

Revisión de literatura sobre técnicas prospectivas del cambio de cobertura y uso del sueloSonia Constanza Garzón Martínez¹  Aníbal Montero Leguizamón²  Victoria Daniela Camacho Ochoa³  

Recibido: (11 de febrero de 2025) – Aceptado: (01 de junio de 2025) – Actualizado: (11 de agosto de 2025)

DOI: 10.17151/luaz.2025.60.5**Resumen**

Objetivo. Se realizó una revisión sistemática de la literatura para identificar los avances en las aplicaciones basadas en algoritmos de aprendizaje automático y aprendizaje profundo para el análisis del cambio de cobertura y uso del suelo con fines prospectivos, sus covariables y las denominaciones de las clasificaciones de cobertura y uso del suelo. **Metodología.** Se llevó a cabo una recuperación bibliográfica, consultando diferentes bibliotecas digitales, a partir de una ecuación de búsqueda delimitada al periodo de estudio entre los años 2000 a 2024. Posteriormente, se aplicó una lectura por niveles para extraer la información relevante al estudio, la cual consistió en la revisión de las secciones de introducción, métodos, figuras, tablas, resultados y conclusiones, para generar las anotaciones pertinentes con la investigación. **Resultados.** Se obtuvo un total de 55 estudios, entre artículos, libros y trabajos de tesis, de los cuales se les resumió y extrajo la información pertinente a la investigación, para luego relacionarla con la discriminación por tipos de cobertura y uso del suelo, factores impulsores del cambio, y las técnicas de aprendizaje automático frecuentemente utilizadas. Adicionalmente, se realizó una citación de los conceptos claves de la modelación del cambio de cobertura y uso del suelo con autómatas celulares. **Conclusiones.** Cuando el análisis del cambio de cobertura y uso del suelo apunta hacia objetivos prospectivos, el uso de autómatas celulares es destacable, por la posibilidad de generar simulaciones de posibles líneas futuras, posibilitando el análisis de escenarios, así como deducir y recrear las reglas de transición entre diferentes tipos de cobertura o usos del suelo, de forma automatizada y estadísticamente evaluable.

Palabras clave: Cobertura vegetal, Usos del suelo, Medio ambiente, Tierras, SIG.

Literature review on land cover change and land use**Abstract**

Objective. A systematic literature review was conducted to identify advances in applications based on Machine Learning and Deep Learning algorithms for the analysis of land cover change and land use for prospective purposes, their covariates and the names of land cover and land use classifications. **Methodology.** A bibliographic retrieval was carried out consulting different digital libraries based on a search equation limited to the study period from 2000 to 2024. Subsequently,

a layered reading was applied to extract information relevant to the study, which consisted in reviewing the introduction, methods, figures, tables, results and conclusions, in order to generate annotations relevant to the research. **Results.** A total of 55 studies were obtained, including articles, books and thesis, from which the information pertinent to the research was summarized and extracted, then related to discrimination by land coverage and land use types, drivers of change, and frequently used machine learning techniques. Additionally, a citation of the key concepts of land cover and land use with cellular automata was provided. **Conclusions.** When analyzing land cover and land use change toward prospective objectives, the use of cellular automata is remarkable, for the possibility of generating simulations of possible future lines, enabling scenario analysis, as well as deducing and recreating the transition rules between different land cover types or land uses, in an automated and statistically evaluable way.

Keywords: Land cover, Land use, Environment, Lands, GIS.

Introducción

Desde un enfoque prospectivo, los escenarios de cambio de uso y cobertura del suelo (LULCC por sus siglas en inglés) se han usado como herramientas para la toma de decisiones en planificación territorial para regiones de bosques tropicales, esto con el fin de proteger la biodiversidad y reducir las emisiones derivadas de la degradación de los ecosistemas, analizando el efecto de diferentes vías de desarrollo y ayudando a formular estrategias científicas e implementar políticas plausibles que conserven los ecosistemas naturales y proporcionen a su vez servicios ecosistémicos (Agudelo et al., 2023).

Actualmente, los planificadores tienen un valioso arsenal de herramientas de simulación para proyectar el LULCC. El desarrollo de los sistemas de información geográfica (SIG) y la tecnología de teledetección ha atraído recientemente más atención a las técnicas de geo-simulación, dada la creciente aplicación de los análisis multiespacioc temporales con la ayuda de la clasificación de imágenes, siendo los algoritmos de aprendizaje automático una opción favorable para los investigadores (Shivappa et al., 2023). En el ámbito de la predicción del LULCC, la célula automática (CA), ha ganado un uso destacado debido al avance del aprendizaje de máquina y particularmente del aprendizaje profundo, dada su robustez para proporcionar simulaciones futuras precisas de los paisajes, ya que las características del terreno pueden cubrirse y representarse al mismo tiempo (Alkaraki et al., 2024).

En el pasado reciente, se han propuesto modelos de aprendizaje de máquina o aprendizaje automatizado para la identificación de transiciones en las clases de uso de la tierra y para la predicción del LULCC. El aprendizaje de máquina, con sus altas tasas de aprendizaje y análisis de Big Data, puede mejorar la precisión del ajuste de los datos, produciendo así simulaciones y predicciones más inteligentes y sólidas.

En comparación con los enfoques empíricos, estadísticos y dinámicos tradicionales, los modelos de aprendizaje automático son más flexibles y tienen la capacidad de aprender y procesar de manera eficiente, pues se superponen a problemas relacionados con covarianzas multivariadas y pueden manejar la no linealidad o la falta de una distribución normal estadísticamente verificable en los datos del LULCC. Como tal, los modelos de aprendizaje de máquina tienen el potencial de mejorar

la simulación y predicción de las dinámicas espaciotemporales no sistemáticas y complejas en el LULCC. A pesar de sus ventajas, la aplicación de modelos de aprendizaje de máquina para la simulación y predicción del LULCC sigue siendo muy limitada (Ouma et al., 2024).

Por otra parte, las cuestiones de los cambios en el uso y la cobertura del suelo y las conexiones intermedias o indirectas de estos cambios han generado interés en los últimos años (Yesserie, 2009). No obstante, identificar y evaluar las fuerzas impulsoras que están detrás del LULCC sigue siendo uno de los ejercicios más difíciles que los geógrafos y científicos ambientales deben abordar continuamente. La dificultad surge del hecho de que en los sistemas de uso y cobertura del suelo entran en juego múltiples acciones e interacciones entre diferentes factores —económicos, políticos, ambientales, biofísicos, institucionales y culturales—, lo que dificulta la comprensión de los procesos subyacentes al fenómeno del cambio. En este contexto, la modelación de los cambios en el uso de la tierra utilizando Big Data está ganando cada vez más popularidad (Omrani et al., 2012).

El objetivo de este artículo es revisar las aplicaciones basadas en algoritmos de aprendizaje de máquina y de aprendizaje profundo para el análisis del cambio de cobertura y uso del suelo con propósitos prospectivos, refiriéndose a la prospectiva para la predicción de futuras coberturas de la tierra, sea en uno o varios posibles escenarios analizables. En paralelo, se exploraron y se distinguieron los factores impulsores que se proponen en las investigaciones encontradas para explicar el LULCC. Esta revisión abarca un periodo comprendido desde el año 1997 con el inicio de la conceptualización de la CA (Batty, 1997; Batty et al., 1997; Clarke et al., 1997, White y Engelen, 1997) en su predominante uso para la simulación del futuro de las coberturas y usos del suelo. Se hace un bosquejo conceptual del LULCC, factores impulsores y autómatas celulares para luego realizar una síntesis de la información compilada, abordada desde las problemáticas que se derivan de la conceptualización y modelado para la predicción del LULCC. Lo anteriormente mencionado se deriva de la metodología implementada y se plasma en los resultados y conclusiones mencionados a continuación.

Materiales y método


Se empleó una recuperación bibliográfica, consultando las bibliotecas digitales Scopus, IEEE Explore, ScienceDirect, Springer, Web of Science y Wiley Online, utilizando las siguientes palabras en sus metabuscadores: (i) land cover change; land use change (ii) prospective, scenarios, forecasting, simulation; (iii) machine learning, deep learning, artificial neural network; (iv) geographical information. La búsqueda se delimitó al periodo comprendido entre los años 2000 y 2024, en los idiomas español e inglés y sin restricciones geográficas.

Siguiendo las pautas de Frey (2017), y debido a que las librerías digitales recuperan documentos no relevantes al propósito de esta investigación, a manera de filtrado, se retuvieron aquellos resultados de las librerías que mostraban en su título, resumen, gráficos y conclusiones, una relación de interés con la temática investigada a partir de los siguientes criterios de descarte: i) falta de alineación con los conceptos dispuestos para la revisión de literatura; ii) enfoque incongruente entre la publicación encontrada y la aplicación particular asociada con predicciones y prospectivas del LULCC; iii) accesibilidad al idioma de la publicación, descartando aquellos que no se encuentren en inglés o español; iv) limitación de disponibilidad por permisos de pago.

Posteriormente, se realizó una lectura de los resultados de fuentes de información en un segundo nivel, el cual consiste en leer en su completitud la introducción, los métodos, las figuras, las tablas, los resultados y las conclusiones, para luego extraer las anotaciones sobre la contribución del documento en relación con las definiciones de los principales conceptos involucrados con la investigación, y a la vez, hacer la compilación sistematizada, apoyada en hojas de cálculo, de los diferentes conjuntos de denominaciones de coberturas y usos de suelo encontrados, denominaciones de factores impulsores, técnicas de aprendizaje de máquina y métricas de evaluación encontrados.

En la [Figura 1](#) se muestra un mapa conceptual del flujo de trabajo aplicado en el que se aplica la metodología propuesta.

Figura 1. Flujo de trabajo de la metodología empleada



Fuente: elaboración propia.

Resultados

Con base en la metodología antes mencionada, se recuperaron 288 documentos de las librerías digitales, de los cuales y a partir de la lectura por niveles, se recopiló un total de 55 estudios entre artículos, libros y trabajos de tesis a los que se les extrajo la información pertinente a la investigación. A continuación, se resumen los hallazgos, así como el análisis bibliométrico obtenido.

Cobertura y uso del suelo

La cobertura de la tierra es todo aquello que se observa sobre la superficie terrestre tal como vegetación, áreas urbanas, afloramientos rocosos, cuerpos de agua entre otros. Por otra parte, el uso de la tierra se relaciona con las actividades humanas o las funciones económicas de una porción específica de la tierra. En este sentido, los cambios del uso de la tierra son impulsores de cambios de las coberturas sobre la superficie terrestre (Rodríguez et al., 2019). Los estudios de monitoreo de la cobertura y uso de la tierra son importantes en la investigación ambiental, ya que permiten evaluar las tendencias espacio-temporales de procesos como la deforestación y degradación ambiental, provocada por las actividades humanas (Escandón et al., 2018); así como realizar el seguimiento al cumplimiento de los acuerdos de conservación, generar análisis entre diferentes actores, definir variables asociadas a la fragmentación de ecosistemas, ser base para el cálculo de reservas de carbono, identificar aproximaciones sobre recursos hídricos, ejercicios de conectividad vial entre centros poblados, y demás aplicaciones (Arango y Ordoñez, 2020).

En la [Tabla 1](#), se muestra la denominación de las coberturas y usos de suelo encontrados en cada uno de los estudios recuperados, encontrando con mayor frecuencia y en el orden de mayor aparición las siguientes categorías: agricultura (tierra cultivable o tierra agrícola); urbano o área construida; bosque; agua o cuerpo de agua; pastizales.

Tabla 1. Denominaciones de coberturas y usos de suelo encontrados

Referencia	Usos o coberturas de suelo en el estudio
Trunfio (2005)	Wildfire spreading.
Lahti (2008)	Rural houses, Parks, Forest mangrove orchads water, Parishes and coastline, Airports, Cimmey's and mines, Core habitats and remmant vegetation, Extensive agricultural land, Growth zones, Prohibited areas and National parks.
Charif et al. (2012)	Urban-neighbours, Industrial or commercial-neighbours, Agricultural-neighbours, Forest-neighbours.
Memarian et al. (2012)	Agriculture, Bare land, Forest, Grassland, Marshland, Mining, Oil palm, Rubber, Urban area, Water bodies.
Li et al. (2012)	Urban, Agriculture, Range land, Forest
Hewitt et al. (2013)	Urban land, Non-urban land
Rodríguez et al. (2013)	Deforestation, crop intensification, conversion to pastures, and abandonment
Yang et al. (2014a)	Agricultural land, Construction land, Forestland, Water.
Qiang y Lam (2015)	Urban, Agriculture, Rangeland, Forest, Water, Wetland, Barren
Yang et al. (2016)	Agricultural land, Construction land, Unused land, Conservation land.
Yao et al. (2017)	Urban, Non-urban
Rimal et al. (2018)	Sand Area (SA), Water body (WB), Open field (OF), Vegetation cover (VC), Urban/Built-up (UB), Cultivated land (CL).
Irawan et al. (2019)	Forest, Non-forest vegetation, Settlement area, Open space, Waters
Kang et al. (2019)	Construction land, Agricultural land, Water area, Nature reserve
Falah et al. (2020)	Urban, Non-urban
Thanekar (2020)	Barren land, Built-up and Urban, Cropland, Deciduous forests, Evergreen forests, Fallow land, Grassland, Mangroves, Mixed forests, Plantations, Shrubland, Wasteland, Water bodies, Others.
Kulithalai y Deka (2022)	Barren land, Build-up, Forest, Vegetation, Waterbody.
Wang et al. (2021)	Urban, Non-urban.

Wu et al. (2022)	Cropland, Grassland, Woodland, Urban and rural settlement, Other special land uses, Undeveloped land.
Ghalehtemouri et al. (2022)	Gardens, Water body, Built up land, Irrigated agriculture, Rainfed agriculture, Pasture and mountains.
Sajan et al. (2022)	Built-up areas, vegetation, fallow lands, croplands, litchi cultivation areas, wetlands, and waterbodies.
González et al. (2022)	CORINE nomenclature of Level 1 and 2: artificial surface, agricultural areas, forest, shrub and/or herbaceous vegetation, sparsely or no vegetated areas, water bodies, secondary vegetation, and ice and snow; the latter only for the Andean region
Agudelo et al. (2023)	Floodplain forests, Grasslands and shrublands, Fragmented Forests and secondary vegetation, Amazon forests, Pastures and crops, Water bodies and wetlands, Floodplain forests
Fetene et al. (2023)	Forest, Agricultural land, Built-up, Bare land, Water, Grassland, Shrubland
Shivappa et al. (2023)	Water body, Urban, Forest, Agriculture, Barren lands
Anand et al. (2023)	Waterbodies, Built-up land, Crop land, Plantation, Fallow land.
Luo et al. (2023)	Barren, Cropland, Forest, Grass, Shrub, Urban, Water
Gasirabo et al. (2023)	Forestland, Grassland, Cropland, Settlement, Water
Aniah et al. (2023)	Settlement, Agriculture, Bare land, Water Body, Shrub and tree Savannah, Wooded Savannah
Kumar et al. (2024)	Agriculture, Dense forest, Open forest, Built-up area, Barren land, Water body
Atef et al. (2024)	Water, desert, built-up, and agricultural
Moreira et al. (2024)	Forest, Non-forest formation, Pasture, Temporary crops, Urban, Mining, Water
Pawe y Saikia (2024)	Built-up area, Non-built-up area
Kayitesy et al. (2024)	Bareland, Built-up, Grass, Forest, River, Tea, Agriculture, Lake
Chisanga et al. (2024)	Cropland, Seasonally flooded grassland, Sparse forest, Dense forest, Shrub land, Grassland, Wetland, Built-up, Bare land, Water body
Alkaraki et al. (2024)	Urban, Barren, Forest, Agriculture, Range- sparsely vegetated
Raza et al. (2024)	Built-up, Water, Vegetation, Barren Land
Isinkaralar (2024)	Settled areas and other urban areas
Ouma et al. (2024)	Tree cover, shrubland, grassland, cropland, water, built-up areas and bare soil open land.

Fuente: elaboración propia.

Cambio de cobertura y uso del suelo (LULCC)

Los LULCC representan una de las transformaciones más visibles y complejas del paisaje, con impactos profundos en los ecosistemas, la estructura socioeconómica y la dinámica ambiental a distintas escalas. Estos cambios no ocurren de manera homogénea; por el contrario, están determinados por una diversidad de impulsores, que incluyen factores económicos, políticos, demográficos y climáticos, los cuales interactúan de forma diferenciada según la región, el tipo de cubierta original y los patrones de desarrollo urbano o rural. La heterogeneidad en las condiciones biofísicas, culturales y de gobernanza de cada territorio genera trayectorias de cambio muy diversas,

lo que plantea importantes desafíos para su análisis, modelación y gestión. En este contexto, distintos estudios han abordado las implicaciones del LULCC, especialmente en zonas donde el crecimiento urbano y el desarrollo económico han inducido profundas transformaciones del territorio.

En este sentido, Irawan et al. (2019) mencionan en su publicación que el desarrollo de una ciudad es una manifestación del desarrollo regional, cuyo impacto se refleja en los cambios de la cobertura de la tierra y el incremento de las áreas de asentamiento. De acuerdo con Kulithalai et al. (2021), el LULCC se ha convertido en un asunto crítico para los tomadores de decisiones y conservacionistas debido al crecimiento inapropiado y sus efectos en los ecosistemas naturales. Los LULCC son uno de los impactos al paisaje más evidentes, debido a las actividades antrópicas, particularmente en regiones de rápido crecimiento. De modo semejante, Falah et al. (2020) refieren que hoy en día el análisis del LULCC en el uso urbano juega un papel principal en las decisiones y programas de largo plazo. En India, las áreas que proporcionan los mayores rendimientos agrícolas están bajo la amenaza de extinguirse o bien de sufrir un cambio de uso, debido al efecto antropogénico y el consecuente cambio climático aunado al rápido ritmo de las actividades de desarrollo (Sajan et al., 2022).

Por otro lado, Wang et al. (2021) refieren que las ciudades costeras bajas son ampliamente reconocidas como zonas de asentamientos urbanos densamente poblados. Ello las vuelve más vulnerables a riesgos resultantes del intensivo cambio de cobertura y uso del suelo, de las actividades humanas, del cambio climático global y del aumento del nivel del mar. Qiang y Lam (2015) mencionan que la cuenca baja del Río Mississippi es una de las costas más vulnerables de los Estados Unidos, que ha enfrentado numerosas amenazas en las pasadas décadas. El mayor problema en la región deltaica es la significativa pérdida de tierra durante los últimos años debido a dichos factores. De modo que, las principales interrogantes científicas y de gestión se sintetizan en identificar cuáles son los factores que contribuyen al LULCC, cómo modelar dichos factores y cómo definir los escenarios futuros asociados.

Factores impulsores

El LULCC constituye un fenómeno determinado por factores biofísicos y antrópicos cuya influencia varía según el contexto geográfico, temporal y socioeconómico. La identificación y análisis de estos factores impulsores representa un reto metodológico, dada la heterogeneidad de sus efectos, la multiplicidad de escalas en las que operan y, en muchos casos, la disponibilidad o accesibilidad limitada de los insumos necesarios para su caracterización. Esta diversidad no solo refleja la naturaleza multifactorial del fenómeno, sino que también evidencia las dificultades asociadas a su gestión e interpretación, lo cual incide directamente en la formulación de políticas de planificación territorial basadas en evidencia.

En palabras de Feng y Wang (2021), los LULCC son una actividad espaciotemporal compleja, está influenciada por una variedad de factores, entre ellos la sociedad, la economía, la geografía y las políticas. Por ejemplo, la expansión urbana se ve afectada por muchos factores y puede resultar difícil determinar cuál es el que tiene mayor influencia. (Christiansen y Loftsgarden, 2011). A pesar de los numerosos estudios dedicados a investigar los patrones y mecanismos de expansión urbana, la dinámica espaciotemporal de las fuerzas impulsoras y sus diferencias regionales no han sido bien documentadas (Li et al., 2018). Además, las fuerzas impulsoras de la expansión urbana varían entre

ciudades, regiones y países (Christiansen y Loftsgarden, 2011). Por ejemplo, Clarke et al. (1997) delimitaron inicialmente dentro del conjunto de impulsores la topografía, las redes de vías y la distribución de asentamientos. En la [Tabla 2](#), se muestra la denominación de los factores impulsores encontrados en cada uno de los estudios recuperados, siendo de los más frecuentes los factores alusivos a la morfología del terreno como la pendiente y la elevación, extraídos de los modelos digitales y con respecto a los factores de carácter antrópico la distancia a las vías.

Tabla 2. *Denominaciones de factores impulsores encontrados*

Referencia	Usos o coberturas de suelo en el estudio
Lahti (2008)	Elevation data, Transport network (roads and railways)
Charif et al. (2012)	Slope, Transport networks
Memarian et al. (2012)	Proximity to stream, Proximity to road, Proximity to population centre, Proximity to sawmill, Proximity to oil refinery, Proximity to WTP, Proximity to landslide, Runoff accumulation potential, Rainfall, Sediment transport capacity index, Stability index, Saturation index, Standard deviation of elevation, Elevation, Soil series, Soil suitability for agriculture, Soil hydrologic group, Geology, Consistency ratio
Li et al. (2012)	Slope, Land Use, Excluded, Urban, Transportation, Hillshade
Hewitt et al. (2013)	Euclidean distance from water sources, Euclidean distance from roads, Elevation, Rainfall, Slope, Temperature
Rodríguez et al. (2013)	Demographic, socioeconomic, and abiotic variables and to some attractors of landscape change
Yang et al. (2014a)	Distance to city center, Distance to town center, Distance to main road, Distance to coastline, Slope
Qiang y Lam (2015)	Elevation, Soil type, Original LULC, Distance to primary roads, Distance to secondary roads, Distance to urban area, Distance to open water, Distance to pipelines, Number of urban cells, Number of agriculture cells, Number of rangeland cells, Number of forest cells, Number of open water cells, Number of wetland cells, Number of barren cells.
Yang et al. (2014a)	Distance to town center, Distance to light rail, Distance to main road, Distance to coastline, Distance to water, Distance to forestland, Distance to construction land, Distance to agricultural land, Slope
Yao et al. (2017)	Population growth; Global markets and agricultural production; Local crop production; meat production.
Rimal et al. (2018)	Distance from main roads, Distance from water bodies, Distance from built-up areas, Slope
Irawan et al. (2019)	Elevation, slope, distance from the river, distance from the road, distance from the toll gates and distance from the toll road.
Kang et al. (2019)	Land use
Falah et al. (2020)	Landsat images in 1996 and 2016
Thanekar (2020)	Aspect*(terrain analysis), DEM, Hillshade, Slope
Kulithalai y Deka (2022)	DEM, slope, road network, distance from the road, distance from built-up areas, and distance from stream network
Wang et al. (2021)	DEM, Slope, Distance to coastlines, Distance to city centres, Distance to road, Distance to green parks, Distance to waterbodies, Distance to railway lines, Distance to railway stations, Neighbouring urban, Road density

Wu et al. (2022)	DEM, Slope, Distance to water, Distance to urban center, Distance to district center, GDP, Population, Distance to main road, Distance to railway, Distance to highway, Distance to traffic junction, Distance to bus station
Ghalehtemouri et al. (2022)	Market influence, population growth and level of technology
Sajan et al. (2022)	DEM, Slope, Euclidean distance to the railway line, Euclidean distance to a river, Euclidean distance to road, and Euclidean distance to existing settlement
González et al. (2022)	Landsat OLI 8
Agudelo et al. (2023)	Degradation, Substitution, Regeneration
Fetene et al. (2023)	Distance from the road and river, slope, aspect
Shivappa et al. (2023)	Slope, road map, built-up maps, digital elevation model
Anand et al. (2023)	DEM, Slope, distance to road and distance to river
Luo et al. (2023)	Annual mean temperature, Annual precipitation, DEM, Slope, Distance to water, Distance to main roads, Distance to highway, Distance to airports, Distance to urban centers
Gasirabo et al. (2023)	Distance to rivers, distance to roads, locations of major cities, elevation, slope and population
Aniah et al. (2023)	Land use and land cover
Atef et al. (2024)	Slope, DEM, Distance to canal, Distance to roads
Moreira et al. (2024)	Distance to roads, Elevation, Slope, Distance to anthropic disturbance
Pawe y Saikia (2024)	Accessibility, Mobility services, Higher facility areas, Social facilities, Employment service, Local facilities
Kayitesy et al. (2024)	Elevation, slope, Soil organic carbon, Soil clay content, soil salt content, soil silt content, Distance to roads, Distance to rivers, Distance to urban, Population density, National parks, Lake
Chisanga et al. (2024)	Elevation, slope, aspect
Alkaraki et al. (2024)	Slope, Aspect, Elevation, Distance to roads, Distance to major cities, Population density
Raza et al. (2024)	Distance from educational centers, distance from healthcare centers , distance from major roads, distance from the river, digital elevation model.
Isinkaralar (2024)	Income, distance, population with the close circle
Ouma et al. (2024)	Elevation, Slope, Aspect, Distance to roads, Distance to urban areas, Land use and land cover

Fuente: elaboración propia.

Autómata celular (CA)

Se observa un predominio del uso de la CA para modelar y generar datos futuros a partir del LULCC evidenciado de la recuperación de literatura de esta investigación. De las lecturas de segundo nivel realizadas se encuentra que, en comparación a los enfoques cuantitativos de la última década y bajo el auge del uso de las técnicas de aprendizaje de máquina y la compatibilidad conceptual de las reglas de transición utilizadas por la cadenas de Markov y la CA, este enfoque de las CA habilita y

prioriza el modelado de las interacciones locales de las coberturas y usos del suelo, permite la validación tanto temática como estadística, genera fácil comparabilidad del desempeño predictivo cuantificado en la literatura, habilita la generación de datos futuros y permite condicionar estas simulaciones para generar escenarios prospectivos. En este caso, los modelos netamente estadísticos o físicos no comprenden todas las ventajas anteriormente mencionadas, solo enfoques más generalizados como los modelos basados en agentes (ABM) y un recurso computacional suficiente habilitarían estas mismas capacidades en adición con la incorporación de la complejidad de los agentes estudiados (Torres et al., 2023).

Batty et al. (1997) definen una CA a partir de cuatro principios: 1) celdas dentro de un arreglo espacial, 2) un conjunto de estados para esas celdas, 3) vecindad de celdas definible para cada una y 4) reglas de transición entre estados de las celdas. Batty (1997) aplica esta conceptualización para simular la ubicación de lo que denomina actividad urbana. Posteriormente, se destaca el potencial de los modelos de autómatas celulares para simular transformaciones del territorio, incluido el LULCC al poder integrar la preservación de las zonas ribereñas, áreas ambientalmente sensibles y la gestión de servicios ecosistémicos en las proyecciones de crecimiento urbano a escala regional (Mitsova et al., 2011).


Yang et al. (2014a) destacan que la mayoría de las investigaciones se enfocan en descubrir los factores macroscópicos que afectan este cambio, lo que resulta en ignorar los efectos locales dentro de los vecinos. De la recreación simulada de esas dinámicas resultará la proyección a futuro de la configuración del territorio, específicamente de la cobertura del suelo. Los modelos de autómatas celulares pueden ser ampliamente utilizados en estudios urbanos debido a su naturaleza dinámica, su flexibilidad y su capacidad de integrarse con otros modelos, así como la de ajustarse según los datos disponibles (Falah et al., 2020).

Algoritmos empleados

Se mencionó en la descripción de la CA que uno de los cuatro principios de esta son sus llamadas reglas de transición (Batty et al., 1997) dado que, en ese entonces, tal y como en el Juego de la Vida de John Conway (Berlekamp et al., 1982), las transiciones y su probabilidad de ocurrencia eran definidas manualmente a manera de sistema experto. Los algoritmos y métodos tanto computacionales como estadísticos como por ejemplo, las redes neuronales artificiales y las cadenas de Markov permiten entrenar lo que se denomina la función de transición, que toma como entradas del algoritmo, los datos derivados de las diferentes capas ráster que dan cuenta de las coberturas o usos de suelo presentes (tomando un periodo observado de referencia), así como las capas que dan cuenta de los factores impulsores, para que los convierta en coberturas o usos de suelo futuras como salidas del algoritmo (tomando el periodo siguiente al de referencia). La función de transición representada por el algoritmo ya entrenado permitirá la generación de datos simulados, de manera recurrente, al tomar el último periodo de referencia, sea uno observado o uno ya generado para el futuro, desde las coberturas o usos de suelo tanto observadas como generadas junto con las capas que representan los factores impulsores.

La [Figura 2](#) muestra un esquema del generador de datos que construye las entradas al modelo para que el algoritmo asocie las capas de coberturas o usos de suelo de un periodo de referencia y los factores impulsores a capas de coberturas o usos de suelo del siguiente periodo.

Figura 2. Esquema de la función de transición del CA derivado de los estudios que utilizan cadenas de Markov y métodos de aprendizaje de máquina



Fuente: elaboración propia.

En la [Tabla 3](#), se muestra el listado de las diferentes técnicas de aprendizaje de máquina empleadas en cada uno de los estudios recuperados para la deducción de las reglas de transición de los autómatas celulares, junto con las métricas de evaluación del desempeño predictivo en los diferentes estudios, siendo destacado el uso frecuente del Accuracy para evaluar las redes neuronales artificiales y la combinación de estas con cadenas de Markov, seguido del índice Kappa vinculado con los mismos métodos.

Tabla 3. Técnicas de aprendizaje de máquina y métricas de evaluación encontradas

Referencia	Método base del CA	Métricas de desempeño
Trunfio (2005)	Artificial Neural Network	Accuracy rate
Lahti (2008)	Expert system	Map visual comparison
Charif et al. (2012)	Artificial Neural Network	Accuracy rate, Confusion Matrix
Memarian et al. (2012)	Markov Chain	Figure of Merit, Quantity Error Allocation Error
Li et al. (2012)	Expert system	Area, Edge, Clusters
Hewitt et al. (2013)	Expert system	()
Rodríguez et al. (2013)	Expert system	Accuracy rate
Yang et al. (2014a)	Expert system	Kappa index
Qiang y Lam (2015)	Artificial Neural Network	Kappa index, Accuracy rate, confusion matrix
Yang et al. (2016)	Expert system	Kappa index
Yao et al. (2017)	Random Forest	Accuracy rate, Figure of Merit
Rimal et al. (2018)	Markov Chain	Accuracy rate
Irawan et al. (2019)	Markov Chain	Kappa index
Kang et al. (2019)	Markov Chain	Kappa index
Falah et al. (2020)	Analytic hierarchy process	Kappa index
Thanekar (2020)	Artificial Neural Network	Accuracy rate, Kappa index

Kulithalai y Deka (2022)	Random Forest, Support Vector Machine, Markov Chain	Accuracy rate
Wang et al. (2021)	Expert system	Figure of Merit
Wu et al. (2022)	Artificial Neural Network	Accuracy rate, Precision rate, Recall rate, F1, ROC curve, Confusion Matrix, Error map
Ghalehtemouri et al. (2022)	Markov Chain	Accuracy rate, Expected error matrix
Sajan et al. (2022)	Artificial Neural Network	Kappa index
González et al. (2022)	Random Forest, Support Vector Machine, Markov chain	Accuracy rate
Agudelo et al. (2023)	Artificial Neural Network, Markov chain	Accuracy rate
Fetene et al. (2023)	Artificial Neural Network	Accuracy, Kappa index
Shivappa et al. (2023)	Artificial Neural Network	Accuracy, Kappa index
Anand et al. (2023)	Artificial Neural Network, Markov chain	Accuracy, Kappa index
Luo et al. (2023)	Global Change Analysis Model	Root Mean Square Deviation
Gasirabo et al. (2023)	Markov Chain	Accuracy, Kappa index
Aniah et al. (2023)	Markov Chain	Accuracy, Kappa index
Kumar et al. (2024)	Markov Chain	Accuracy
Atef et al. (2024)	Markov Chain	Accuracy, Kappa index
Moreira et al. (2024)	Artificial Neural Network, Markov chain	Accuracy
Pawe y Saikia (2024)	Markov Chain	Kappa index
Kayitesy et al. (2024)	Artificial Neural Network	Accuracy
Chisanga et al. (2024)	Artificial Neural Network	Accuracy, Kappa index
Alkaraki et al. (2024)	Artificial Neural Network	Accuracy, Kappa index
Raza et al. (2024)	Artificial Neural Network, Markov chain	Accuracy, Kappa index
Isinkaralar (2024)	Markov Chain	Accuracy, Kappa index
Ouma et al. (2024)	Artificial Neural Network	Accuracy, Kappa index

Fuente: elaboración propia.

Según Wu et al. (2022) los modelados generalmente ignoraban las situaciones de falta de homogeneidad y combinaciones del uso de suelo y simplificaban la celda a un único tipo de uso. En su estudio, desarrollaron un modelo basado en una red neuronal convolucional de etiquetas múltiples y CA para simular la compleja y heterogénea evolución del uso de suelo. La estrategia de aprendizaje de etiquetas múltiples en el modelo propuesto puede representar mezclas de usos del suelo etiquetando múltiples tipos de usos en cada celda de la cuadrícula. Además, las reglas de transición de la CA fueron modificadas para adaptarlas a la estrategia de aprendizaje de etiquetas múltiples y minadas en un acople con su red neuronal convolucional bajo tres mecanismos de interacción, incluidos: el efecto de vecindad, el coeficiente de inercia adaptativo y el factor aleatorio.

Conclusiones y recomendaciones

En la revisión de literatura se identificó que los dos métodos o técnicas más frecuentes han sido las cadenas de Markov así como las redes neuronales artificiales, esto independientemente de las particularidades de las arquitecturas utilizadas, tal y como se muestra en la segunda columna de la

[Tabla 3](#). Dentro de las ventajas que presentan las cadenas de Markov, cabe mencionar que la definición de este proceso estocástico es compatible con la definición de la CA al determinar que un estado de una unidad de observación en un periodo dado depende únicamente de los estados de las unidades de observación en el periodo inmediatamente anterior.

Por otra parte, la consideración previa también puede explicar, al menos parcialmente, por qué la arquitectura más frecuentemente encontrada en los estudios que emplean redes neuronales convolucionales es el perceptrón multicapa, así como en algunos pocos casos la red neuronal convolucional, siendo estos dos tipos de arquitecturas propios de las redes neuronales prealimentadas.

Considerando las características antes mencionadas sobre cada uno de los dos métodos, la funcionalidad de estos constituye el entrenamiento de una sola función de transición que recrea las reglas de cambio de la CA. En la [Figura 2](#) se muestra cómo esta función recibe tanto la información de los estados de las coberturas o usos de suelo como de las capas de información de sus impulsores de cambio, esto en un periodo dado para recrear la cobertura del periodo siguiente. En este orden, en la fase de entrenamiento del modelo tomaría como futuro, los datos de cobertura o uso de suelo de los periodos siguientes, mientras que, en una fase de predicción, se tomará la función de transición entrenada para generar datos en periodos futuros. Por ejemplo, Clarke et al. (1997) propusieron inicialmente su autómata celular a manera de sistema experto, definiendo las reglas de transición y calibración para el cambio del uso del suelo, en procura de emular los cambios observados en los datos.

Rienow y Goetzke (2015) afirman frente a esto que, aunque el algoritmo SLEUTH que utiliza estas reglas de transición y que plantea Silva y Clarke (2002), el proceso de modelado aún está fuertemente influenciado por decisiones estocásticas que resultan en un patrón variable. Además, no brinda información sobre las fuerzas humanas y ecológicas que impulsan la idoneidad local del crecimiento urbano. Por lo tanto, se hace importante combinar las habilidades de simulación de CA con el enfoque de aprendizaje automático.

En relación con el uso de cadenas de Markov como de perceptrones multicapa, cada uno de estos tiene ventajas particulares. El uso de cadenas de Markov puede ser recomendado donde el volumen de información a procesar es alto, debido a que este consiste en un entrenamiento del modelo mediante estimación estadística y no requiere condiciones especiales de cómputo, mientras que el perceptrón multicapa permite la inclusión de capas de información que den cuenta sobre los factores impulsores del cambio y deduzca las relaciones no lineales entre estos y las coberturas o usos de suelo a la salida.

Existe cierta heterogeneidad en la denominación de las categorías de los usos y coberturas de suelo tenidas en cuenta en diferentes estudios, tal y como se observó en la [Tabla 1](#), y técnicamente no se disponen listados de categorías estandarizadas. Por otro lado, la [Tabla 4](#) presenta una clasificación propuesta de las diferentes alusiones a coberturas y usos del suelo encontradas en la revisión de la literatura. Todos los referentes consultados mencionan clases generales de cobertura, aunque no existe un consenso sobre su categorización. Esta falta de acuerdo responde a las características locales de la cobertura del suelo en cada zona de estudio, así como al propósito específico de cada investigación.

Tabla 4. *Clasificación propuesta para las denominaciones de coberturas y usos de suelo encontradas*

Agricultura	Agricultural, cropland, fallow land, plantations, extensive agricultural, cultivated land.
Área urbana	Construction, built-up, urban, houses, settlement area, airports, urban-neighbours, industrial or commercial-neighbours.
Minería	Mining, Chimney.
Bosque	Forest, deciduous forests, evergreen forests, mixed forests, core habitats, vegetation.
Suelo desnudo	Barren land, shrubland, wasteland, open space, undeveloped land, sand area, open field.
Pastos	grassland, rangeland, gardens, pasture, non-forest vegetation.
Humedal	Mangroves, marshland.
Cuerpos de agua	Water, water bodies, wetland.

Fuente: elaboración propia.

En cuanto a las métricas para evaluar cuantitativamente el desempeño predictivo de los modelos entrenados en predecir los cambios de usos y coberturas, se observa que existe una predilección por la aplicación de la exactitud y el índice Kappa, tal y como se presenta en la tercera columna de la [Tabla 3](#); esto bien puede responder a la comparabilidad del desempeño frente a las referencias que se encuentran a nivel global sobre el uso de los métodos mencionados en la segunda columna de la [Tabla 3](#). También se hace importante el uso de la exactitud como única medida resumen de la evaluación de un modelado en los estudios donde el número de categorías de usos o coberturas de suelo es numeroso, tal y como se observa en los ejemplos de la [Tabla 2](#). Por otra parte, aunque el índice Kappa también es ampliamente utilizado, Pontius y Millones (2011) evidencian carencias técnicas en este y recomiendan el uso de las matrices de confusión en remplazo de este.

Ahora bien, como menciona Omrani et al. (2012) sobre los factores económicos, políticos, ambientales, biofísicos, institucionales y culturales que accionan el LULCC, se observa que estudios como los de Yao et al. (2017), Ghalehtemouri et al. (2022) y Isinkaralar (2024) comprenden algunos factores impulsores socioeconómicos; este tipo de inclusiones son relativamente pocas en comparación con el resto de literatura encontrada y que, salvo cuando se incluyen factores impulsores derivados de la distancia a redes y puntos de servicio, solo se tienen en cuenta los factores biofísicos. Ante esto, Yang et al. (2014b) menciona que se ignoran fuerzas globales como políticas nacionales, mercados internacionales o cambio climático, que pueden ser incluso los impulsores principales del LULCC.

En los distintos trabajos de investigación revisados, es entendido que el cambio de coberturas y usos del suelo se relaciona con factores que causan el impulso o contracción de la transformación, cuya cuantificación se materializa en el preprocesamiento de las capas de información para que estas sean referidas sobre cada tesela o unidad de observación en el área de estudio a manera de

distancias, magnitudes o clasificaciones. De esta forma, se construyen los valores de factores impulsores para el modelado del cambio de cobertura y uso del suelo. En la [Tabla 5](#), se presenta una clasificación propuesta de las diferentes alusiones a factores impulsores encontradas en la revisión de literatura.

Tabla 5. *Clasificación propuesta para las denominaciones de factores impulsores encontrados*

Variables antrópicas	Distancia a áreas urbanas	Distance to city center, distance to town center, distance to district center, distance to construction land, distance to urban center, distance from built-up areas, distance to existing settlement.
	Distancia a redes o puntos de transporte	Distance to main road, distance to light rail, distance to railway, distance to highway, distance to traffic junction, distance from the toll gates, distance from the toll road, distance to bus station, distance to primary roads, distance to secondary roads.
	Distancia a redes o puntos de servicio	Distance to pipelines, distance from stream network, distance to green parks.
	Variables socioeconómicas	GDP, population, market influence, population growth, level of technology.
	Distancia a ejes económicos	Distance to agricultural land, proximity to sawmill, proximity to oil refinery.
Variables naturales	Características físicas del suelo	Proximity to landslide, runoff accumulation potential, sediment transport capacity index, stability index, saturation index, soil suitability for agriculture, soil hydrologic group, geology.
	Distancia a cuerpos de agua	Distance to coastline, distance to water, distance from the river, distance to open water.
	Altimetría	Hillshade, slope, elevation.
	Otros	Distance to forestland.

Fuente: elaboración propia.

Aunque en el alcance de este estudio no han sido relacionadas las diferentes escalas de la información geográfica incorporadas en las distintas investigaciones, es posible afirmar en general que esta depende directamente de la escala asociada a los insumos de cada estudio. Actualmente, existe la disponibilidad de herramientas de software libre para el procesamiento y modelado de datos espaciales que no se limitan por la cantidad, volumen ni la estructura de estos, por lo que se puede observar en la literatura las diferentes posibilidades de experimentación del modelado con algoritmos, estructuras de datos y extracción de características. La asequibilidad a información cuantificable a diferentes resoluciones espaciales y temporales sobre la clasificación en teselas de las coberturas de suelo, así como sobre aquellos factores que impulsan y contraen ese mismo cambio, ha permitido, a lo largo de las diferentes investigaciones que se muestran en esta revisión, el modelado del cambio de coberturas en el tiempo con ayuda de autómatas celulares. También se

encuentra que, durante los años recientes, las reglas de transición a diferentes coberturas del suelo son deducidas y recreadas mediante las técnicas de aprendizaje de máquina.

Se ha observado una tendencia reciente, especialmente durante las décadas de 2010 y 2020, a preferir el uso de autómatas celulares basados en algoritmos de aprendizaje automático, en lugar de los sistemas expertos popularizados en los años noventa y principios de los 2000. Esto se debe a la tendencia global hacia el uso de técnicas de aprendizaje de máquina y de aprendizaje profundo nacidas durante los años noventa y aplicadas en las mayores empresas de tecnología durante los años 2000 y 2010 (Delipetrev et al, 2020). En este sentido, se puede mencionar, que el crecimiento del uso de tecnologías asociadas al uso de sistemas de información geográfica y la disponibilidad creciente de datos geográficos (UN Committee of Experts, 2017) habilita la posibilidad de una mayor exploración de las causantes de un fenómeno como el cambio de coberturas de suelo y cuya definición requiere de un componente espacial como temporal (Gašparović, 2020).

Finalmente, de las diferentes inferencias sobre el futuro de las coberturas y usos del suelo en sus respectivas áreas de estudio, se puede generalizar que la orientación del análisis del cambio de coberturas y usos de suelo hacia objetivos prospectivos requiere de las siguientes dos capacidades: primero, tener potencial predictivo estadísticamente evaluado; y segundo, brindar la posibilidad de generar un análisis por comparación de escenarios. Sobre la primera capacidad, los estudios que basan sus autómatas celulares en algoritmos de aprendizaje de máquina muestran desempeños predictivos con exactitudes por encima del 80 % bajo la susceptibilidad a ser mejorados al incluir más capas de información o de extracción de nuevas características (Kulithalai y Deka, 2022; Agudelo et al., 2023; Anand et al., 2023; Alkaraki et al., 2024; Chisanga et al., 2024; Pawe y Saikia, 2024; Raza et al., 2024).

Sobre la segunda capacidad, la generación de nuevos datos a partir de simulaciones con los autómatas celulares es susceptible de ser acotada por reglas de transición definidas por la exclusión de tipos de cambio de coberturas de suelo, como lo realizaban por ejemplo Clarke et al. (1997), al delimitar las zonas de crecimiento.

Veldkamp y Lambin (2001) enmarcaron cuatro retos dentro de lo que sería la predicción del futuro del uso del suelo: i. El modelado de los factores que impulsan el cambio de uso del suelo, ii. el modelado de la dependencia de la escala de los factores que impulsan el cambio de uso del suelo, iii. el modelado para predecir la ubicación versus la cantidad del cambio de uso del suelo, y iv. la incorporación de retroalimentaciones biofísicas en los modelos de cambio de uso del suelo.

En relación con la problemática sobre el escalado y replicabilidad de las metodologías diseñadas en los estudios, Li et al. (2012), Yao et al. (2017) y Kang et al. (2019) identifican esta misma y mencionan que la generación de datos simulados y predicciones puede llegar a ser costoso en términos tanto de procesamiento como de tiempos de producción. La problemática la abordan con una estrategia de enfoque computacional, por lo que presentan soluciones de implementaciones en la nube y computación distribuida. En este sentido, se debe mencionar que los modelos basados en agentes hacen continuación de la aplicación del enfoque del uso de series de datos espaciales, relegando a la CA a un caso particular de este concepto, más su uso incipiente (Kim et al., 2022; Chambers et al., 2023) emerge de la necesidad adicional de disponer de datos y fuentes de información sobre los agentes a modelar, lo que puede restringir aún más la cobertura y el alcance de los estudios.

Agradecimientos

Los autores expresan sus más sinceros agradecimientos a la Dirección de Investigación y Prospectiva (DIP) del Instituto Geográfico Agustín Codazzi – IGAC por permitir el desarrollo de la presente investigación en el marco de los proyectos adelantados por la dirección.

Potencial conflicto de intereses

Los autores declaran no tener potenciales conflictos de intereses.

Fuentes de financiación

Esta investigación fue financiada por el Instituto Geográfico Agustín Codazzi – IGAC.

Referencias bibliográficas

- Agudelo-Hz, W. J., Castillo-Barrera, N. C., y Uriel, M. G. (2023). Scenarios of land use and land cover change in the Colombian Amazon to evaluate alternative post-conflict pathways. *Scientific Reports*, 13(1), 1–14. <https://doi.org/10.1038/s41598-023-29243-2>
- Alkaraki, K. F., Hazaymeh, K., Al-Tarawneh, O. M. y Jawarneh, R. N. (2024). Deep learning-based modeling of land use/land cover changes impact on land surface temperature in Greater Amman Municipality, Jordan (1980–2030). *GeoJournal*, 89(4), 1–21. <https://doi.org/10.1007/S10708-024-11187-3/FIGURES/100>
- Anand, B., Rekha, R. S., Radhakrishnan, N. y Ramaswamy, K. (2023). Analysis of LULC change dynamics and its impact assessment using CA-ANN model in part of Coimbatore region, India. *GeoJournal*, 88(6), 5825–5845. <https://doi.org/10.1007/S10708-023-10944-0/METRICS>
- Aniah, P., Bawakyillenuo, S., Codjoe, S. N. A., y Dzanku, F. M. (2023). Land use and land cover change detection and prediction based on CA-Markov chain in the savannah ecological zone of Ghana. *Environmental Challenges*, 10. <https://doi.org/10.1016/J.ENVC.2022.100664>
- Arango, D., y Ordóñez, M. (2020). *Protocolo de monitoreo de cambios de coberturas de la tierra*. The Nature Conservancy, Amazon Conservation Team. https://www.nature.org/content/dam/tnc/nature/en/documents/AFC_Protocolo_Monitoreo_Coberturas_Baja.pdf
- Atef, I., Ahmed, W. y Abdel-Maguid, R. H. (2024). Future land use land cover changes in El-Fayoum governorate: a simulation study using satellite data and CA-Markov model. *Stochastic Environmental Research and Risk Assessment*, 38(2), 651–664. <https://doi.org/10.1007/S00477-023-02592-0/TABLES/12>

- Batty, M. (1997). Cellular Automata and Urban Form: A Primer. *Journal of the American Planning Association*, 63(2), 266–274. <https://doi.org/10.1080/01944369708975918>
- Batty, M., Couclelis, H., y Eichen, M. (1997). Urban systems as cellular automata. *Environment and Planning B: Urban Analytics and City Science*, 24(2), 159–305. https://doi.org/10.1068/B240159/ASSET/B240159.FP.PNG_V03
- Berlekamp, E. R., Conway, J. H., y Guy, R. K. (1982). *Winning Ways for Your Mathematical Plays*. Academic Press.
- Chambers, F., Cruz, C., y Serugendo, G. D. M. (2023). Agent-based modelling of urban expansion and land cover change: a prototype for the analysis of commuting patterns in Geneva, Switzerland. *HAL science ouverte*. <https://hal.science/hal-04146986>
- Charif, O., Omrani, H. y Maria, B. (2012). Cellular automata based on artificial neural network for simulating land use changes. *Simulation Series*, 44. <https://doi.org/10.1016/j.apgeog.2014.06.016>
- Chisanga, C. B., Phiri, D. y Mubanga, K. H. (2024). Multi-decade land cover/land use dynamics and future predictions for Zambia: 2000–2030. *Discover Environment*, 2(1), 1–15. <https://doi.org/10.1007/S44274-024-00066-W>
- Christiansen, P. y Loftsgarden, T. (2011). Drivers behind urban sprawl in Europe. https://www.researchgate.net/publication/265350927_Drivers_behind_urban_sprawl_in_Europe
- Clarke, K. C., Hoppen, S. y 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. <https://doi.org/10.1068/B240247>
- Delipetrev, Blagoj., Tsinaraki, Chrisa., Kostić, U. y European Commission. Joint Research Centre. (2020). Historical Evolution of Artificial Intelligence. 1–36. <https://doi.org/10.2760/8015800>
- Escandón Calderón, J., Ordóñez Díaz, J. A. B., Nieto de Pascual Pola, M. C. del C., Ordóñez Díaz, M. de J., Escandón Calderón, J., Ordóñez Díaz, J. A. B., Nieto de Pascual Pola, M. C. del C., y Ordóñez Díaz, M. de J. (2018). Cambio en la cobertura vegetal y uso del suelo del 2000 al 2009 en Morelos, México. *Revista Mexicana de Ciencias Forestales*, 9(46), 27–53. <https://doi.org/10.29298/RMCF.V9I46.135>
- Falah, N., Karimi, A., y Harandi, A. T. (2020). Urban growth modeling using cellular automata model and AHP (case study: Qazvin city). *Modeling Earth Systems and Environment*, 6(1), 235–248. <https://doi.org/10.1007/S40808-019-00674-Z/FIGURES/8>
- Feng, R. y Wang, K. (2021). Spatiotemporal effects of administrative division adjustment on urban expansion in China. *Land Use Policy*, 101. <https://doi.org/10.1016/J.LANDUSEPOL.2020.1051433>
- Fetene, D. T., Lohani, T. K. y Mohammed, A. K. (2023). LULC change detection using support vector machines and cellular automata-based ANN models in Guna Tana watershed of Abay basin,

- Ethiopia. *Environmental Monitoring and Assessment*, 195(11), 1–17. <https://doi.org/10.1007/S10661-023-11968-2/METRICS>
- Frey, S. (2017). The Craft of Research (4a edition). *Reference Reviews*, 31(8), 1–2.
- Gasirabo, A., Xi, C., Hamad, B. R., y Edovia, U. D. (2023). A CA–Markov-Based Simulation and Prediction of LULC Changes over the Nyabarongo River Basin, *Rwanda. Land*, 12(9). <https://doi.org/10.3390/land12091788>
- Gašparović, M. (2020). Urban growth pattern detection and analysis. Urban Ecology: Emerging Patterns and Social-Ecological. *Systems*, 35–48. <https://doi.org/10.1016/B978-0-12-820730-7.00003-3>
- Ghalehtemouri, K. J., Nasr, T. y Bakhtiari, L. (2022). WITHDRAWN: A scenario-based approach for sustainable urban regeneration analysis in radial-concentric ring cities: A case in Hamedan, Iran. *City and Environment Interactions*. <https://doi.org/10.1016/J.CACINT.2022.100089>
- González-González, A., Clerici, N., y Quesada, B. (2022). A 30 m-resolution land use-land cover product for the Colombian Andes and Amazon using cloud-computing. *International Journal of Applied Earth Observation and Geoinformation*, 107 <https://doi.org/10.1016/J.JAG.2022.102688>
- Hewitt, R., Moya-Gómez, B. y Diaz-Pacheco, J. (2013). A Cellular Automata Land-Use Model For The R Software. *Environment*. <https://doi.org/10.5446/15501>
- Irawan, I. A., Supriatna, S., Manessa, M. y Ristya, Y. (2019). Prediction Model of Land Cover Changes using the Cellular Automata – Markov Chain Affected by the BOCIMI Toll Road in Sukabumi Regency. *KnE Engineering*. <https://doi.org/10.18502/KEG.V4I3.5860>
- Isinkaralar, O. (2024). A Methodological Benchmark in Determining the Urban Growth: Spatiotemporal Projections for Eskişehir, Türkiye. *Applied Spatial Analysis and Policy*, 17(4), 1485–1495. <https://doi.org/10.1007/S12061-024-09592-9/FIGURES/6>
- Jafarpour Ghalehtemouri, K., Shamsoddini, A., Mousavi, M. N., Binti Che Ros, F. y Khedmatzadeh, A. (2022). Predicting spatial and decadal of land use and land cover change using integrated cellular automata Markov chain model based scenarios (2019–2049) Zarriné-Rūd River Basin in Iran. *Environmental Challenges*, 6. <https://doi.org/10.1016/J.ENVC.2021.100399>
- Kang, J., Fang, L., Li, S. y Wang, X. (2019). Parallel Cellular Automata Markov Model for Land Use Change Prediction over MapReduce Framework. ISPRS International. *Journal of Geo-Information*, 8. <https://doi.org/10.3390/IJGI8100454>
- Kayitesi, N. M., Guzha, A. C., Tonini, M., y Mariethoz, G. (2024). Land use land cover change in the African Great Lakes Region: a spatial–temporal analysis and future predictions. *Environmental Monitoring and Assessment*, 196(9), 1–23. <https://doi.org/10.1007/S10661-024-12986-4/TABLES/5>
- Kim, B., Lim, C. G., Lee, S. H., y Jung, Y. J. (2022). A Framework of Large-Scale Virtual City Simulation with Land-Use Model. International Conference on Advanced Communication Technology, ICACT, , 58–61. <https://doi.org/10.23919/ICACT53585.2022.9728864>

- Kulithalai Shiyam Sundar, P., y Deka, P. C. (2022). Spatio-temporal classification and prediction of land use and land cover change for the Vembanad Lake system, Kerala: a machine learning approach. *Environmental Science and Pollution Research*, 29(57), 86220–86236. <https://doi.org/10.1007/S11356-021-17257-0/METRICS>
- Kumar, M., Mahato, L. L., Suryavanshi, S., Singh, S. K., Kundu, A., Dutta, D., y Lal, D. (2024). Future prediction of water balance using the SWAT and CA-Markov model using INMCM5 climate projections: a case study of the Silwani watershed (Jharkhand), India. *Environmental Science and Pollution Research*, 31(41), 54311–54324. <https://doi.org/10.1007/S11356-023-27547-4/METRICS>
- Lahti, J. (2008). Modelling Urban Growth Using Cellular Automata: A case study of Sydney. <https://api.semanticscholar.org/CorpusID:17843132>
- Li, D., Li, X., Liu, X. P., Chen, Y. M., Li, S. Y., Liu, K., Qiao, J. G., Zheng, Y. Z., Zhang, Y. H., y Lao, C. H. (2012). GPU-CA model for large-scale land-use change simulation. *Chinese Science Bulletin*, 57(19), 2442–2452. <https://doi.org/10.1007/S11434-012-5085-3/METRICS>
- Li, G., Sun, S., y 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. <https://doi.org/10.1016/J.LANDURBPLAN.2018.03.004>
- Luo, M., Fa, L., Hao, D., Zhu, Q., Dashti, H., y Chen, M. (2023). Uncertain Spatial Pattern of Future Land Use and Land Cover Change and Its Impacts on Terrestrial Carbon Cycle Over the Arctic–Boreal Region of North America. *Earth's Future*, 11. <https://doi.org/10.1029/2023EF003648>
- Memarian, H., Balasundram, S., Talib, J., Teh, C., Sood, A., y Mikayilov, F. (2012). Validation of CA-Markov for Simulation of Land Use and Cover Change in the Langat Basin, Malaysia. *Journal of Geographic Information System*, 44, 542–554. <https://doi.org/10.4236/jgis.2012.46059>
- Mitsova, D., Shuster, W., y Wang, X. (2011). A cellular automata model of land cover change to integrate urban growth with open space conservation. *Landscape and Urban Planning*, 99(2), 141–153. <https://doi.org/10.1016/J.LANDURBPLAN.2010.10.001>
- Moreira, R. M., Lana, M., Sieber, S., y Malheiros, T. F. (2024). A landscape ecology approach: Modeling forest fragmentation with artificial neural networks and cellular-automata Markov-chain for improved environmental policy in the southwestern Brazilian Amazon. *Land Degradation and Development*, 35(2), 687–704. <https://doi.org/10.1002/LDR.4945>
- Omrani, H., Charif, O., Gerber, P., Bódis, K., Basse, R. M., Omrani, H., Charif, O., Gerber, P., Bódis, K., y Basse, R. M. (2012). Simulation of land use changes using cellular automata and artificial neural network. <https://EconPapers.repec.org/RePEc:irs:cepswp:2012-01>
- Ouma, Y. O., Nkwae, B., Odirile, P., Moalafhi, D. B., Anderson, G., Parida, B., y Qi, J. (2024). Land-Use Change Prediction in Dam Catchment Using Logistic Regression-CA, ANN-CA and Random Forest Regression and Implications for Sustainable Land–Water Nexus. *Sustainability*, 16(4). <https://doi.org/10.3390/SU16041699>

- Pawe, C. K., y Saikia, A. (2024). Simulating urban land use change trajectories in Guwahati city, India. *International Journal of Environmental Science and Technology*, 21(4), 4385–4404. <https://doi.org/10.1007/S13762-023-05305-W/METRICS>
- Pontius, Robert y Millones, Marco. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32, 4407–4429. <https://www.tandfonline.com/doi/full/10.1080/01431161.2011.552923>
- Qiang, Y., y Lam, N. S. N. (2015). Modeling land use and land cover changes in a vulnerable coastal region using artificial neural networks and cellular automata. *Environmental Monitoring and Assessment*, 187(3), 1–16. <https://doi.org/10.1007/S10661-015-4298-8/METRICS>
- Raza, D., Khushi, M., SHU, H., Aslam, H., Saleem, M. S., Ahmad, A., Mirza, S., Saeed, U., y Khan, S. U. (2024). CA-ANN based LULC prediction and influence assessment on LST-NDVI using multi-temporal satellite images. *Environmental Earth Sciences*, 83(5), 1–20. <https://doi.org/10.1007/S12665-024-11467-8/METRICS>
- Rienow, A., y 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. <https://doi.org/10.1016/J.COMPENVURBSYS.2014.05.001>
- Rimal, B., Zhang, L., Keshtkar, H., Haack, B. N., Rijal, S., y Zhang, P. (2018). Land Use/Land Cover Dynamics and Modeling of Urban Land Expansion by the Integration of Cellular Automata and Markov Chain. *ISPRS International Journal of Geo-Information*, 7. <https://doi.org/10.3390/IJGI7040154>
- Rodríguez Eraso, N., Armenteras-Pascual, D., y Alumbrosos, J. R. (2013). Land use and land cover change in the Colombian Andes: dynamics and future scenarios. *Journal of Land Use Science*, 8(2), 154–174. <https://doi.org/10.1080/1747423X.2011.650228>
- Rodríguez, J., Murcia, U. G., Castillo, N., Arias, J., Agudelo, W., Hernández, L., Romero, H., y Chavez, J. (2019). *Análisis de los cambios de coberturas de la tierra en el periodo 2018 al 2020 en la Amazonía colombiana*. Instituto SINCHI. <https://sinchi.org.co/como-se-han-transformado-las-coberturas-de-la-tierra-en-la-amazonia-colombiana-entre-2018-2020>
- Sajan, B., Mishra, V. N., Kanga, S., Meraj, G., Singh, S. K., y Kumar, P. (2022). Cellular Automata-Based Artificial Neural Network Model for Assessing Past, Present, and Future Land Use/Land Cover Dynamics. *Agronomy*, 12. <https://doi.org/10.3390/AGRONOMY12112772>
- Shivappa Masalvad, S., Patil, C., Pravalika, A., Katageri, B., Bekal, P., Patil, P., Hegde, N., Sahoo, U. K., y Sakare, P. K. (2023). Application of geospatial technology for the land use/land cover change assessment and future change predictions using CA Markov chain model. *Environment, Development and Sustainability*, 26(10), 24817–24842. <https://doi.org/10.1007/S10668-023-03657-4/METRICS>
- Silva, E. A. y Clarke, K. C. (2002). Calibration of the SLEUTH urban growth model for Lisbon and Porto, Portugal. *Computers, Environment and Urban Systems*, 26(6), 525–552. [https://doi.org/10.1016/S0198-9715\(01\)00014-X](https://doi.org/10.1016/S0198-9715(01)00014-X)

- Thanekar, G. (2020). *Land Use Land Cover Prediction Analysis*. <https://doi.org/10.13140/RG.2.2.13983.48802>
- Torres, L., Viana, C. M., y Rocha, J. (2023). Hybrid modeling of deforestation impacts from infrastructure projects using cellular automata and multi-agent systems. *Applied Geography*, 151, 102871. <https://doi.org/10.1016/j.apgeog.2023.102871>
- Trunfio, G. A. (2005). Enhancing Cellular Automata by an Embedded Generalized Multi-layer Perceptron. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). https://doi.org/10.1007/11550822_54
- UN Committee of Experts - GGIM. (2017). GGIM | United Nations Committee of Experts on Global Geospatial Information Management. https://ggim.un.org/ggim_20171012/ggim_committee.html
- Veldkamp, A. y Lambin, E. F. (2001). Predicting land-use change. *Ecosystems y Environment*, 85(1–3), 1–6. [https://doi.org/10.1016/S0167-8809\(01\)00199-2](https://doi.org/10.1016/S0167-8809(01)00199-2)
- Wang, S., Liu, Y., Feng, Y., y Lei, Z. (2021). To move or stay? A cellular automata model to predict urban growth in coastal regions amidst rising sea levels. *International Journal of Digital Earth*, 14(9), 1213–1235. <https://doi.org/10.1080/17538947.2021.1946178>
- White, R. y Engelen, G. (1997). Cellular Automata as the Basis of Integrated Dynamic Regional Modelling. *Sage journals*, 24(2), 235–246. <https://doi.org/10.1068/B240235>
- Wu, X., Liu, X., Zhang, D., Zhang, J., He, J. y Xu, X. (2022). Simulating mixed land-use change under multi-label concept by integrating a convolutional neural network and cellular automata: a case study of Huizhou, China. *GIScience y Remote Sensing*, 59(1), 609–632. <https://doi.org/10.1080/15481603.2022.2049493>
- Yang, J., Chen, F., Xi, J., Xie, P. y Li, C. (2014a). A Multitarget Land Use Change Simulation Model Based on Cellular Automata and Its Application. *Abstract and Applied Analysis*. <https://doi.org/10.1155/2014/375389>
- Yang, X., Zheng, X.-Q. y Chen, R. (2014b). A local weights-based cellular automata approach to simulate urban land use changes. *International Journal of Geographical Information Science*, 28(11), 2344–2362. <https://doi.org/10.1080/13658816.2014.922686>
- Yang, J., Su, J., Chen, F., Xie, P. y Ge, Q. (2016). A Local Land Use Competition Cellular Automata Model and Its Application. *ISPRS International Journal of Geo-Information*, 5. <https://doi.org/10.3390/IJGI5070106>
- Yao, Y., Liu, X., Li, X., Liu, P., Hong, Y., Zhang, Y., y Mai, K. (2017). Simulating urban land-use changes at a large scale by integrating dynamic land parcel subdivision and vector-based cellular automata. *International Journal of Geographical Information Science*, 31(12), 2452–2479. <https://doi.org/10.1080/13658816.2017.1360494>

Yesserie, A. G. (2009). Spatio-temporal land use/land cover changes analysis and monitoring in the Valencia Municipality, Spain.

1 Magister en Ciencias de la Información y las Comunicaciones. Universidad Distrital Francisco José de Caldas, Bogotá (Colombia). Investigador Instituto Geográfico Agustín Codazzi (IGAC), sonia.garzon@igac.gov.co, ORCID: <https://orcid.org/0000-0002-0057-2776>, Google Scholar: https://scholar.google.com/citations?hl=es&user=pk_8W04AAAAJ

2 Magister en ingeniería de Sistemas de la Universidad Nacional de Colombia, Bogotá (Colombia). Investigador Instituto Geográfico Agustín Codazzi (IGAC), anibal.montero@igac.gov.co, ORCID: <https://orcid.org/0009-0000-9469-6915>, Google Scholar: <https://scholar.google.es/citations?hl=es&user=PP7CT6IAAAAJ>

3 Magister en Visual Analytics and Big Data. Universidad internacional de la Rioja, La Rioja (España). Investigador Instituto Geográfico Agustín Codazzi (IGAC), victoria.camacho@igac.gov.co, ORCID: <https://orcid.org/0000-0003-4239-8646>, Google Scholar: <https://scholar.google.es/citations?hl=es&user=W4LSmNcAAAAJ>

Para citar este artículo: Garzón Martínez, S. C., Montero Leguizamón, A. y Camacho Ochoa, V. D. (2025). Revisión de literatura sobre técnicas prospectivas del cambio de cobertura y uso del suelo. *Revista Luna Azul*, (60), 66-88. <https://doi.org/10.17151/luaz.2025.60.5>

Esta obra está bajo una [Licencia de Creative Commons Reconocimiento CC BY](https://creativecommons.org/licenses/by/4.0/)



Código QR del artículo

