



Secretaría de
Planeación Distrital



Modelado de Expansión Urbana en Cartagena mediante Autómatas Celulares y Redes Neuronales Artificiales

WORKING
PAPERS
CET

NÚMERO 02

Autores:

Agualimpia Reales Alberto
Gonzalez Agudelo Jose Daniel
Yonoff Jacome Kevin Alexander



MODELADO DE EXPANSIÓN URBANA EN CARTAGENA MEDIANTE AUTÓMATAS CELULARES Y REDES NEURONALES ARTIFICIALES

Agualimpia Reales Alberto *

Gonzalez Agudelo Jose Daniel*

Yonoff Jacome Kevin Alexander *

Resumen

La expansión urbana acelerada en ciudades costeras como Cartagena de Indias genera presiones sobre ecosistemas estratégicos y desafíos para la planificación territorial sostenible. Este estudio desarrolló dos modelos predictivos de cambio de cobertura del suelo integrando Autómatas Celulares (AC) y Redes Neuronales Artificiales (RNA) mediante la herramienta MOLUSCE de QGIS. El Modelo 1, calibrado con coberturas de 2017 y 2021, proyectó la expansión urbana a 2025 alcanzando un índice Kappa de 0.9219 y precisión del 97.46% al validarse con datos reales de 2024. El Modelo 2, basado en coberturas de 2017 y 2024, generó proyecciones hacia 2031 con Kappa de 0.8803. Las variables explicativas incluyeron densidad poblacional, pendiente, distancia a vías principales, zonas de expansión urbana y áreas de conservación ambiental. Durante 2017-2024, la superficie urbanizada creció +11.39 km² (+12.7%), mientras el manglar y la cobertura arbórea disminuyeron -3.51 km² (-10.1%) y -5.70 km² (-4.1%) respectivamente. Se identificó conversión dominante de Cultivos a Urbanizado (65.9%) y cambio de régimen: urbanización acelerada 2017-2021 (+2.39 km²/año) versus desaceleración 2021-2024 (+0.61 km²/año). La proyección a 2031 mostró crecimiento mínimo (+0.37 km²) condicionado por restricciones normativas en áreas protegidas. Los modelos CA-ANN demostraron robustez para capturar dinámicas territoriales complejas, aportando insumos técnicos que fortalecen la planificación urbana sostenible donde convergen presiones de desarrollo y conservación ecosistémica.

Palabras clave: Expansión urbana; Red neuronal artificial; Autómatas celulares; Sistemas de Información Geográfica; Ciudad de Cartagena.

Los conceptos expresados en este documento son de entera responsabilidad de los autores y no comprometen la posición institucional de la Secretaría Distrital de Planeación ni de la Alcaldía Mayor de Cartagena de Indias.

* Asesor externo, Centro de Estudios Territoriales (CET), secretaría de Planeación Distrital, Alcaldía de Cartagena.

* Asesor externo, Centro de Estudios Territoriales (CET), secretaría de Planeación Distrital, Alcaldía de Cartagena.

* Asesor externo, Centro de Estudios Territoriales (CET), secretaría de Planeación Distrital, Alcaldía de Cartagena.



MODELING URBAN EXPANSION IN CARTAGENA USING CELLULAR AUTOMATA AND ARTIFICIAL NEURAL NETWORKS

Agualimpia Reales Alberto *

Gonzalez Agudelo Jose Daniel*

Yonoff Jacome Kevin Alexander *

Abstract

Accelerated urban expansion in coastal cities such as Cartagena de Indias generates pressure on strategic ecosystems and challenges sustainable territorial planning. This study developed two predictive land cover change models integrating Cellular Automata (CA) and Artificial Neural Networks (ANN) using QGIS MOLUSCE tool. Model 1, calibrated with 2017 and 2021 coverages, projected urban expansion to 2025 achieving a Kappa index of 0.9219 and 97.46% accuracy when validated with actual 2024 data. Model 2, based on 2017 and 2024 coverages, generated projections to 2031 with Kappa of 0.8803. Explanatory variables included population density, slope, distance to main roads, urban expansion zones, and environmental conservation areas. During 2017-2024, urbanized area grew +11.39 km² (+12.7%), while mangrove and tree cover decreased -3.51 km² (-10.1%) and -5.70 km² (-4.1%) respectively. Dominant conversion from Cropland to Urban (65.9%) and regime change were identified: accelerated urbanization 2017-2021 (+2.39 km²/year) versus deceleration 2021-2024 (+0.61 km²/year). Projection to 2031 showed minimal growth (+0.37 km²) conditioned by regulatory restrictions on protected areas. CA-ANN models demonstrated robustness for capturing complex territorial dynamics, providing technical inputs that strengthen sustainable urban planning where development pressures and ecosystem conservation converge.

Keywords: Urban expansion; Artificial neural network; Cellular automata; Geographic Information Systems; City of Cartagena.

The concepts expressed in this document are the sole responsibility of the authors and do not compromise the institutional position of the District Planning Secretariat or the Mayor's Office of Cartagena de Indias.

* External advisor, Center for Territorial Studies (CET), District Planning Secretariat, Mayor's Office of Cartagena.

* External advisor, Center for Territorial Studies (CET), District Planning Secretariat, Mayor's Office of Cartagena.

* External advisor, Center for Territorial Studies (CET), District Planning Secretariat, Mayor's Office of Cartagena.



1. INTRODUCCIÓN

La expansión urbana constituye uno de los fenómenos territoriales más relevantes del siglo XXI. De acuerdo con Principi (2022), para el año 2030 cerca del 60 % de la población mundial residirá en áreas urbanas, concentrándose la mayor parte de este crecimiento en países en desarrollo. Este proceso genera profundas transformaciones espaciales que, sin una adecuada planificación, pueden derivar en fragmentación de ecosistemas, sobrecarga de infraestructuras y deterioro de la calidad de vida urbana (Aguilera Benavente, 2006).

En el contexto latinoamericano, Colombia presenta un alto nivel de urbanización, con aproximadamente el 75 % de su población viviendo en cabeceras municipales hacia 2018, según la “National Urban Policy Review of Colombia” de la Organización para la Cooperación y el Desarrollo Económicos (OECD, 2022). Este valor refleja una transformación estructural del territorio: mientras en 1950 menos del 40 % de la población residía en áreas urbanas, en la actualidad el país supera el promedio regional y consolida un patrón de urbanización sostenido, tendencia que representa una inversión completa del esquema histórico, en el que predominaban los asentamientos rurales (Padilla et al., 2015). El fenómeno se intensifica particularmente en ciudades intermedias y áreas metropolitanas, donde Salazar Tamayo & Julio Estrada (2022) documentan que la mayoría de las ciudades colombianas duplicaron su extensión urbana en los últimos 10 años, resultando en alta demanda de suelo y capacidades limitadas de autoridades locales para gestión territorial sostenible.

Cartagena de Indias, situada en la región Caribe de Colombia, constituye un caso representativo de los desafíos territoriales que enfrentan las ciudades costeras del país. Su localización estratégica, el crecimiento poblacional y la expansión de la infraestructura urbana han incrementado la presión sobre ecosistemas sensibles como manglares, cuerpos de agua y zonas de recarga hídrica (Salazar Tamayo & Julio Estrada, 2022). Diversos estudios advierten que la interacción entre procesos de urbanización, cambio climático y transformaciones geomorfológicas ha configurado escenarios de vulnerabilidad ambiental que demandan enfoques integrados de planificación y gestión del territorio (Alshari & Gawali, 2022; Nguyen et al., 2021; Padilla et al., 2015; Thammaboribal & Tripathi, 2024). Ante este contexto, se requiere fortalecer las herramientas de análisis espacial que permitan anticipar posibles trayectorias de expansión y evaluar su compatibilidad con la sostenibilidad ambiental y la resiliencia urbana. En este marco, la modelación de cambio de uso del suelo surge como un instrumento técnico-científico clave para orientar la toma de decisiones y apoyar la formulación de estrategias de ordenamiento que equilibren las necesidades de desarrollo con la conservación de los ecosistemas costeros (Principi, 2022).

El modelado de expansión urbana mediante autómatas celulares (AC) integrados con redes neuronales artificiales (RNA) se ha consolidado como una metodología robusta para la simulación de dinámicas territoriales complejas (Kamaraj & Rangarajan, 2021). Los AC permiten representar sistemas dinámicos en los que cada celda del espacio evoluciona de acuerdo con reglas de transición dependientes del estado de sus vecinas, reproduciendo patrones espaciales característicos del crecimiento urbano (Asia Air Survey & Next GIS, 2014; Fontana et al., 2023). Las RNA, por su parte, posibilitan identificar relaciones no lineales entre variables explicativas, como la pendiente del terreno, la distancia a vías



principales o la densidad de población, fortaleciendo la capacidad predictiva del modelo (Padilla et al., 2015). La herramienta MOLUSCE (Modules for Land Use Change Evaluation), implementada como complemento en QGIS, integra ambos enfoques en un entorno automatizado que facilita el análisis y la proyección de escenarios de cambio de uso del suelo (Asia Air Survey & Next GIS, 2014; Fontana et al., 2023). Estudios recientes han validado su efectividad en diversos contextos urbanos y ambientales, evidenciando una alta precisión en la predicción de la expansión urbana.

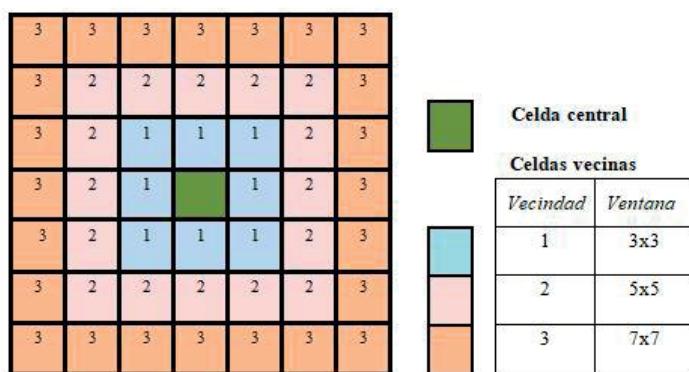
El presente trabajo desarrolla un modelo predictivo de cambio de cobertura de suelo para Cartagena de Indias mediante la integración de autómatas celulares y redes neuronales artificiales implementadas en la herramienta MOLUSCE. El modelo se calibra inicialmente con información de cobertura de suelo correspondiente a los años 2017 y 2021, y se valida mediante la comparación entre las predicciones generadas para 2024 y los datos observados en 2024. Posteriormente, se formula un segundo modelo calibrado con las capas actualizadas de 2017 y 2024, con el propósito de proyectar escenarios alternativos de transformación territorial hacia el año 2031. Las variables explicativas empleadas incluyen la pendiente del terreno, la distancia a vías principales, la distancia a zonas de expansión urbana, la densidad poblacional y las áreas sujetas a restricciones ambientales. Los resultados obtenidos constituyen una base técnica para la interpretación de las dinámicas espaciales de la ciudad y proporcionan insumos útiles para fortalecer los procesos de planificación territorial y gestión del suelo urbano en contextos costeros.

2. MARCO TEÓRICO Y METODOLÓGICO

El análisis y predicción de las transformaciones en la cobertura del suelo constituye un desafío metodológico que ha impulsado el desarrollo de múltiples enfoques técnicos (Mas et al., 2014; Sarkar & Mondal, 2020). Las técnicas de teledetección permiten documentar los cambios territoriales mediante la clasificación de imágenes satelitales (Blissag et al., 2024), mientras que los modelos estadísticos (como la regresión logística) facilitan la identificación de relaciones funcionales entre variables explicativas y probabilidades de cambio, no obstante, su carácter lineal limita la representación de la complejidad espacial (Asia Air Survey & Next GIS, 2014). En este contexto, la modelación basada en autómatas celulares (AC) y redes neuronales artificiales (RNA) ha surgido como una alternativa robusta, al combinar la representación de dinámicas locales con la capacidad de aprendizaje automático de patrones no lineales (Alshari & Gawali, 2022; Fontana et al., 2023; Principi, 2022)

Los autómatas celulares, desarrollados inicialmente por Von Neumann y Ulam en la década de 1940, constituyen sistemas dinámicos formados por celdas organizadas en una malla discreta, donde el estado de cada celda depende del de sus vecinas y de un conjunto de reglas de transición (Fontana et al., 2023; Principi, 2022). Entre los elementos básicos del modelo se incluyen la teselación espacial, el conjunto de estados posibles, la definición de vecindad, las reglas de evolución y el reloj de cómputo (Iskandar et al., 2024). La vecindad de Moore, una de las configuraciones más comunes, considera todas las celdas que rodean a la central, pudiendo ajustarse en distintos órdenes para definir el alcance de la influencia espacial (Padilla et al., 2015).

Figura 1: Vecindad de Moore con diferentes proximidades.

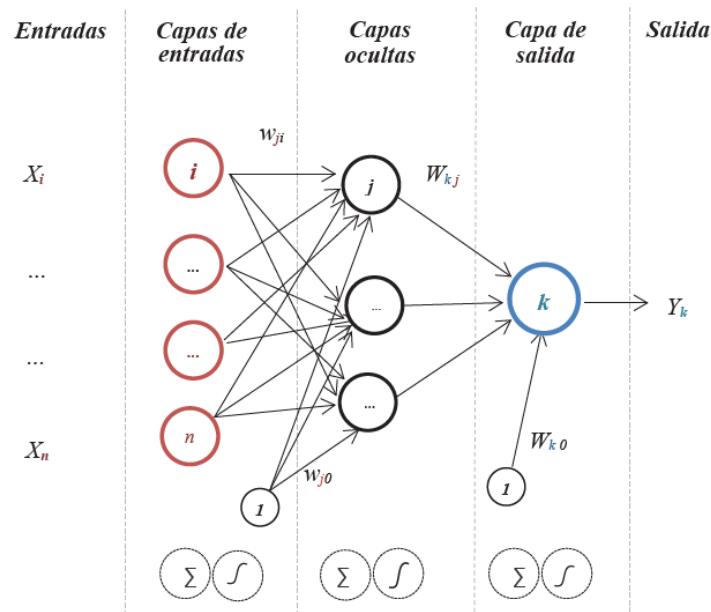


Fuente: Tomado de Principi (2022).

Los AC resultan especialmente apropiados para modelar la expansión urbana, ya que reproducen la naturaleza descentralizada del crecimiento de las ciudades mediante un enfoque de abajo hacia arriba. Su estructura espacial, dinámica y adaptable permite representar procesos de urbanización con gran eficiencia computacional y elevada capacidad de interpretación (Alshari & Gawali, 2022; Nguyen et al., 2021). Las redes neuronales artificiales, concebidas también a mediados del siglo XX, imitan el funcionamiento del sistema neuronal biológico para identificar patrones complejos en los

datos (Fontana et al., 2023). El perceptrón multicapa es la arquitectura más utilizada en modelación espacial: recibe las variables de entrada, las procesa en capas ocultas mediante funciones de activación y genera una capa de salida que produce la predicción (Fontana et al., 2023; Principi, 2022).

Figura 2: Representación de un perceptrón multicapa.



Fuente: Tomado de Principi (2022).

Durante el entrenamiento, los pesos de conexión se ajustan iterativamente mediante algoritmos de retropropagación que minimizan el error entre valores observados y predichos (Asia Air Survey & Next GIS, 2014). Este proceso permite a la red capturar relaciones no lineales entre factores biofísicos y socioeconómicos, fundamentales para estimar la probabilidad de cambio entre categorías de uso del suelo (Asia Air Survey & Next GIS, 2014).

La integración CA-ANN combina la capacidad de los AC para representar la dependencia espacial con la habilidad de las RNA para identificar relaciones complejas entre variables territoriales. Mientras las redes determinan la aptitud de transformación de cada celda, los autómatas simulan la propagación espacial del cambio (Alshari & Gawali, 2022; kamaraj & Rangarajan, 2021). Este enfoque supera las limitaciones de modelos puramente estadísticos o estocásticos al incorporar la estructura espacial local y el aprendizaje no lineal (Principi, 2022). El proceso de modelación CA-ANN comprende cinco fases: (1) preparación de datos y normalización de variables explicativas; (2) análisis de cambio mediante matrices de transición entre dos fechas base; (3) entrenamiento de la red neuronal para estimar las probabilidades de cambio; (4) simulación con autómatas celulares, aplicando las reglas de transición espaciales; y (5) validación estadística mediante índices Kappa que evalúan la concordancia global, espacial y cuantitativa entre mapas simulados y observados (Flores-Juca & Carrera, 2022; Fontana et al., 2023).



La herramienta MOLUSCE (Modules for Land Use Change Evaluation) automatiza estas fases dentro de QGIS, integrando los métodos de redes neuronales, regresión logística, pesos de evidencia y evaluación multicriterio (Asia Air Survey & Next GIS, 2014). Su carácter de software libre, la facilidad de integración con datos geográficos y su validación en estudios internacionales respaldan su elección para el presente trabajo (Nguyen et al., 2021; Thammaboribal & Tripathi, 2024). Los modelos CA-ANN han demostrado su versatilidad en contextos urbanos y ambientales diverso: Principi (2022) simuló la expansión de Luján, Argentina; Thammaboribal & Tripathi (2024) aplicaron el modelo en Pathumthani, Tailandia; y Alshari & Gawali (2022) en Saná, Yemen, alcanzando precisiones superiores al 80 %. De igual forma, Nguyen et al. (2021) emplearon esta metodología para analizar riesgos de inundación asociados a cambios de cobertura en Vietnam. Esta diversidad de aplicaciones confirma la robustez del enfoque y su pertinencia para analizar los procesos de cambio de cobertura en Cartagena de Indias, una ciudad costera donde confluyen presiones de urbanización, conservación de ecosistemas y adaptación al cambio climático.



3. HERRAMIENTA MOLUSCE EN QGIS

La herramienta MOLUSCE, acrónimo de *Modules for Land Use Change Evaluation*, fue específicamente diseñada para analizar, evaluar, modelizar y simular cambios y escenarios futuros de uso del suelo, implementada como complemento en el Sistema de Información Geográfica de código abierto QGIS (Asia Air Survey & Next GIS, 2014). Esta herramienta automatiza el flujo completo de trabajo del enfoque CA-ANN mediante una interfaz integrada que organiza el proceso de modelación en módulos secuenciales: preparación de datos de entrada, evaluación de correlaciones entre variables, análisis de cambios de área, modelación del potencial de transición, simulación mediante autómatas celulares y validación estadística (Asia Air Survey & Next GIS, 2014). Su carácter de software libre garantiza accesibilidad y replicabilidad metodológica, mientras que su integración nativa con QGIS permite la gestión eficiente de información geoespacial en formato ráster.

MOLUSCE ofrece cuatro métodos de modelación del potencial de transición: redes neuronales artificiales (ANN), regresión logística (LR), pesos de evidencia (WoE) y evaluación multicriterio (MCE), siendo las tres primeras técnicas de aprendizaje automático que identifican patrones ocultos en las muestras de entrenamiento, mientras que MCE permite al usuario incorporar conocimiento experto sobre la importancia relativa de los factores territoriales (Asia Air Survey & Next GIS, 2014). El flujo de trabajo en MOLUSCE inicia con la normalización de las variables explicativas, procedimiento fundamental para lograr un entrenamiento eficiente de la red neuronal y resultados de predicción precisos. La estandarización se realiza mediante el cálculo del puntaje Z, expresado como la ecuación 1:

$$Z = \frac{(X - \bar{X})}{\sigma} \quad (1)$$

donde Z representa la variable normalizada, X la variable considerada, \bar{X} la media y σ la desviación estándar (Principi, 2022). Este proceso transforma todas las variables a una escala comparable (típicamente entre 0 y 1), eliminando el efecto de diferencias en unidades de medida, rangos de variación y dispersión entre factores, permitiendo que el modelo pondere adecuadamente la influencia de cada variable independientemente de su escala original (Jain, 2024). Seguidamente, la herramienta facilita la evaluación de correlaciones entre variables espaciales mediante métodos como el coeficiente de Pearson, identificando el grado de similitud y la fuerza de la relación entre factores, lo que permite detectar redundancias y ajustar el conjunto de variables explicativas para optimizar el modelo (Flores-Juca & Carrera, 2022).

El módulo de análisis de cambios calcula la superficie y localización de las transformaciones ocurridas entre dos momentos temporales, denominados tiempo inicial (T1) y tiempo final (T2) (Fontana et al., 2023; kamaraj & Rangarajan, 2021). MOLUSCE genera automáticamente estadísticas básicas que cuantifican la superficie ocupada por cada categoría de uso del suelo en ambas fechas, así como los cambios absolutos y porcentuales experimentados (Asia Air Survey & Next GIS, 2014). Paralelamente, construye una matriz de transición que expresa las probabilidades de cambio entre categorías mediante valores entre 0 y 1, calculada mediante multiplicación de matrices que sintetiza las relaciones de cambio existentes en el período analizado (Fontana et al., 2023; Principi, 2022). Esta matriz constituye un componente esencial del modelo, ya que las tendencias históricas de cambio identificadas en el período T1-T2 determinan las proyecciones futuras que el autómata



celular ejecutará manteniendo el mismo rango temporal (Muhammad et al., 2022). Por ejemplo, si T1 corresponde al año 2010 y T2 al 2020, la simulación proyectará cambios hacia 2030 asumiendo continuidad en las dinámicas observadas durante la década previa. Adicionalmente, el módulo genera un mapa de cambios que espacializa las transiciones mediante una capa ráster donde cada clase de transición se identifica con un color específico, permitiendo visualizar los patrones geográficos de transformación territorial (Principi, 2022; Fontana et al., 2023).

La modelación del potencial de transición mediante redes neuronales artificiales constituye el núcleo metodológico de MOLUSCE. El algoritmo implementa un perceptrón multicapa totalmente conectado que utiliza retropropagación clásica con capacidad autónoma para analizar la precisión alcanzada durante el entrenamiento y realizar su propia validación, almacenando la mejor configuración de pesos en memoria (Lukas et al., 2023). El proceso de aprendizaje emplea un esquema estocástico en línea donde se selecciona aleatoriamente una muestra del conjunto de entrenamiento y los pesos de la red se actualizan iterativamente según la ecuación 2:

$$w(n + 1) = r * dw(n) + m * dw(n - 1) \quad (2)$$

donde w representa el vector de pesos de neuronas, dw el vector de cambios de pesos, n el número de iteración, r la tasa de aprendizaje y m el momento (Asia Air Survey & Next GIS, 2014). El usuario define parámetros críticos del entrenamiento, incluyendo el número de muestras (típicamente entre 1,000 y 10,000), el modo de muestreo (aleatorio estratificado), el tamaño de la vecindad para considerar efectos espaciales locales, la tasa de aprendizaje y el momento (valores pequeños como 0.001-0.005 garantizan estabilidad, aunque requieren mayor tiempo de procesamiento), el número de capas ocultas (generalmente entre 5 y 10) y el número máximo de iteraciones (Asia Air Survey & Next GIS, 2014). El error de ajuste se mide mediante el error cuadrático medio de las salidas de la red, y el entrenamiento finaliza cuando se alcanza la mejor precisión de validación, momento en que la herramienta proporciona gráficos de evolución del error, el error mínimo global y la precisión delta (Principi, 2022).

Una vez entrenada la red neuronal, MOLUSCE aplica el módulo de simulación mediante autómatas celulares, que utiliza el algoritmo probabilístico de Monte Carlo para generar mapas de potencial de transición. Estos mapas expresan, mediante valores entre 0 (bajo potencial) y 100 (alto potencial), la probabilidad de que cada celda cambie de una categoría de cobertura a otra (Asia Air Survey & Next GIS, 2014). El simulador opera mediante un esquema iterativo: primero toma las probabilidades de transición de la matriz y calcula el número de píxeles que deben cambiar para cada clase de transición; posteriormente el modelo escanea las celdas vecinas (según la configuración de vecindad definida) y calcula los potenciales de transición considerando tanto las probabilidades globales como las influencias espaciales locales; el simulador construye entonces un ráster de certeza que mide la confianza del modelo como la diferencia entre los dos potenciales de transición más altos de cada píxel; finalmente, para cada clase de transición, el algoritmo identifica las celdas con mayor confianza y ejecuta los cambios de categoría correspondientes (Asia Air Survey & Next GIS, 2014). Cada iteración del modelo representa un año de evolución del sistema, y al finalizar todas las iteraciones programadas, MOLUSCE genera el mapa simulado de cobertura futura (Fontana et al., 2023; Lukas et al., 2023). Si se especifican múltiples iteraciones, el esquema se repite utilizando el resultado de cada iteración como estado inicial para la siguiente, propagando así los cambios a través del tiempo de forma acumulativa. El módulo final de validación permite verificar la precisión de la simulación



mediante tres tipos de estadísticas Kappa que evalúan diferentes aspectos de la concordancia entre el mapa simulado y el mapa de validación observado (Lukas et al., 2023). El índice Kappa general mide la correspondencia global entre ambos mapas y se calcula como lo indica la ecuación 3:

$$k = \frac{[P(A) - P(E)]}{[1 - P(E)]} \quad (3)$$

donde $P(A)$ representa la proporción de acuerdo observado y $P(E)$ la proporción de acuerdo esperado por azar (Asia Air Survey & Next GIS, 2014). El índice Kappa localización evalúa específicamente la similitud en la asignación espacial de las categorías mediante la ecuación 4:

$$k_{lo} = \frac{[P(A) - P(E)]}{[P_{max} - P(E)]} \quad (4)$$

donde P_{max} representa el máximo acuerdo posible (Asia Air Survey & Next GIS, 2014). Finalmente, el Kappa histograma mide la similitud cuantitativa entre los mapas calculándose directamente desde sus histogramas como lo muestra la ecuación 5:

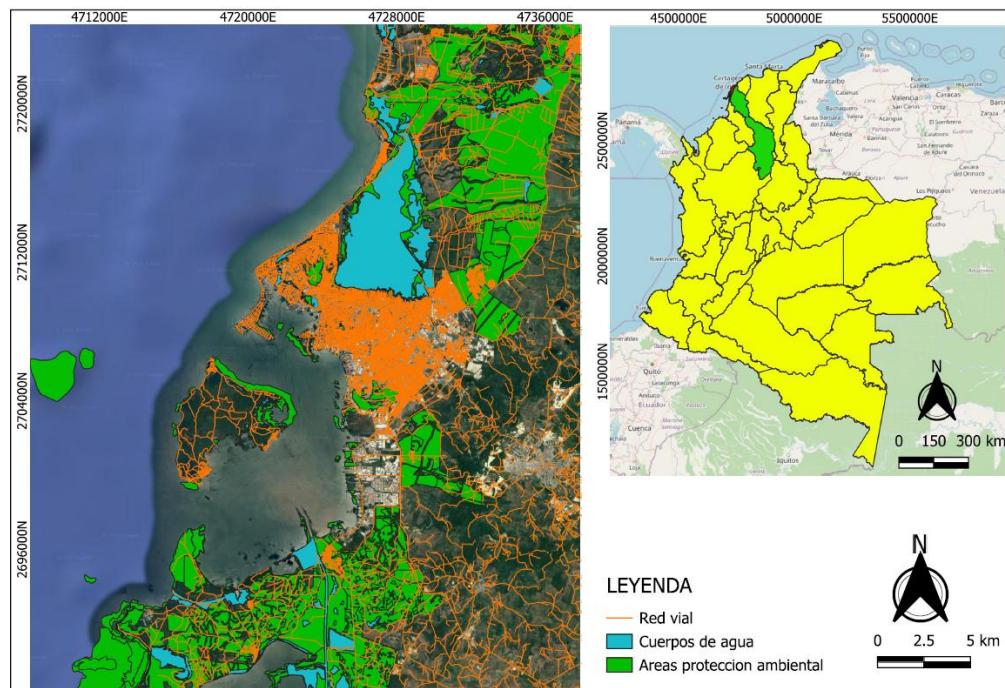
$$k_h = \frac{[P_{max} - P(E)]}{[1 - P(E)]} \quad (5)$$

Según la escala de Principi (2022), valores de Kappa inferiores a 0.00 indican desacuerdo, entre 0.00-0.20 acuerdo leve, 0.21-0.40 aceptable, 0.41-0.60 moderado, 0.61-0.80 considerable y 0.81-1.00 excelente. MOLUSCE genera automáticamente estas tres métricas junto con matrices de confusión y estadísticas complementarias que permiten evaluar integralmente el desempeño del modelo, identificando fortalezas y debilidades en la representación tanto cuantitativa como espacial de los cambios simulados (Lukas et al., 2023).

4. CASO DE ESTUDIO: CARTAGENA DE INDIAS

Cartagena de Indias se localiza en la costa norte de Colombia, en el departamento de Bolívar, región Caribe colombiana. La ciudad constituye uno de los once distritos especiales del país, clasificada como Distrito Turístico, Histórico y Cultural (OECD, 2022). Su localización estratégica sobre el Mar Caribe y su rol como puerto marítimo le confieren características territoriales particulares que históricamente han determinado su desarrollo urbano (ver figura 3).

Figura 3: Mapa de ubicación de Cartagena de Indias.



Fuente: Elaboración de los autores.

Según datos reportados por la OECD (2022), Cartagena contaba con aproximadamente 1.0 millón de habitantes en sus núcleos urbanos municipales (cabeceras municipales), consolidándose como la quinta ciudad más poblada de Colombia junto con Bogotá (7.4 millones), Medellín (2.4 millones), Cali (2.2 millones) y Barranquilla (1.2 millones). La ciudad forma parte del sistema urbano policéntrico colombiano, donde casi el 40% de la población urbana del país (13.2 millones de personas) se concentra en estos cinco municipios principales. El crecimiento poblacional registrado en estas cinco ciudades desde 2005 ha sido del 11.5%, ligeramente inferior al crecimiento urbano nacional que alcanzó el 15.7% en el mismo período (OECD, 2022). El proceso de urbanización en Cartagena, como en otras ciudades colombianas, se ha manifestado tanto a través de densificación como de expansión urbana. Entre 1990 y 2015, las ciudades colombianas experimentaron un fenómeno de dispersión urbana (urban sprawl) evidenciado porque la huella urbana creció en promedio 2.50% anualmente mientras la población aumentó 2.28% (Salazar Tamayo & Julio Estrada, 2022).



Este patrón de crecimiento físico superando el demográfico indica una ocupación territorial menos eficiente con implicaciones para la provisión de servicios e infraestructuras urbanas. El mapa de ubicación (Figura 3) ilustra la configuración territorial actual de Cartagena, donde se identifican tres componentes espaciales críticos para el presente estudio. La red vial principal, representada mediante líneas rojas, articula el territorio y constituye una variable explicativa fundamental para el modelo CA-ANN, dado que la proximidad a vías determina la accesibilidad y por tanto la aptitud para expansión urbana. Los cuerpos de agua, identificados en color cian, incluyen sistemas lagunares interiores (Ciénaga de la Virgen, Ciénaga de Tesca) y el Mar Caribe, que funcionan como límites naturales al crecimiento urbano y reguladores hídricos del territorio. Las áreas de protección ambiental, delimitadas en verde, concentran ecosistemas de manglar que proveen servicios ecosistémicos estratégicos y están sujetas a normativas de restricción de uso.

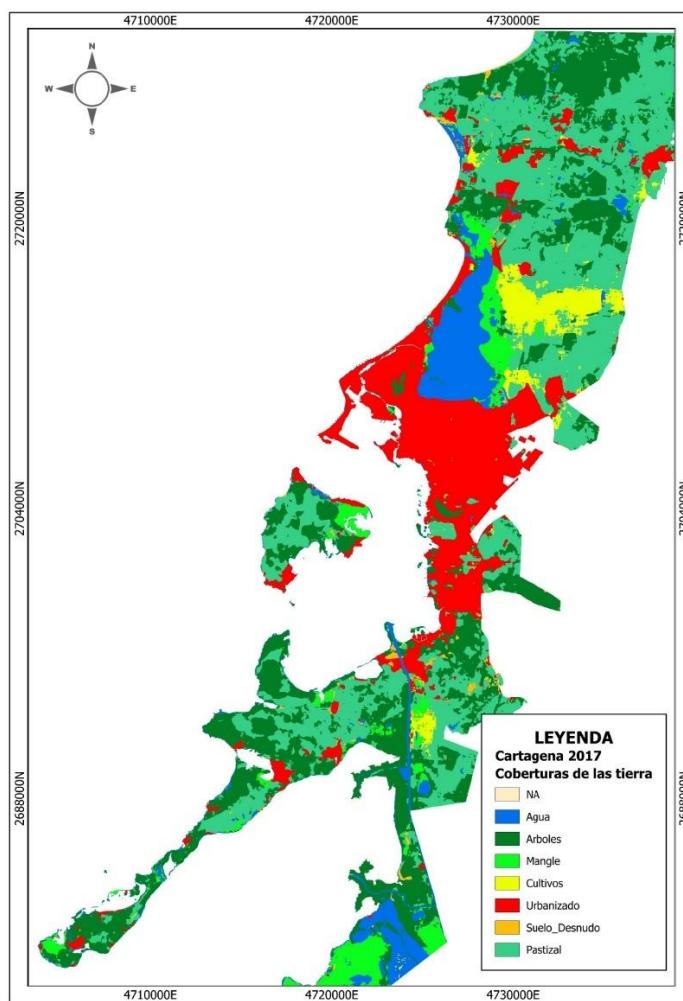
Diversos estudios documentan que la interacción entre procesos de urbanización, presión sobre ecosistemas costeros y vulnerabilidad ante eventos climáticos configura escenarios de riesgo que demandan enfoques integrados de planificación territorial (Lukas et al., 2023; OECD, 2022). En este contexto, Salazar Tamayo & Julio Estrada (2022) advierten que la mayoría de las ciudades colombianas duplicaron su extensión urbana en los últimos 10 años, resultando en alta demanda de suelo y capacidades limitadas de autoridades locales para gestión territorial sostenible. Esta dinámica acelerada de expansión, en ausencia de mecanismos efectivos de control urbanístico, genera ocupación de áreas con restricciones ambientales y aumento de vulnerabilidad socioambiental.

5. METODOLOGÍA APLICADA

5.1 Datos de entrada

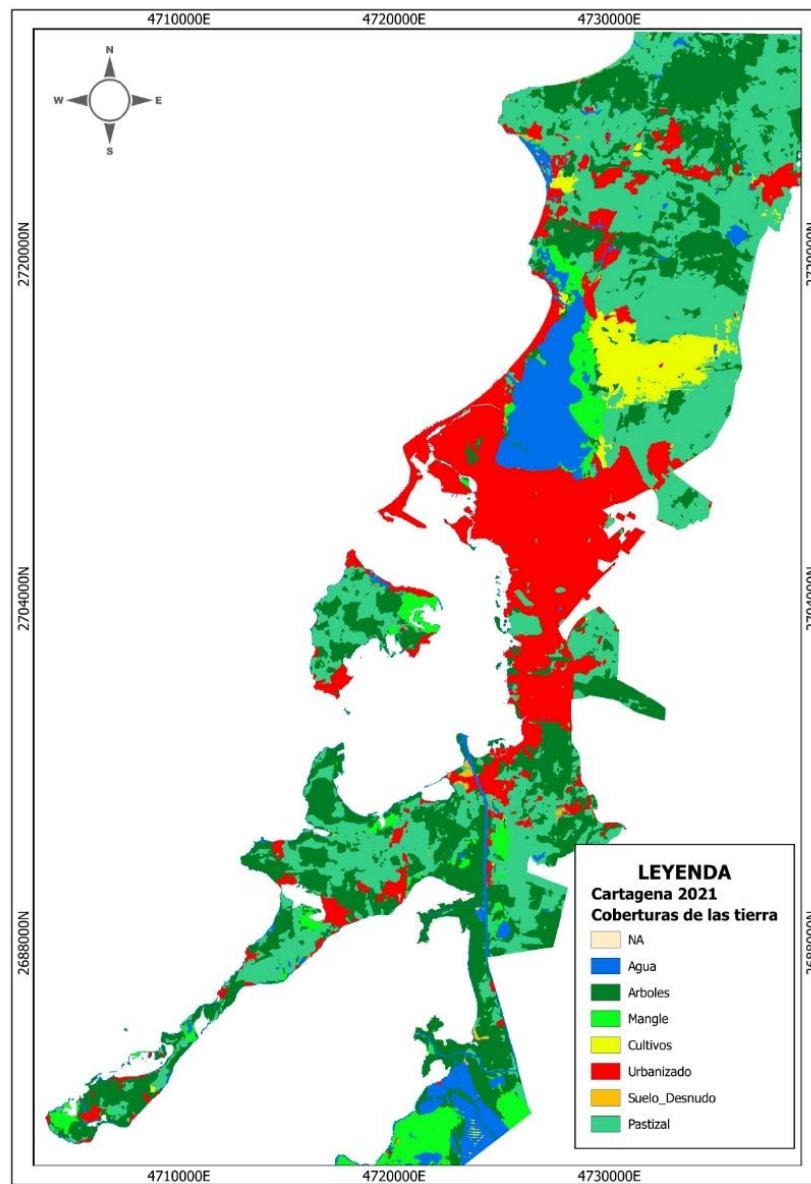
El modelo CA-ANN requiere como insumos fundamentales capas ráster de cobertura de suelo en dos momentos temporales y un conjunto de variables espaciales que actúan como factores explicativos del cambio. Para el presente estudio se implementaron dos modelos con estrategias temporales diferenciadas: el Modelo 1 utilizó capas de cobertura correspondientes a 2017 (tiempo inicial, T1) y 2021 (tiempo final, T2), mientras que el Modelo 2 empleó capas de 2017 y 2024 (ver figuras 4, 5 y 6).

Figura 4: Mapa de cobertura de tierras de Cartagena de Indias (2017).



Fuente: Elaboración de los autores.

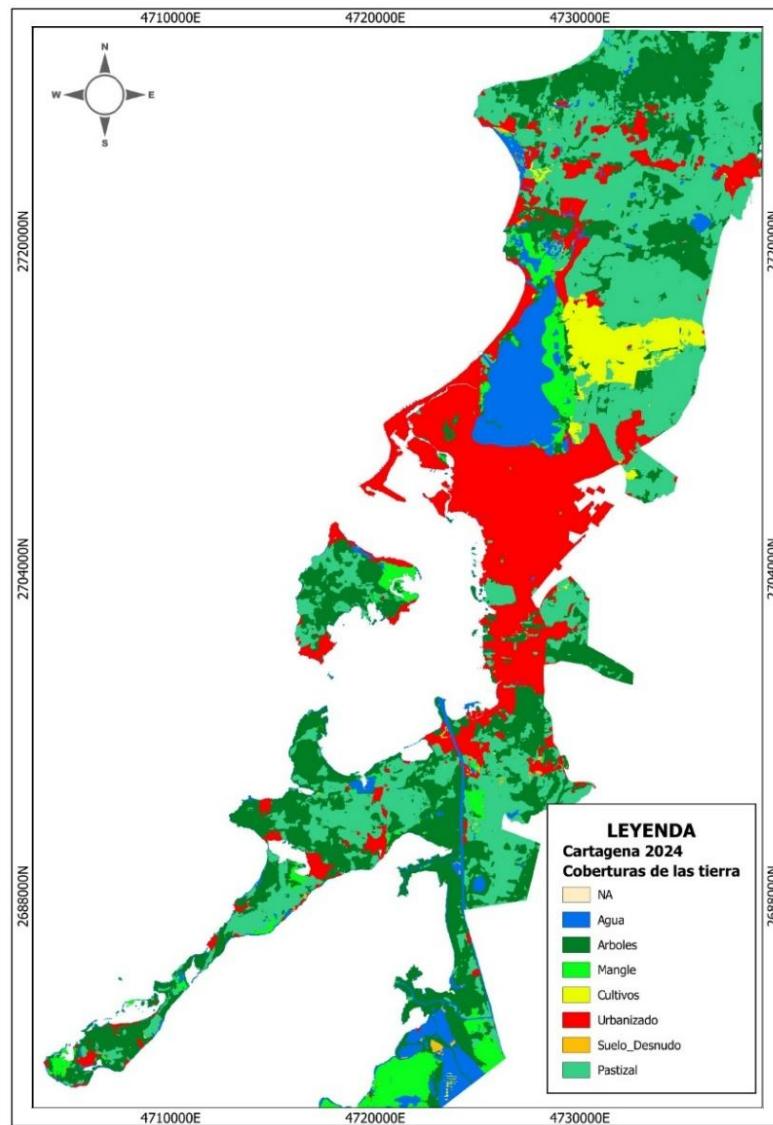
Figura 5: Mapa de cobertura de tierras de Cartagena de Indias (2021).



Fuente: Elaboración de los autores.

Ambos modelos trabajaron con la misma clasificación temática de ocho categorías: N/A, Agua, Árboles, Manglar, Cultivos, Urbanizado, Suelo Desnudo y Pastizal. Las variables espaciales seleccionadas como factores de cambio fueron cinco: densidad poblacional, pendiente del terreno, distancia euclíadiana a vías principales, distancia euclíadiana a zonas de expansión urbana, y áreas de conservación ambiental. Previo a su incorporación al modelo, todas las capas ráster se procesaron para garantizar homogeneidad geométrica, es decir, que cada variable contara con el mismo número de filas, columnas y píxeles, así como idéntica extensión espacial y sistema de coordenadas (EPSG:9377 - MAGNA-SIRGAS 2018 / Origen-Nacional).

Figura 6: Mapa de cobertura de tierras de Cartagena de Indias (2024).



Fuente: Elaboración de los autores.

5.2 Correlación entre variables

Una vez preparados los datos de entrada, se evaluó la correlación entre las variables espaciales mediante el coeficiente de Pearson disponible en el módulo "Evaluating correlation" de MOLUSCE. Este análisis determina el grado de similitud y la fuerza de la relación entre pares de variables, identificando potenciales redundancias que podrían introducir sesgo en el entrenamiento de la red neuronal (Flores-Juca & Carrera, 2022). La matriz de correlación generada presenta valores entre -1 y 1, donde valores cercanos a 1 indican correlación positiva fuerte, cercanos a -1 correlación negativa fuerte, y próximos a 0 ausencia de correlación lineal. Los resultados del análisis de correlación para el área de estudio de Cartagena revelaron las siguientes relaciones entre variables (Tabla 1):

Tabla 1. Matriz de correlación de Pearson entre variables espaciales explicativas.

Variable	Densidad Poblacional	Distancia Vías	Distancia Zonas Expansión	Pendiente	Áreas Conservación
Densidad Poblacional	--	-0.381	0.171	-0.074	-0.190
Distancia Vías	-0.381	--	-0.088	-0.240	-0.259
Distancia Zonas Expansión	0.171	-0.088	--	-0.005	0.122
Pendiente	-0.074	-0.240	-0.005	--	0.351
Áreas Conservación	-0.190	-0.259	0.122	0.351	--

Fuente: Elaboración de los autores.

Nota: Los valores en la diagonal (--) representan la autocorrelación perfecta de cada variable consigo misma.

El análisis evidencia que ningún par de variables presenta correlación fuerte ($r > 0.8$), lo que descarta problemas severos de multicolinealidad (Principi, 2022). La correlación más significativa se observa entre densidad poblacional y distancia a vías ($r = -0.381$), indicando que las áreas más densamente pobladas tienden a ubicarse más cerca de la infraestructura vial principal, patrón esperable en contextos urbanos donde la accesibilidad es un factor determinante de concentración poblacional. La correlación positiva moderada entre pendiente y áreas de conservación ($r = 0.351$) sugiere que las zonas protegidas tienden a localizarse en terrenos con mayor inclinación, posiblemente debido a que estas áreas presentan mayores restricciones para el desarrollo urbano. Las correlaciones negativas débiles entre distancia a vías y otras variables (-0.240 con pendiente, -0.259 con áreas de conservación) indican que la red vial tiende a evitar tanto zonas de topografía accidentada como áreas bajo protección ambiental. Dado que todas las correlaciones presentan valores moderados a bajos, se conservaron las cinco variables en el modelo, considerando que cada una aporta información diferenciada sobre los factores que influyen en el cambio de cobertura del suelo.

5.3 Cambios de área

El módulo "Area Changes" de MOLUSCE calcula las estadísticas de transformación entre las coberturas del tiempo inicial (T1) y el tiempo final (T2), cuantificando la superficie y localización de los procesos de cambio. La herramienta genera automáticamente dos productos analíticos: una tabla de estadísticas básicas que presenta la superficie ocupada por cada clase en T1 y T2, los cambios absolutos en kilómetros cuadrados y los cambios porcentuales (ver Tabla 2); y una matriz de transición que expresa las probabilidades de cambio entre categorías mediante valores entre 0 y 1 (Principi, 2022) (ver Tabla 3 y 4).

Tabla 2. Estadísticas básicas de cambios de cobertura para ambos modelos.

Clase	2017 (km ²)	2021 (km ²)	Δ 2017-2021 (km ²)	2024 (km ²)	Δ 2017-2024 (km ²)
NA	2239.34	2239.34	0.00	2239.34	0.00
Agua	43.08	42.29	-0.79	43.52	+0.44
Árboles	140.02	136.97	-3.05	134.32	-5.70
Manglar	34.75	32.23	-2.52	31.24	-3.51
Cultivos	18.90	17.99	-0.91	17.41	-1.49
Urbanizado	89.41	98.98	+9.56	100.80	+11.39
Suelo Desnudo	3.37	1.43	-1.94	1.17	-2.20
Pastizal	175.20	174.85	-0.35	176.27	+1.07

Fuente: Elaboración propia a partir de resultados de MOLUSCE en QGIS.

Tabla 3. Matriz de transición para modelo 1: Período 2017-2021.

Clase	NA	Agua	Árboles	Manglar	Cultivos	Urbanizado	Suelo Desnudo	Pastizal
NA	1.000	0.0	0.0	0.0	0.0	0.0	0.0	0.0
Agua	0.0	0.908	0.022	0.022	0.006	0.015	0.010	0.018
Árboles	0.0	0.010	0.748	0.009	0.001	0.027	0.000	0.205
Manglar	0.0	0.042	0.093	0.791	0.008	0.009	0.000	0.056
Cultivos	0.0	0.004	0.031	0.025	0.648	0.039	0.000	0.253
Urbanizado	0.0	0.003	0.010	0.000	0.000	0.969	0.001	0.017
Suelo Desnudo	0.0	0.118	0.046	0.063	0.014	0.313	0.138	0.307
Pastizal	0.0	0.005	0.135	0.003	0.025	0.044	0.001	0.785

Fuente: Elaboración propia a partir de resultados de MOLUSCE en QGIS. Los valores representan probabilidades de transición (valores entre 0 y 1). Los valores en la diagonal representan estabilidad de cada clase.

La identificación de estas tendencias resulta fundamental porque constituye la base sobre la que se realiza la proyección futura, que asume continuidad en las dinámicas observadas considerando el mismo rango temporal (Principi, 2022). Adicionalmente, MOLUSCE genera un mapa de cambios que espacializa las transiciones mediante una capa ráster donde cada clase de transición se identifica con un código único, permitiendo visualizar los patrones geográficos de transformación territorial y detectar sectores con mayor intensidad de cambio.

Tabla 4. Matriz de transición para modelo 2: Período 2017-2024.

Clase	NA	Agua	Árboles	Manglar	Cultivos	Urbanizado	Suelo Desnudo	Pastizal
NA	1.000	0.0	0.0	0.0	0.0	0.0	0.0	0.0
Agua	0.0	0.908	0.022	0.022	0.006	0.015	0.010	0.018
Árboles	0.0	0.010	0.748	0.009	0.001	0.027	0.000	0.205
Manglar	0.0	0.042	0.093	0.791	0.008	0.009	0.000	0.056
Cultivos	0.0	0.004	0.031	0.025	0.648	0.039	0.000	0.253
Urbanizado	0.0	0.003	0.010	0.000	0.000	0.969	0.001	0.017
Suelo Desnudo	0.0	0.118	0.046	0.063	0.014	0.313	0.138	0.307
Pastizal	0.0	0.005	0.135	0.003	0.025	0.044	0.001	0.785

Fuente: Elaboración propia a partir de resultados de MOLUSCE en QGIS. Los valores representan probabilidades de transición (valores entre 0 y 1). Los valores en la diagonal representan estabilidad de cada clase.

5.4 Modelo de transición

El modelamiento del potencial de transición se realizó mediante redes neuronales artificiales utilizando la arquitectura de perceptrón multicapa completamente conectado disponible en MOLUSCE. El proceso inicia con la definición del número de muestras y el modo de muestreo: para ambos modelos se especificaron 10,000 puntos distribuidos aleatoriamente sobre el territorio, garantizando representatividad espacial de las diferentes combinaciones de coberturas y variables explicativas. La configuración de parámetros de entrenamiento fue idéntica para ambos modelos (Tabla 5), buscando consistencia metodológica que permitiera comparar el desempeño predictivo entre períodos.

Tabla 5. Configuración de parámetros de la red neuronal artificial.

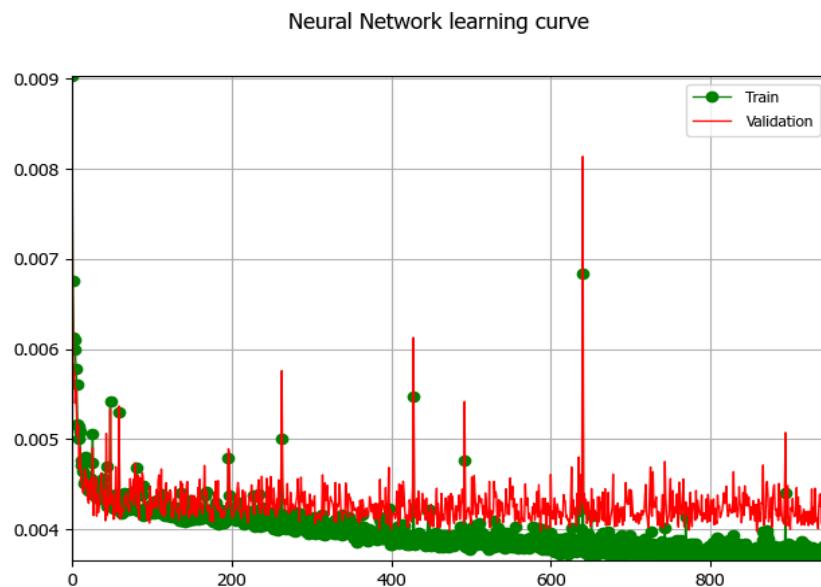
Parámetro	Valor
Modo de muestreo	Aleatorio (Random)
Número de muestras	10,000
Método	Perceptrón multicapa (Multi-layer Perceptron)
Vecindad (Neighbourhood)	1 px (Moore 3x3)
Tasa de aprendizaje (Learning Rate)	0.001
Momento (Momentum)	0.005
Capas ocultas (Hidden Layers)	8
Iteraciones máximas	950

Fuente: Elaboración de los autores.

5.5 Modelo 1 (2017-2021):

El entrenamiento del Modelo 1 alcanzó un índice Kappa de validación de 0.87342, clasificándose como "excelente" según la escala de Principi (2022). La curva de aprendizaje (Figura 7) muestra la evolución del error cuadrático medio durante las iteraciones, donde la línea verde representa el error de entrenamiento y la línea roja el error de validación.

Figura 7: Curva de aprendizaje del Modelo 1 (2017-2021) mostrando evolución del error de entrenamiento y validación



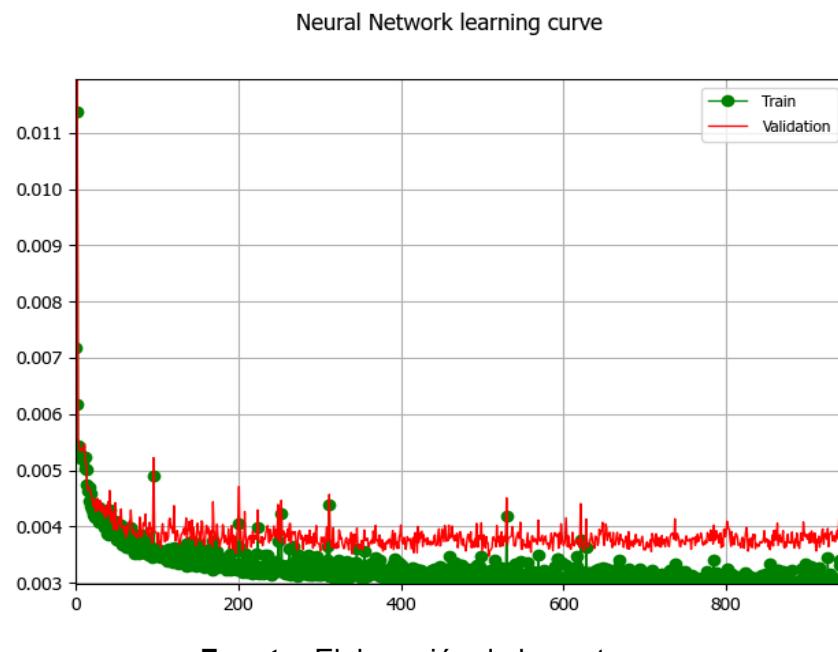
Fuente: Elaboración de los autores.

Se observa una convergencia rápida del error durante las primeras 100 iteraciones, seguida de estabilización en valores bajos (aproximadamente 0.004), indicando que la red logró capturar efectivamente los patrones de cambio del período 2017-2021. El error mínimo de validación alcanzado fue de 0.00398, con una precisión delta de -0.00013.

5.6 Modelo 2 (2017-2024):

El entrenamiento del Modelo 2 alcanzó un índice Kappa de validación de 0.88035, ligeramente superior al Modelo 1, confirmando la robustez del enfoque CA-ANN para este contexto territorial. La curva de aprendizaje (Figura 8) presenta un patrón similar de convergencia rápida inicial, con estabilización del error en niveles incluso más bajos que el Modelo 1 (aproximadamente 0.003). El error mínimo de validación alcanzado fue de 0.00347, con una precisión delta de -0.00030. La diferencia positiva de aproximadamente 0.7 puntos en el índice Kappa entre ambos modelos sugiere que el período más extenso (7 años) proporcionó mayor información para el aprendizaje de patrones complejos de transición territorial.

Figura 8: Curva de aprendizaje del Modelo 2 (2017-2024) mostrando evolución del error de entrenamiento y validación



Fuente: Elaboración de los autores.

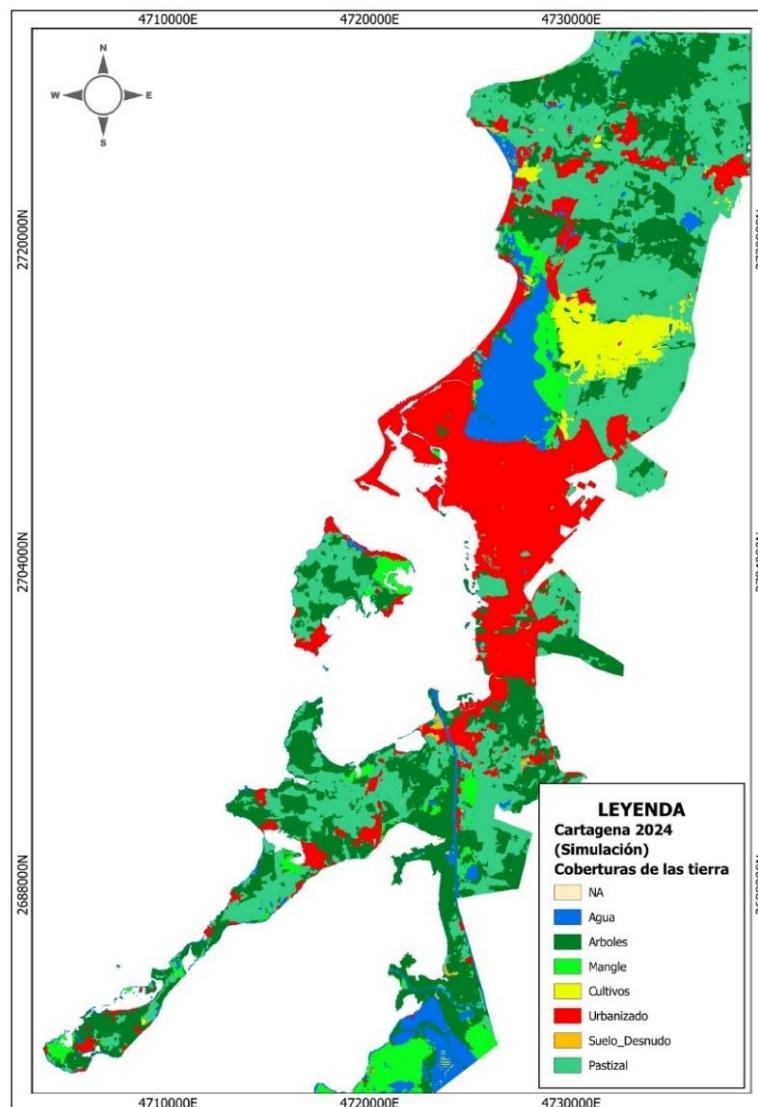
Los valores Kappa superiores a 0.80 en ambos modelos confirman la capacidad de las redes neuronales para identificar relaciones complejas y no lineales entre las variables explicativas y las probabilidades de transición entre categorías de cobertura. Las curvas de aprendizaje evidencian ausencia de sobreajuste (overfitting), dado que los errores de entrenamiento y validación convergen de manera estable sin divergencias significativas en las iteraciones finales. Esta estabilidad en el entrenamiento garantiza que los modelos capturan patrones generalizables del territorio y no simplemente memorizan las muestras de entrenamiento, lo cual resulta esencial para la confiabilidad de las proyecciones futuras.

6. RESULTADOS

6.1 Simulación de uso del suelo 2024

La simulación del Modelo 1 (2017-2021) proyectó un escenario a 2024 que fue comparado con el mapa de cobertura real observado en 2024. El mapa simulado (Figura 9) muestra la distribución espacial de las categorías de cobertura predichas por el modelo CA-ANN.

Figura 9: Mapa de cobertura de suelo simulado para 2024 mediante Modelo 1



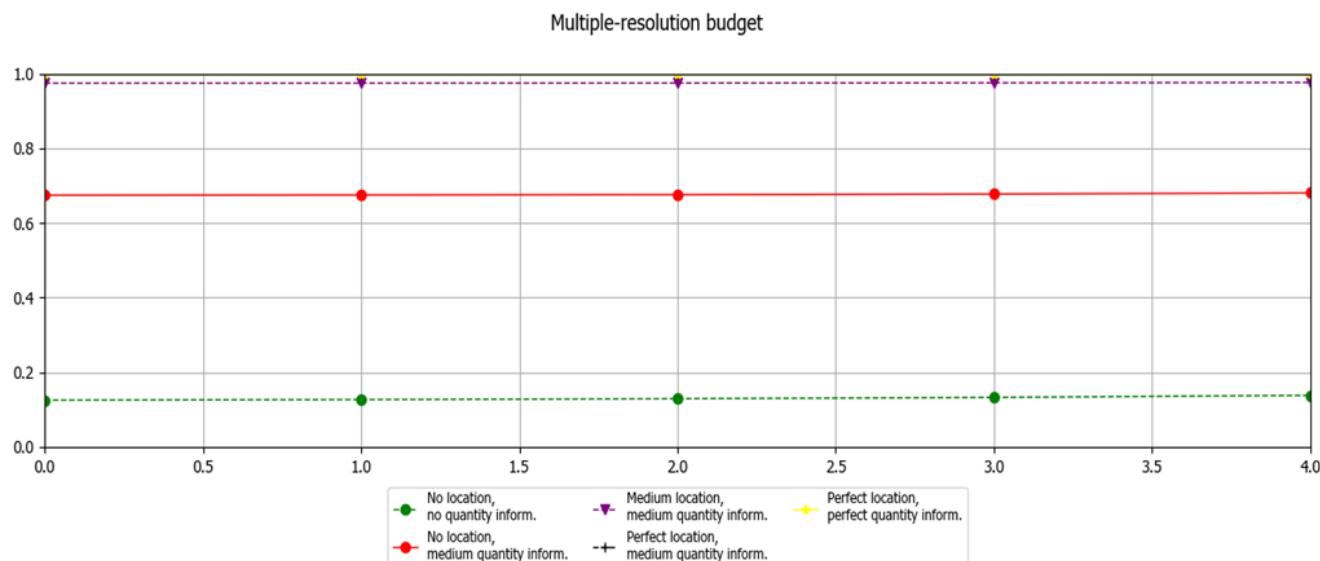
Fuente: Elaboración de los autores.



La validación del modelo arrojó los siguientes índices de concordancia:

- Kappa general (overall): 0.92190
- Kappa histograma: 0.99531
- Kappa localización: 0.92624
- Porcentaje de correctitud: 97.46%

Figura 10: Gráfico de resolución múltiple mostrando la validación del modelo



Fuente: Elaboración de los autores. La Tabla 6 presenta la comparación cuantitativa entre las superficies observadas y simuladas:

Tabla 6. Comparación de superficies entre cobertura real 2024 y simulación 2024 (Modelo 1).

Clase	2024 Real (km ²)	2024 Simulado (km ²)	Δ (km ²)	Error (%)
NA	2239.34	2239.34	0.00	0.00
Agua	43.52	42.28	-1.24	-2.85
Árboles	134.32	136.70	+2.38	+1.77
Manglar	31.24	32.22	+0.99	+3.17
Cultivos	17.41	17.98	+0.56	+3.22
Urbanizado	100.80	99.48	-1.32	-1.31
Suelo_Desnudo	1.17	1.43	+0.26	+22.22
Pastizal	176.27	174.64	-1.63	-0.92

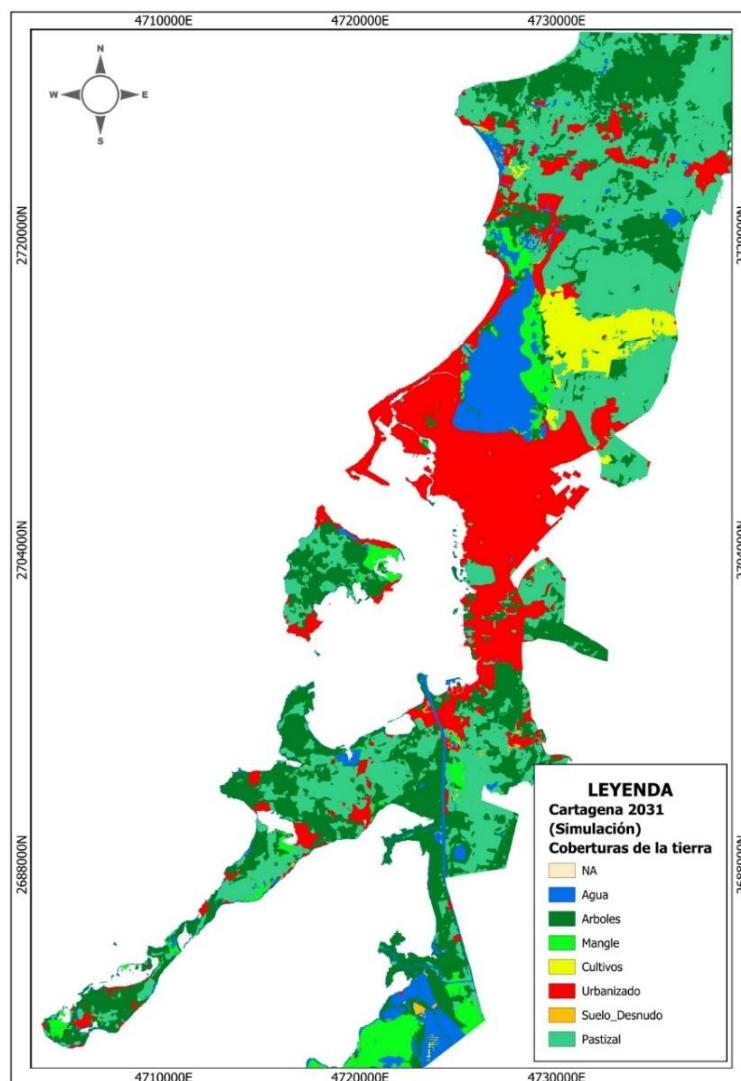
Fuente: Elaboración propia a partir de resultados de MOLUSCE en QGIS.

Los valores Kappa superiores a 0.92 confirman la alta capacidad predictiva del modelo. Los errores en superficie son menores al 3% para la mayoría de clases, excepto Suelo Desnudo que, por ocupar una superficie mínima (1.17 km²), presenta mayor error porcentual pese a una diferencia absoluta de solo 0.26 km². La clase Urbanizado muestra una precisión del 98.7%, validando la efectividad del enfoque CA-ANN para proyectar escenarios de expansión urbana.

6.2 Simulación de uso del suelo 2031

La proyección del Modelo 2 (2017-2024) simuló el escenario de cobertura de suelo para el año 2031 mediante una iteración de siete años a partir de la capa base de 2024. El mapa resultante (Figura 11) muestra la distribución espacial proyectada de las categorías de cobertura según las tendencias observadas durante el período 2017-2024 para el año 2031.

Figura 11: Mapa de cobertura de suelo proyectado para 2031 mediante Modelo 2



Fuente: Elaboración de los autores.



La Tabla 7 presenta las proyecciones cuantitativas de cambio para cada categoría de cobertura entre 2024 y 2031:

Tabla 7. Proyección de cambios de cobertura 2024-2031 (Modelo 2).

Clase	2024 (km ²)	2031 Proyectado (km ²)	Δ (km ²)	Δ (%)
NA	2239.34	2239.34	0.00	0.00
Agua	43.52	43.52	0.00	0.00
Árboles	134.32	134.02	-0.29	-0.22
Manglar	31.24	31.23	-0.01	-0.03
Cultivos	17.41	17.40	-0.01	-0.06
Urbanizado	100.80	101.17	+0.37	+0.37
Suelo_Desnudo	1.17	1.17	0.00	0.00
Pastizal	176.27	176.22	-0.06	-0.03

Fuente: Elaboración de los autores.

La proyección muestra cambios mínimos en todas las categorías durante el período 2024-2031. La clase Urbanizado presenta un incremento de apenas +0.37 km² (+0.37%), equivalente a una tasa de crecimiento de +0.05 km²/año. Las coberturas naturales muestran pérdidas marginales: Árboles -0.29 km², Manglar -0.01 km², Cultivos -0.01 km² y Pastizal - 0.06 km².

El crecimiento desacelerado proyectado por el modelo se atribuye principalmente a la restricción impuesta por la variable de áreas de conservación ambiental, la cual supone que estas zonas permanecerán inalteradas según la normativa vigente. Sin embargo, la experiencia empírica en contextos urbanos colombianos documenta que frecuentemente estas áreas resultan vulneradas por procesos de ocupación irregular y expansión urbana no planificada, lo que sugiere que la proyección podría subestimar el crecimiento real si no se implementan mecanismos efectivos de control territorial.



CONCLUSIONES Y RECOMENDACIONES

El desarrollo de dos modelos CA-ANN en MOLUSCE permitió analizar las dinámicas de cambio de cobertura del suelo en Cartagena de Indias durante el período 2017–2024 y proyectar la expansión urbana hacia 2031. La estrategia dual de modelación validó la efectividad del enfoque y evidenció patrones espaciales críticos de transformación territorial. El Modelo 1 alcanzó un índice Kappa de entrenamiento de 0.8734 y de validación de 0.9219, con una precisión global del 97.46 % al comparar la proyección 2025 frente a los datos reales de 2024, lo que confirma la capacidad del enfoque CA-ANN para reproducir con alta fidelidad los patrones de cambio territorial en contextos urbanos costeros. Por su parte, el Modelo 2, calibrado con un período temporal más amplio, obtuvo un Kappa de 0.8803, demostrando consistencia metodológica y capacidad de generalización del modelo. Durante el intervalo 2017–2024, la superficie urbanizada aumentó +11.39 km² (+12.7 %), mientras que el manglar y la cobertura arbórea se redujeron en –3.51 km² (–10.1 %) y –5.70 km² (–4.1 %), respectivamente. El principal patrón de conversión correspondió al paso de cultivos a zonas urbanizadas (65.9 %), lo que refleja un proceso de desagrariación periurbana. Asimismo, se identificó un cambio de régimen en la dinámica urbana, caracterizado por una etapa acelerada entre 2017 y 2021 (+2.39 km²/año) seguida de una desaceleración entre 2021 y 2024 (+0.61 km²/año).

La proyección hacia 2031 muestra un crecimiento urbano mínimo (+0.37 km² en siete años), condicionado por la restricción espacial impuesta por las áreas de conservación. Este escenario asume un cumplimiento normativo estricto, condición que podría no reflejar la realidad territorial, dada la frecuencia de ocupaciones informales en zonas protegidas de ciudades colombianas. En consecuencia, el modelo podría subestimar la expansión real si no se consolidan mecanismos efectivos de control del suelo. En cuanto a las correlaciones espaciales, se observó una relación negativa moderada entre densidad poblacional y distancia a vías ($r = -0.381$), confirmando el papel determinante de la accesibilidad en la configuración urbana. La correlación positiva entre pendiente y áreas de conservación ($r = 0.351$) indica que las zonas protegidas tienden a localizarse en terrenos con mayores restricciones topográficas.

De los resultados obtenidos se derivan varias recomendaciones orientadas al perfeccionamiento del modelo y su aplicabilidad en la gestión territorial. Es necesario ampliar el conjunto de variables explicativas incorporando factores socioeconómicos como el precio del suelo, el índice de pobreza o la proximidad a equipamientos urbanos, que podrían mejorar la capacidad predictiva. Igualmente, resulta pertinente incluir la distancia a asentamientos informales, dado que estos suelen actuar como núcleos de expansión urbana no planificada. Se recomienda actualizar periódicamente el modelo, idealmente cada tres o cuatro años, utilizando coberturas recientes y datos censales que permitan recalibrar los parámetros y detectar posibles variaciones en los patrones de cambio. También se sugiere desarrollar modelos diferenciados para períodos con y sin perturbaciones extraordinarias, lo que permitiría distinguir entre tendencias estructurales y eventos coyunturales. En términos técnicos, sería conveniente explorar arquitecturas neuronales más profundas, con un mayor número de capas ocultas y muestras de entrenamiento más amplias, a fin de evaluar mejoras potenciales en la precisión del aprendizaje.



Del mismo modo, la generación de escenarios alternativos mediante el ajuste manual de las probabilidades de transición permitiría representar distintos niveles de cumplimiento normativo sobre áreas protegidas, brindando así una herramienta más flexible para la toma de decisiones. Finalmente, se propone integrar proyecciones demográficas por sectores para ponderar la probabilidad de expansión según la presión poblacional diferencial, y validar los resultados mediante procesos participativos con actores locales, contrastando las zonas simuladas con aquellas donde efectivamente se registró expansión no prevista. Estas acciones contribuirían a fortalecer la pertinencia del modelo CA-ANN como instrumento de apoyo a la planificación territorial sostenible en contextos urbanos costeros.



REFERENCIAS BIBLIOGRÁFICAS

1. Aguilera Benavente, F. (2006). PREDICCIÓN DEL CRECIMIENTO URBANO MEDIANTE SISTEMAS DE INFORMACIÓN GEOGRÁFICA Y MODELOS BASADOS EN AUTÓMATAS CELULARES. *GeoFocus*, 81–112.
2. Alshari, E. A., & Gawali, B. W. (2022). Modeling Land Use Change in Sana'a City of Yemen with MOLUSCE. *Journal of Sensors*, 2022. <https://doi.org/10.1155/2022/7419031>
3. Asia Air Survey, & Next GIS. (2014). *MOLUSCE Modules for Land Use Change Evaluation*.
4. Blissag, B., Yebdri, D., & Kessar, C. (2024). Spatiotemporal change analysis of LULC using remote sensing and CA-ANN approach in the Hodna basin, NE of Algeria. *Physics and Chemistry of the Earth*, 133. <https://doi.org/10.1016/j.pce.2023.103535>
5. Flores-Juca, E., & Carrera, M. B. (2022). *PROSPECTIVE ANALYSIS OF THE INCIDENCE OF URBAN EXPANSION IN THE FIELD OF TERRITORIAL PLANNING: CITY OF CUENCA*. 19(1), 33–49.
6. Fontana, A. G., Nascimento, V. F., Ometto, J. P., & do Amaral, F. H. F. (2023). Analysis of past and future urban growth on a regional scale using remote sensing and machine learning. *Frontiers in Remote Sensing*, 4. <https://doi.org/10.3389/frsen.2023.1123254>
7. Iskandar, B., Saidah, Kurnia, A. A., Jauhari, A., & Zannah, F. (2024). Modeling Land Cover Change Using MOLUSCE in Kahayan Tengah Forest Management Unit, Kalimantan Tengah. *Jurnal Sylva Lestari*, 12(2), 242–257. <https://doi.org/10.23960/jsl.v12i2.865>
8. Jain, M. (2024). Future land use and land cover simulations with cellular automata-based artificial neural network: A case study over Delhi megacity (India). *Helion*, 10(14). <https://doi.org/10.1016/j.heliyon.2024.e34662>
9. kamaraj, manikandan, & Rangarajan, S. (2021). *Predicting the Future Land Use and Land Cover Changes for Bhavani Basin, Tamil Nadu, India Using QGIS MOLUSCE Plugin*. <https://doi.org/10.21203/rs.3.rs-616393/v1>
10. Lukas, P., Melesse, A. M., & Kenea, T. T. (2023). Prediction of Future Land Use/Land Cover Changes Using a Coupled CA-ANN Model in the Upper Omo–Gibe River Basin, Ethiopia. *Remote Sensing*, 15(4). <https://doi.org/10.3390/rs15041148>



11. Mas, J. F., Kolb, M., Paegelow, M., Camacho Olmedo, M. T., & Houet, T. (2014). Inductive pattern-based land use/cover change models: A comparison of four software packages. *Environmental Modelling and Software*, 51, 94–111. <https://doi.org/10.1016/j.envsoft.2013.09.010>
12. Muhammad, R., Zhang, W., Abbas, Z., Guo, F., & Gwiazdzinski, L. (2022). Spatiotemporal Change Analysis and Prediction of Future Land Use and Land Cover Changes Using QGIS MOLUSCE Plugin and Remote Sensing Big Data: A Case Study of Linyi, China. *Land*, 11(3). <https://doi.org/10.3390/land11030419>
13. Nguyen, H. D., Fox, D., Dang, D. K., Pham, L. T., Viet Du, Q. V., Nguyen, T. H. T., Dang, T. N., Tran, V. T., Vu, P. L., Nguyen, Q. H., Nguyen, T. G., Bui, Q. T., & Petrisor, A. I. (2021). Predicting future urban flood risk using land change and hydraulic modeling in a river watershed in the central province of Vietnam. *Remote Sensing*, 13(2), 1–24. <https://doi.org/10.3390/rs13020262>
14. OECD. (2022). *National Urban Policy Review of Colombia*. OECD. <https://doi.org/10.1787/9ca1caaee-en>
15. 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. <https://doi.org/10.5377/ce.v8i1.2055>
16. Principi, N. (2022). Modelado de expansión urbana mediante autómatas celulares y redes neuronales artificiales. *Revista Universitaria de Geografía*, 1(31). <https://doi.org/10.52292/j.rug.2022.31.1.0036>
17. Salazar Tamayo, M. M., & Julio Estrada, J. D. (2022). Planning gaps: unexpected urban expansion in five Colombian metropolitan areas. *Buildings and Cities*, 3(1), 725–744. <https://doi.org/10.5334/bc.240>
18. Sarkar, D., & Mondal, P. (2020). Flood vulnerability mapping using frequency ratio (FR) model: a case study on Kulik river basin, Indo-Bangladesh Barind region. *Applied Water Science*, 10(1). <https://doi.org/10.1007/s13201-019-1102-x>
19. Thammaboribal, P., & Tripathi, N. K. (2024). Predicting Land Use and Land Cover Changes in Pathumthani, Thailand: A Comprehensive Analysis from 2013 to 2023 Using Landsat Satellite Imagery and CA-ANN Algorithm, with Projections for 2028. *International Journal of Geoinformatics*, 20(5), 13–27. <https://doi.org/10.52939/ijg.v20i5.3225>