



UNIBA
Centro Universitario
Internacional
de Barcelona



UNIVERSITAT DE
BARCELONA

Facultad de Geografía e Historia

**Trabajo previo a la obtención del título de Máster en Planificación Territorial
y Gestión Ambiental**

**“Generación de un modelo de crecimiento tendencial urbano de la ciudad de
Macas (Ecuador) al año 2030, mediante técnicas de modelación espacial
multivariable”**

Autor: Iván Fernando Palacios Orejuela

Director: PhD. Meritxell Gisbert Traveria

Barcelona – España

Octubre 2020

Dedicatoria

Agradezco en primer lugar a nuestro Padre Dios por permitirme alcanzar un escalón más en mi carrera profesional, y a mi madre celestial, la Purísima de Macas a quien me encomiendo todos los días.

A mis padres, personas maravillosas a quienes les debo todo, por el sacrificio que han hecho, su amor y apoyo incondicional, por creer en mí y demostrarme que con esfuerzo y trabajo se logran cosas importantes.

A mi personita favorita, por estar a mi lado siempre, y brindarme su amor y comprensión en las buenas y en las malas.

Dedico este trabajo a mi tío Patricio, quien ahora está junto a nuestro creador, y a mi hermano José Andrés, dos ángeles que desde el cielo nos acompañarán siempre en nuestros corazones.

Resumen

El crecimiento de las ciudades es uno de los principales problemas con gran impacto sobre el territorio, cambiando el uso y cobertura del suelo, y dando lugar a nuevas afectaciones ambientales y sociales. La ciudad de Macas (Ecuador), ha tenido un crecimiento poco regulado y disperso, por lo que predecir su expansión coadyuvaría a preveer posibles inconvenientes a futuro. El objetivo del estudio fue, generar un modelo de crecimiento tendencial urbano de Macas al año 2030, mediante modelación espacial multivariable, para que sirva como una herramienta en la delimitación del suelo rural de expansión urbana según la LOOTUGS del Ecuador. Se aplicaron diversas técnicas de simulación espacial, de las cuales tres fueron las escogidas para su comparación y selección del mejor modelo, como fueron: autómatas celulares con perceptrón multicapa (AC – MLP) y con algoritmos genéticos (AC – AG), y aprendizaje ponderado por similitud (SimWeight). Los resultados de la validación mostraron un 31%, 47% y 54% de similitud para AC – AG, AC – MLP y SimWeight, respectivamente, por tanto, éste último fue el mejor modelo. Con la mancha urbana resultante, se identificó una tendencia de expansión hacia el Norte, y delimitó una propuesta del suelo de expansión urbana para Macas, la misma que está adyacente al área urbana actual. El modelo de ciudad deseado, las políticas que se tomen y la inclusión de este tipo de análisis espacial, permitirán planificar de una forma sostenible y ordenada a la ciudad.

Palabras clave: autómatas celulares, algoritmos genéticos, expansión urbana, LOOTUGS, SimWeight.

Abstract

The growth of cities is one of the main problems with a great impact on the territory, changing land use and cover, and giving rise to new environmental and social effects. The Macas's city (Ecuador), has had a poorly regulated and dispersed growth, so predicting its expansion would help to foresee possible problems in the future. The objective of the study was to generate a model of urban trend growth of Macas by the year 2030, through multivariate spatial modeling, to serve as a tool in the delimitation of rural land for urban sprawl according to the LOOTUGS of Ecuador. Various spatial simulation techniques were applied, of which three were chosen for comparison and selection of the best model, such as: cellular automata with multilayer perceptron (AC - MLP) and with genetic algorithms (AC - AG), and weighted learning by similarity (SimWeight). The results of the validation showed a 31%, 47% and 54% similarity for AC-AG, AC-MLP and SimWeight, respectively, therefore, the latter was the best model. With the resulting urban area, an expansion trend towards the North was identified, and a proposal for the urban expansion land for Macas was defined, the same one that is adjacent to the current urban area. The desired city model, the policies adopted and the inclusion of this type of spatial analysis will allow the city to plan in a sustainable and orderly manner.

Keywords: cellular automata, genetic algorithms, urban sprawl, LOOTUGS, SimWeight.

Índice

Dedicatoria	ii
Resumen	iii
Abstract	iv
Índice de tablas	viii
Índice de figuras	ix
Capítulo I: Introducción	1
1.1. Antecedentes	1
1.2. Planteamiento del problema	2
1.3. Justificación	3
1.4. Objetivos	4
1.4.1. Objetivo general	4
1.4.2. Objetivos Específicos	4
1.5. Hipótesis	5
1.6. Preguntas orientadoras de la investigación	5
1.7. Metas	5
Capítulo II: Marco Teórico	6
2.1 Fundamento teórico	6
2.1.1 Ordenamiento territorial	6
2.1.2 Planificación urbana	6
2.1.3 Expansión urbana	7
2.1.4 Tipos de ciudades urbanas	7
2.1.5 Crecimiento urbano de la ciudad de Macas	9

2.1.5.1	Límites políticos administrativos	9
2.1.5.2	Historia de la ciudad de Macas y el cantón Morona	10
2.1.5.3	Etapas de la planificación en la ciudad y el cantón	13
2.1.5.4	Límite urbano de la ciudad	14
2.1.5.5	Crecimiento demográfico de la ciudad	18
2.1.5.6	Descripción del área de estudio	20
2.1.6	Modelos espaciales de crecimiento urbano	21
2.1.6.1	Modelos generados mediante Cadenas de Markov	22
2.1.6.1.1	Land Change Modeler (LCM)	23
2.1.6.2	Modelos generados mediante Autómatas Celulares	30
2.1.6.2.1	DINAMICA EGO	31
2.1.6.2.2	MOLUSCE	37
2.1.7	Análisis normativo de la planificación territorial y urbana en Ecuador	40
2.1.7.1	Marco nacional	40
2.1.7.2	Ley Orgánica de Ordenamiento Territorial, Uso y Gestión de Suelo (LOOTUGS)	44
2.1.7.3	Clasificación y subclasificación del suelo	45
2.1.7.4	Marco cantonal	46
Capítulo III: Metodología		48
3.1	Generación y tratamiento de información geográfica	49
3.1.1	Tratamiento de imágenes satelitales	50
3.1.2	Elaboración de modelo de susceptibilidad a deslizamientos	53
3.1.3	Construcción y recopilación de información vectorial	56

3.2	Definición de la resolución espacial del modelo de predicción urbano	57
3.3	Modelamiento espacial.....	58
3.3.1	Determinación de variables potenciales a usar	58
3.3.2	Aplicación de MOLUSCE	59
3.3.3	Aplicación de LCM.....	63
3.3.4	Aplicación de DINAMICA EGO	68
3.3.5	Comparación entre modelos	78
3.3.6	Selección del modelo óptimo para modelar el crecimiento urbano.....	78
Capítulo IV: Análisis y Discusión de Resultados		79
4.1	Resultados con MOLUSCE.....	80
4.2	Resultados con LCM.....	85
4.3	Resultados con DINAMICA EGO	94
4.4	Modelo óptimo de crecimiento urbano.....	104
Capítulo V: Conclusiones y Recomendaciones.....		115
5.1	Conclusiones	115
5.2	Recomendaciones	116
Referencias.....		117

Índice de tablas

Tabla 1 <i>Escenarios propuestos según el suelo urbano requerido</i>	8
Tabla 2 <i>Desglosamiento de insumos de partida usados el estudio</i>	49
Tabla 3 <i>Características de una imagen ASTER</i>	50
Tabla 4 <i>Características de una imagen Sentinel 2A</i>	52
Tabla 5 <i>Ponderaciones mediante AHP a variables del modelo de deslizamientos</i>	54
Tabla 6 <i>Criterios seguidos para la reclasificación de ráster</i>	59
Tabla 7 <i>Cambio temporal de la mancha urbana de la ciudad de Macas</i>	79
Tabla 8 <i>Resultados de la validación del modelo simulado en MOLUSCE</i>	84
Tabla 9 <i>Valores de V de Cramer a las variables consideradas en LCM</i>	85
Tabla 10 <i>Probabilidades de transición de la cadena de Markov para MLP</i>	87
Tabla 11 <i>Coeficientes de la regresión logística</i>	88
Tabla 12 <i>Valores del ROC para los modelos de simulación obtenidos</i>	93
Tabla 13 <i>Matrices de transición obtenidas</i>	94
Tabla 14 <i>Valores de Cramer obtenidos del análisis de correlación</i>	97
Tabla 15 <i>Estadísticas de los parámetros calculados de fragmentación del paisaje</i>	98
Tabla 16 <i>Resultados de mínima similitud para la relación Expander/Patcher</i>	99
Tabla 17 <i>Probabilidades de transición con MC para SimWeight al 2030</i>	109
Tabla 18 <i>Caracterización de la tipología de expansión del paisaje en Macas</i>	112
Tabla 19 <i>Superficie de la mancha urbana de Macas en el periodo de estudio</i>	114

Índice de figuras

Figura 1 <i>Tipos de modelos urbanos</i>	7
Figura 2 <i>Modelo urbano según el suelo urbano necesario: a) compacto, b) policéntrico, c) difusa</i>	8
Figura 3 <i>Mapa de la división política del cantón Morona</i>	10
Figura 4 <i>Complejo de tolas</i>	11
Figura 5 <i>Mapa del área urbana definida en el Plan Regulador de 1980</i>	15
Figura 6 <i>Mapa del área urbana definida por el PDOT 2004</i>	16
Figura 7 <i>Mapa del área urbana actual de la ciudad de Macas</i>	17
Figura 8 <i>Mapa de la evolución del área urbana de la ciudad de Macas</i>	18
Figura 9 <i>Población censal entre 1962 y 2010 en el cantón Morona y Macas</i>	19
Figura 10 <i>Población referencial proyectada al 2020 del cantón Morona y Macas</i>	19
Figura 11 <i>Mapa de ubicación de la zona de estudio</i>	21
Figura 12 <i>Estructura de MLP</i>	26
Figura 13 <i>A_n vs $A_n * \exp(W^+)$ de distancia a todas las vías (en metros) para definir puntos de ruptura (a); A_n vs $A_n * \exp(W^+)$ de distancia a todas las vías (b)</i>	33
Figura 14 <i>Relación entre PDOT y PUGS acorde a la normativa ecuatoriana</i>	46
Figura 15 <i>Flujograma de trabajo para la generación del modelo de crecimiento urbano de Macas</i>	48
Figura 16 <i>Imagen ASTER del 2001, en combinación 6-1-3 para resaltar la mancha urbana de Macas</i>	51
Figura 17 <i>Imagen Sentinel 2A de enero/2020, en combinación 12-11-4 para resaltar la mancha urbana de Macas</i>	53

Figura 18 <i>Mapa de susceptibilidad a deslizamientos generado en la zona de estudio</i>	55
Figura 19 <i>Mancha urbana de Macas, en los tres periodos de tiempo definidos</i>	56
Figura 20 <i>Ingreso de los ráster en MOLUSCE</i>	61
Figura 21 <i>Cálculo de matriz de transición en MOLUSCE</i>	62
Figura 22 <i>Análisis de cambio y transición ocurrida en LCM</i>	63
Figura 23 <i>Ejemplo del test de Cramer en LCM</i>	64
Figura 24 <i>Estructura del modelo de transición integrado con sus variables explicativas</i>	64
Figura 25 <i>Modelo de entrenamiento del potencial de transición con MLP</i>	65
Figura 26 <i>Modelo de entrenamiento del potencial de transición con LR</i>	66
Figura 27 <i>Modelo de entrenamiento del potencial de transición con SimWeight</i>	67
Figura 28 <i>Cadena de Markov y asignación de cambio con SimWeight</i>	68
Figura 29 <i>Modelo para el cálculo de matrices de transición</i>	68
Figura 30 <i>Modelo para calcular los rangos de pesos de evidencia</i>	69
Figura 31 <i>Parámetros considerados en los rangos de pesos de evidencia</i>	70
Figura 32 <i>Modelo para calcular los coeficientes de los pesos de evidencia</i>	71
Figura 33 <i>Modelo de correlación espacial</i>	72
Figura 34 <i>Modelo de predicción para el periodo de calibración del crecimiento urbano</i>	73
Figura 35 <i>Modelo de mínima similitud</i>	75
Figura 36 <i>Modelo de algoritmos genéticos con niveles de tolerancias</i>	77
Figura 37 <i>Superficie en hectáreas de la mancha urbana en las parroquias de Macas y Proaño</i>	80
Figura 38 <i>Coficiente de Cramer obtenidos con los inputs del modelo en MOLUSCE</i>	81
Figura 39 <i>Curva de aprendizaje de la red neuronal con 5x5 de tamaño de vecindario</i>	82
Figura 40 <i>Curva de aprendizaje de la red neuronal con 7x7 de tamaño de vecindario</i>	82

Figura 41 <i>Curva de aprendizaje de la red neuronal con 9x9 de tamaño de vecindario</i>	83
Figura 42 <i>Resultados de la simulación con CA según el tamaño del vecindario</i>	84
Figura 43 <i>Estructura del modelo de aprendizaje de MLP</i>	86
Figura 44 <i>Mapa del potencial de transición contenido con MLP</i>	87
Figura 45 <i>Mapa del potencial de transición contenido con LR</i>	89
Figura 46 <i>Pesos de relevancia para las variables incluidas en SimWeight</i>	90
Figura 47 <i>Mapa del potencial de transición contenido con SimWeight</i>	91
Figura 48 <i>Modelos de predicción del crecimiento urbano de Macas en LCM</i>	92
Figura 49 <i>Resultados de la validación de modelos de predicción en LCM</i>	92
Figura 50 <i>Representación gráfica de coeficientes de pesos de evidencia para las variables incluidas: 1) distancia a suelo urbano, 2) distancia al viario, 3) susceptibilidad a deslizamientos, 4) distancia a mercados, 5) distancia a centros educativos, 6) distancia a espacios recreativos, 7) distancia a relleno sanitario, 8) distancia a cuerpos de agua, 9) distancia a centros de salud, 10) distancia al terminal, 11) pendientes</i>	95
Figura 51 <i>Resultados de la mínima similitud en la etapa de calibración del modelo</i>	100
Figura 52 <i>Comparación de resultados de mínima similitud entre límites de tolerancia vs. número de generaciones/individuos: 1) $\pm 60\%$, 2) $\pm 80\%$, 3) $\pm 90\%$, 4) $\pm 100\%$, 5) $\pm 120\%$, 6) $\pm 130\%$, 7) $\pm 140\%$, 8) $\pm 150\%$</i>	101
Figura 53 <i>Comparación de resultados de validación con un tamaño de ventana de 7 píxeles</i> . 103	
Figura 54 <i>Modelo de predicción del crecimiento urbano de Macas en DIMANICA con algoritmos genéticos</i>	104
Figura 55 <i>Selección del modelo óptimo para la simulación de crecimiento urbano futuro del lugar de estudio</i>	105

Figura 56 <i>Modelo resultante de crecimiento urbano mediante SimWeight</i>	110
Figura 57 <i>Tipologías de expansión del paisaje</i>	111
Figura 58 <i>Propuesta de delimitación del suelo rural de expansión urbana</i>	113

Capítulo I: Introducción

1.1. Antecedentes

El crecimiento urbano constante de las ciudades es actualmente una problemática global, con gran impacto sobre el territorio, debido principalmente al cambio de cobertura y uso del suelo (CCUS) (Arsanjani et al., 2011). La demandante cantidad de espacio y recursos responde a una expansión horizontal, ocurriendo principalmente en las zonas rurales o periféricas de las urbes (Arsanjani, 2011). El rápido incremento de la población, ejerce una presión sobre el entorno natural circundante de la ciudad, existiendo una correlación directa entre el CCUS y el crecimiento de estas, que pueden ser representados matemáticamente mediante modelos espaciales (Yu y Qingyun, 2011).

El modelamiento espacial multivariable tuvo gran impulso gracias a los Sistemas de Información Geográfica (SIG) que facilitaron en gran medida el análisis y predicción del crecimiento urbano (Musaoglu et al., 2005). Esta ventaja de los SIG se complementó con la visualización y medición de tendencias y patrones espaciales de la expansión urbana hacia el futuro (Allen y Lu, 2003), convirtiéndose en una importante herramienta para la planificación adecuada del desarrollo de una ciudad (Feng et al., 2012; Liang et al., 2018; Long et al., 2013; Yao et al., 2016). Existen varios métodos de predicción que han sido usados para el estudio de este fenómeno, entre los que se destacan las autómatas celulares, los modelos basados en agentes y la evaluación multicriterio (Aguilera et al., 2010; Li y Gong, 2016).

Estas herramientas pueden coadyuvar a un crecimiento ordenado de las ciudades, sirviendo de fundamento científico para una planificación territorial y urbana (Barreira et al., 2015), optimizando recursos, con el menor daño posible al medioambiente, e instituyéndolas como directrices para el desarrollo sostenible de las ciudades a través de políticas (Zhang et al., 2011).

1.2. Planteamiento del problema

El incremento demográfico que ha tenido la ciudad de Macas (Ecuador) en la última década se evidencia en el crecimiento urbano de la urbe, convirtiéndola en la ciudad más poblada de la provincia de Morona Santiago y a su vez del cantón Morona. Sin embargo, la falta de políticas y la inexistencia de una planificación urbana clara que ordene los asentamientos humanos, ha hecho que la expansión de la mancha urbana sea dispersa y desordenada, creciendo horizontalmente a pasos acelerados. Dentro del último Plan de Desarrollo y Ordenamiento Territorial (PDOT) vigente, no se identifica un suelo destinado para el crecimiento de la ciudad, ni tampoco se han realizado estudios que determinen hacia donde se encuentra la dinámica de expansión de Macas en el futuro. Todo esto, sumado a la falta de control de las autoridades, ha generado un gran problema social y territorial actual y futuro, debido a la presión antrópica que ha cambiado el uso de suelo sobre áreas donde no se cuenta con los servicios básicos ni las aptitudes para acoger el desarrollo de edificaciones.

El modelamiento multivariable espacial dentro de un SIG, se presentan como un mecanismo práctico para simular el crecimiento de las ciudades y proporcionar criterios válidos para la ordenación de esta actividad. Es por ello que, el planteamiento del presente trabajo, es el modelamiento tendencial del crecimiento urbano de la ciudad de Macas para que éste sirva como un insumo técnico en el correcto ordenamiento del territorio. El resultado al que se pretende llegar aterriza en una propuesta de delimitación del suelo óptimo para acoger la expansión de la ciudad en el futuro, acorde a la Ley Orgánica de Ordenamiento Territorial, Uso y Gestión del Suelo (LOOTUGS) del Ecuador, que la denomina “suelo rural de expansión urbana”.

1.3. Justificación

El análisis multitemporal de los cambios en el uso y cobertura del territorio es de vital importancia para el entendimiento de las dinámicas y factores que influyen en el crecimiento de las ciudades (Arsanjani et al., 2011). Los distintos métodos de simulación de crecimiento urbano, integrados a los SIG, se presentan como una herramienta fundamental para evaluar los impactos, actuales y futuros, con el fin de planificar el desarrollo equilibrado de la ciudad y su entorno.

La ciudad de Macas, al ser la capital del cantón y de la provincia, concentra la mayor parte del movimiento económico y político, lo cual ha motivado el aumento de la población, y por ende, la expansión de la mancha urbana. Según el último censo poblacional, la ciudad posee una población (proyectada al 2020) de 27156 habitantes, con una tasa de crecimiento que duplica al del censo anterior (INEC, 2010). Este aumento demográfico ha generado la construcción de casas e infraestructura en los suelos vacantes de la ciudad. Sin embargo, debido a la falta de una planificación urbana, los asentamientos de nuevas viviendas se han localizado en los lugares desprovistos de servicios básicos. Esto ha provocado el fraccionamiento de las pocas reservas de cobertura boscosa que le quedan a la ciudad. Además, y con el objetivo de brindar dichos servicios a toda la población, se ha tenido que invertir un considerable monto económico sin lograr hasta la fecha actual, dotar de la infraestructura necesaria para abastecer de servicios básicos a las nuevas zonas creadas (GAD Morona, 2012).

Ante esto, se plantea la obtención de un modelo de crecimiento tendencial urbano para la ciudad hacia el año 2030, que permita entender la dinámica de expansión urbana. De esta forma, se podrán generar estrategias para la ordenación del territorio, tomando como insumo base la información cartográfica existente, que será necesaria para alcanzar un modelamiento preciso que

permita la asignación, en conformidad a la normativa legal actual, del uso de suelo destinado a la actividad antrópica.

Además, este estudio se alinea con los objetivos de desarrollo sostenible, en especial con el objetivo 11 (Ciudades y Comunidades Sostenibles) (ONU, 2015), y con los lineamientos territoriales de acceso equitativo a infraestructura y conocimiento (puntos c.2 y c.5) contenidos en la Estrategia Territorial Nacional (ETN), dentro del Plan Nacional de Desarrollo (PND) vigente (PND, 2017). Todo esto, será de gran utilidad para el Gobierno Autónomo Descentralizado (GAD) del cantón Morona, para la planificación urbana de la ciudad hacia el futuro.

1.4. Objetivos

1.4.1. Objetivo general

Generar un modelo de crecimiento tendencial urbano de la ciudad de Macas al año 2030, mediante modelación espacial multivariable, y sea una herramienta para la delimitación del suelo rural de expansión urbana según la LOOTUGS del Ecuador.

1.4.2. Objetivos Específicos

- Aplicar un estudio multitemporal del crecimiento urbano de la ciudad de Macas en los periodos de 2001, 2012 y 2020.
- Desarrollar distintas técnicas de modelación multivariable que simulen el crecimiento de la urbe al año 2020.
- Validar los modelos obtenidos y seleccionar el que mejor ajuste alcance, al compararlos con el mapa real del último periodo.
- Predecir el crecimiento urbano de la ciudad de Macas al año 2030, desde un enfoque tendencial, entendiendo su dinámica de expansión con las tres fechas analizadas.

- Proponer una delimitación del suelo rural de expansión urbana, siguiendo la definición estipulada en la LOOTUGS.

1.5. Hipótesis

El modelo generado del crecimiento urbano tendencial de la ciudad de Macas, permite la identificación del suelo rural óptimo para el crecimiento de la urbe en los próximos años.

1.6. Preguntas orientadoras de la investigación

- ¿El crecimiento de la ciudad de Macas se ha realizado sin ninguna herramienta planificadora?
- ¿Cómo ha sido la dinámica, en términos de área, del crecimiento de la mancha urbana horizontal de la ciudad de Macas desde el año 2001?
- ¿Qué variables influyen más en el crecimiento urbano tendencial de la ciudad de Macas?
- ¿Es posible obtener un modelo espacial que prediga correctamente el crecimiento urbano de la ciudad de Macas?
- ¿La delimitación del suelo rural de expansión urbana, señalada en la LOOTUGS, es factible delimitarla únicamente con el resultado del modelamiento espacial?

1.7. Metas

- Un modelo de crecimiento tendencial urbano de la ciudad de Macas al año 2030.
- Una figura comparativa de los modelos de simulación realizados.
- Una tabla con los resultados del estudio multitemporal de la superficie de la mancha urbana para los tres periodos analizados y del modelo de predicción al año 2030.

Capítulo II: Marco Teórico

2.1 Fundamento teórico

2.1.1 Ordenamiento territorial

El ordenamiento, ordenación, planeamiento, o planificación territorial es un término que engloba un concepto muy vasto y complejo de resumirlo, ya que su significado y entendimiento depende de quien lo use y el contexto territorial en que se aplique.

Existen varios estudios donde se define la ordenación del territorio, por ejemplo, según Gómez (2002), el ordenamiento territorial identifica, organiza, regula y distribuye las diferentes actividades del hombre en un territorio con aptitud de acogerlas.

Con esta conceptualización, se puede decir que, el ordenamiento territorial es un instrumento de planificación político – técnico y administrativo – jurídico, que trata de ordenar las actuaciones antrópicas mediante la identificación de características específicas del suelo, que brinden el menor daño posible al medioambiente y permitan la mayor prestación de servicios a sus habitantes.

2.1.2 Planificación urbana

Es el conjunto de instrumentos técnicos y normativos que regulan la estructuración espacial del área urbana de una ciudad, considerando las características propias de cada una de estas (López, 2015).

En el contexto normativo ecuatoriano, el Art. 4, párrafo 12 de la LOOTUGS la conceptúa como un grupo de disposiciones e instrumentos técnico – normativos que establecen la forma organizativa espacial de los usos y ocupaciones del suelo, tanto urbano como rural, sus obligaciones y derechos vinculados a estos (Asamblea Nacional, 2016).

2.1.3 Expansión urbana

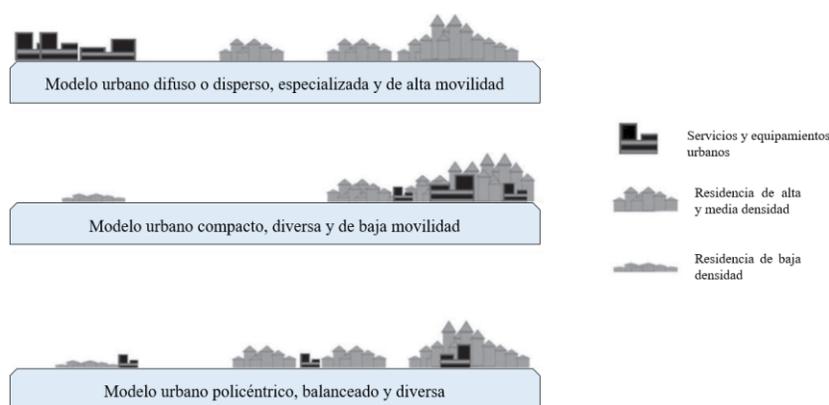
Hace referencia al crecimiento espacial de las ciudades (Urriza y Garriz, 2014), que se produce de forma dinámica en el tiempo, y está relacionado principalmente a factores económicos, industriales y demográficos (Cerde, 2007), que ocurre en la periferia de las urbes de manera irregular (Bazant, 2010), provocando la ocupación de suelos con vocación productiva, la fragmentación de espacios naturales, entre otros.

2.1.4 Tipos de ciudades urbanas

Son la representación sintética del comportamiento espacial de una ciudad (Álvarez, 2010). Estos modelos urbanos han sido analizados desde varios enfoques (forma, funcionalidad, estructura, proceso), siendo los más conocidos los siguientes tres tipos de ciudades: compacta, dispersa o difusa, y policéntrica o balanceada (CEPAL, 2013). En la Figura 1 se representan los distintos modelos urbanos mencionados:

Figura 1

Tipos de modelos urbanos.

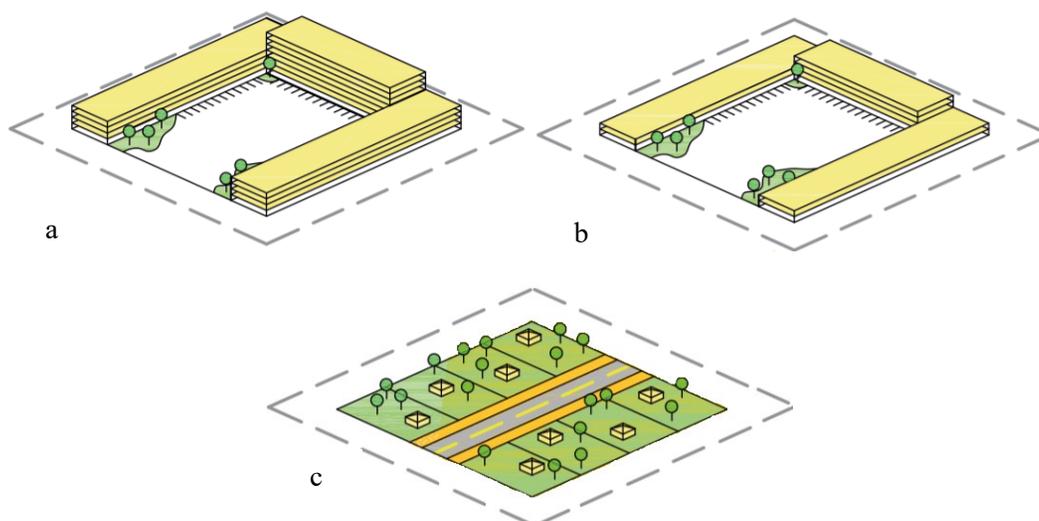


Fuente: adaptado de Sanabria y Ramírez (2017).

Los modelos de ciudades también se pueden expresar en escenarios dependientes de su índice de edificabilidad, es decir, según la estimación del suelo urbano necesario para albergar la tipología de ciudad deseada, como sigue:

Figura 2

Modelo urbano según el suelo urbano necesario: a) compacto, b) policéntrico, c) difusa.



Fuente: adaptado de ONU Habitat (2014).

Algunas de las características de estas tipologías de ciudad se muestran en la Tabla 1, a continuación:

Tabla 1

Escenarios propuestos según el suelo urbano requerido.

Características	Escenario a (compacta)	Escenario b (policéntrica)	Escenario c (difusa)
Índice de edificabilidad	3.0	1.5	0.2
Superficie del suelo	733 ha	1467 ha	11000 ha
Superficie pública	733 ha	1467 ha	11000 ha
Superficie total	1466 ha	2933 ha	22000 ha
Densidad poblacional	681.82 persona/ha	340.91 persona/ha	45.45 persona/ha
Densidad habitacional	136 vivienda/ha	68 vivienda/ha	9 vivienda/ha

Fuente: (ONU Habitat, 2014).

2.1.5 Crecimiento urbano de la ciudad de Macas

Para hablar de la ciudad de Macas, se requiere escudriñar en los anales de la historia del Ecuador, ya que, al igual que en el resto del territorio nacional (Palacios y Leiva, 2019, 2020), esta parte del país posee una riqueza histórica muy amplia, pero tristemente poco estudiada. En este apartado, se presenta una contextualización histórica, geográfica y demográfica de Macas, para ofrecer un mejor entendimiento del área de estudio.

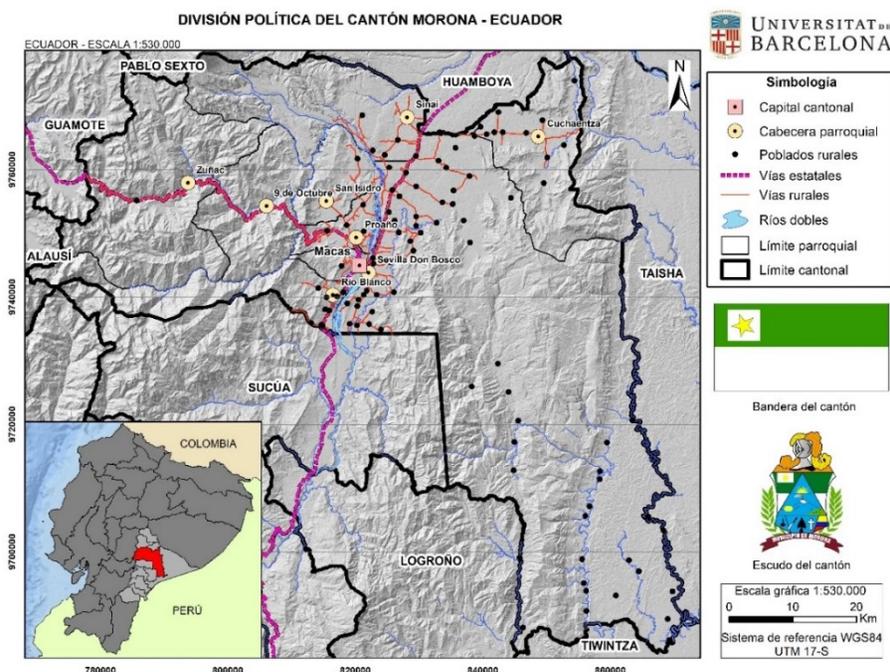
2.1.5.1 Límites políticos administrativos

La ciudad de Macas, pertenece a la parroquia que lleva el mismo nombre, y es la única urbana, de las nueve parroquias que conforman el cantón Morona. Para comprender el emplazamiento de la ciudad Macas, es necesario definir en primera instancia los circunvecinos con los que limita su cantón, Morona.

Según los límites cantonales aprobados por el Comité Nacional del Límites Internos (CONALI) en el 2018, Morona limita con los siguientes cantones: al Norte con Pablo VI y Huamboya, al Este con Taisha, al Sur con Sucúa, Logroño y Tiwintza; al Oeste limita con los cantones de Alausí y Guamote. Por su parte, Macas a nivel parroquial tiene los siguientes límites: al Norte con General Proaño, al Este con Sevilla Don Bosco, al Sur con Río Blanco, y al Oeste nuevamente con Río Blanco y 9 de Octubre, como se muestra en la Figura 3.

Figura 3

Mapa de la división política del cantón Morona.



Fuente: elaboración propia.

2.1.5.2 Historia de la ciudad de Macas y el cantón Morona

- Período preinca

Los estudios arqueológicos realizados en esta zona han sido contados, sin embargo, sus resultados demuestran la gran riqueza cultural y el pasado que se esconde en la amazonía ecuatoriana. El primer arqueólogo que se dedicó al estudio de los antiguos pobladores de Macas, fue el Padre Pedro Porras, quien identificó vestigios arqueológicos de los pobladores de esta zona, y propuso 4 fases o periodos de ocupación, que en conjunto formaban la Tradición Upano o cultura Upano (Porras, 1987):

- ✓ Fase Pre Upano: datada entre los 2750 a.C. y 2520 a.C.
- ✓ Fase Upano I: situada entre 1100 a.C. y 120 a.C.
- ✓ Fase Upano II: cronológicamente ubicada entre los 40 a.C. y 170 d.C.

- ✓ Fase Upano III: definida desde los 940 d.C.

Esta cultura se desarrolló prósperamente a lo largo del valle del río Upano, encontrando vestigios en ambas márgenes del río. Se destaca el sitio arqueológico del Alto Upano (Cabrero, 2017; Salazar, 2008), ubicado en la comunidad de Huapula, donde se encuentran agrupadas un conjunto de montículos de tierra (tolas o pirámides truncadas) (Pazmiño, 2017; Rostain, 2012), que hacen alusión a figuras zoomorfas y antropomorfas (Rostain, 1999, 2010; Salazar, 1998). En la Figura 4, se observa una ejemplificación de lo descrito anteriormente.

Figura 4

Complejo de tolas.



Fuente: (Salazar, 2008).

- Período colonial

El nombre de Macas, se le atribuye al cacique o pueblo sobreviviente de la Tradición Upano “Los Macas”, y perduró hasta la época de la conquista inca. El topónimo tiene relación con el quichua, en dialectos de Panzaleo y Cañari, Puruhá – Mochica (Barruecos, 1959), por lo que se infiere una condición de pueblo de piedemonte (Rostain, 2012). Ya desde la época colonial, se conocía a esta zona como la “tierra de los Macas”, siendo el centro de una disputa de poder por la conquista del Oriente, entre los gobiernos de Yaguarzongos y Quijos (Carrera, 1987).

El primer contacto español en esta tierra fue en 1534, entre el Capitán Díaz de Pineda y los caciques Huamboya y Macas. En el año de 1540, Rodrigo Núñez de Bonilla ingresa por primera vez a la tierra de los Macas (Cárdenas y Cueva, 2004).

Fueron dos las ciudades erigidas por españoles en la época de la conquista en esta zona. La primera se dio el 15 de agosto de 1563 con la fundación de Nuestra Señora del Rosario a cargo de Juan de Salinas Guinea, ordenado por Vásquez de Ávila, gobernante de Quijos (Costales y Costales, 1996). La segunda fue Sevilla de Oro, con una fecha de fundación entre 1573 a 1574, por el Capitán José Villanueva Maldonado, bajo las órdenes del gobernador de Yaguarzongos, Juan de Salinas Loyola. Sin embargo, el ubicarse más al norte del antiguo asentamiento de Nuestra Señora del Rosario, quedó circunscrita en los dominios del Gobierno de Quijos (Carrera, 1987; Costales y Costales, 1996). Esta ciudad, permaneció al margen oriental del río Upano hasta 1685, cuando una avenida de dicho río obligó al traslado de sus pobladores al margen occidental, donde se encontraban los Macas (Carrera, 1987). El resultado de ese mestizaje y tradición cultural se conserva en lo que hoy se conoce como el Pueblo Macabeo.

- Período republicano

Luego de los ajetreos de la independencia, en 1824 se aprueba una ley que dividió a la Gran Colombia, donde Macas figuró como un cantón de la provincia de Chimborazo. Para el siguiente año, Macas pasó a ser parte del cantón Sangay perteneciente a la misma provincia. Fue el 29 de mayo de 1861, que Macas es considerada como capital del cantón Sangay (provincia de Chimborazo), y en memoria de este acontecimiento se celebra anualmente su cantonización (Costales y Costales, 1998).

El 13 de noviembre de 1911 (con Registro Oficial N° 58 del Año I), se reconoce la “provincia del Oriente” formada por 5 cantones, manteniendo a Macas como capital del cantón

Santiago. Acto seguido, en 1920, Macas pasa a ser la capital de la provincia de Santiago – Zamora y cabecera del cantón Morona (como consta en el Registro Oficial N° 33 del 19 de agosto de 1925). En noviembre 10 de 1953, se dividieron en tres las provincias del oriente, una de ellas fue Morona Santiago con Macas como capital de esta nueva provincia (Registro Oficial N°360 del Año II). Finalmente, en 1959 la región oriental se dividió en cuatro provincias, donde Morona Santiago mantenía a Macas como su capital provincial y cabecera del cantón Morona (Cárdenas y Cueva, 2004). Actualmente, esta división administrativa – política de la provincia, es la que perdura hasta hoy en día.

2.1.5.3 Etapas de la planificación en la ciudad y el cantón

La planificación territorial en el cantón Morona, al igual que en el Ecuador, posee una reciente experiencia, ya que se han desarrollado dos procesos de elaboración y aprobación de PDOT conforme a las directrices de la constitución del 2008 (Benabent y Vivanco, 2019). Desde que la Carta Magna fue aprobada, se produjo un paso fundamental (al menos desde la parte normativa), en temas de ordenamiento del territorio, debido a que se consideró a este como punto clave para la planificación del desarrollo del país (Pauta, 2013).

El GAD Morona como tal, ha elaborado tres PDOT en su corta historia planificadora (aunque previamente hubo el Plan Regulador de Macas realizado en 1980). El primero fue en 2004 y se denominó “Actualización del Plan de Desarrollo Estratégico Cantonal, Morona 2004”, el cual tenía un enfoque más urbanístico, dejando de lado la parte estructurante rural. El segundo PDOT fue en el año 2012 (siendo el primero con las directrices de la constitución del 2008), y se llamó “Plan Cantonal de Desarrollo y Ordenamiento Territorial, Morona 2012 – 2020). La característica de este plan, el cual todavía sigue en vigencia, es que presenta tres partes fundamentales: Diagnóstico, Propuesta y Modelo de Gestión. La metodología implementada en ese entonces

sugería un trabajo muy dispendioso del diagnóstico, abarcando seis componentes: biofísico, económico, sociocultural, asentamientos humanos, movilidad energía y conectividad, político institucional. Si bien este plan contenía un bagaje de información muy completo, su extensión y profundización en los contenidos, era discordante con el resto de etapas del plan. Finalmente, el tercer y último PDOT aprobado, fue la actualización del anterior en 2015 y que llevó por nombre “Actualización del Plan Cantonal de Desarrollo y Ordenamiento Territorial, Morona 2015 – 2019”. En este, se efectuaron ciertas incorporaciones de nueva información y reajuste de los programas, proyectos y metas planteadas, pero se mantuvo la esencia del anterior, ya que su periodo de vigencia era de 8 años. Estos dos PDOT permanecen en vigor hasta que el nuevo PDOT sea desarrollado.

Recientemente, en mayo del 2019 se procedió con la nueva actualización del PDOT cantonal para el periodo 2019 – 2023, siguiendo una metodología distinta al de los planes anteriormente elaborados. Esto se debe a que tanto la parte normativa nacional (lo cual se abordará con más claridad en el apartado 2.2.7), como las necesidades del cantón han cambiado, trabajando con un enfoque metodológico más integrador, lo que Gómez (2002), denomina planificación estratégica. Este PDOT está siendo elaborado y tendrá vigencia para un período de 12 años.

2.1.5.4 Límite urbano de la ciudad

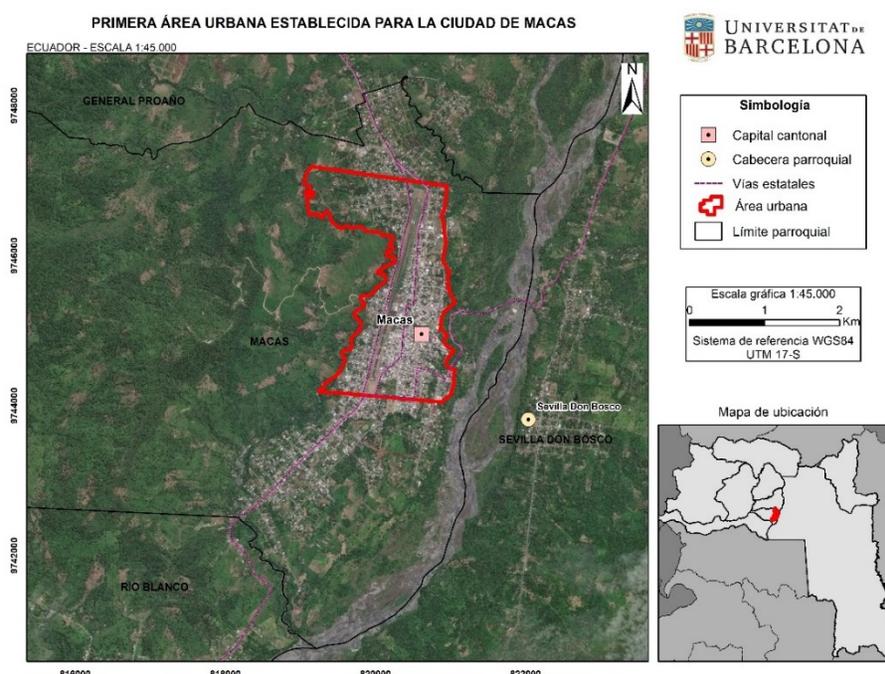
La división entre urbano y rural ha sido motivo de varios estudios y divergencias entre autores, puesto que, tanto en la parte metodológica como conceptual, no se tiene consensuado las diferencias precisas entre estas dos clases de suelo (Benabent, 2019; Cadavid, 2009; De Guerrero, 2011; Esteban, 1998, 2011; Gil de Pareja, 2011). Esto se debe, en parte, a que el sistema urbano es muy complejo y dinámico, dando origen a varias formas de expansión (suburbios, edge cities, contraurbanización, sprawl, entre otros) que no siguen las características exactas de ninguno de

estos dos tipos de suelo (Cerde, 2007). En el contexto nacional, a estas áreas intermedias se las conoce como zona periurbana, suburbana o simplemente poblados rurales (Gómez y Gómez, 2016).

Específicamente, en lo que se refiere a la ciudad de Macas, se definió una primera área urbana en el Plan Regulador de 1980, cuya delimitación seguía dos líneas transversales imaginarias al Norte y Sur de la ciudad, considerando los extremos del aeropuerto como límite (ver Figura 5).

Figura 5

Mapa del área urbana definida en el Plan Regulador de 1980.

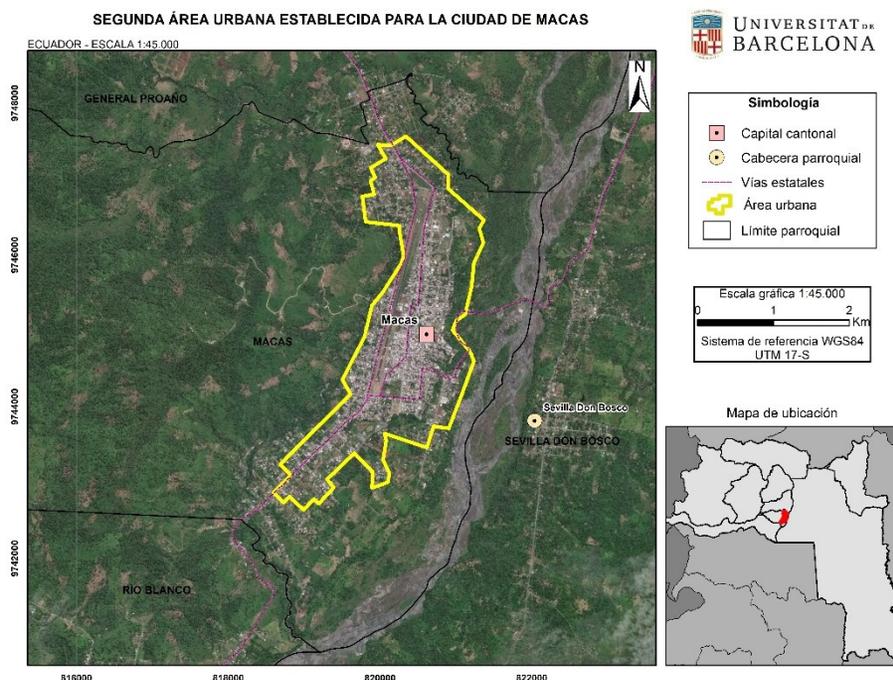


Fuente: adaptado de GAD Morona (2004).

Una segunda delimitación fue propuesta por el PDOT 2004 considerando las áreas edificadas existentes de aquel tiempo, las zonas de planificación propuestas y un perímetro de control urbano establecido en dicho plan (ver Figura 6).

Figura 6

Mapa del área urbana definida por el PDOT 2004.

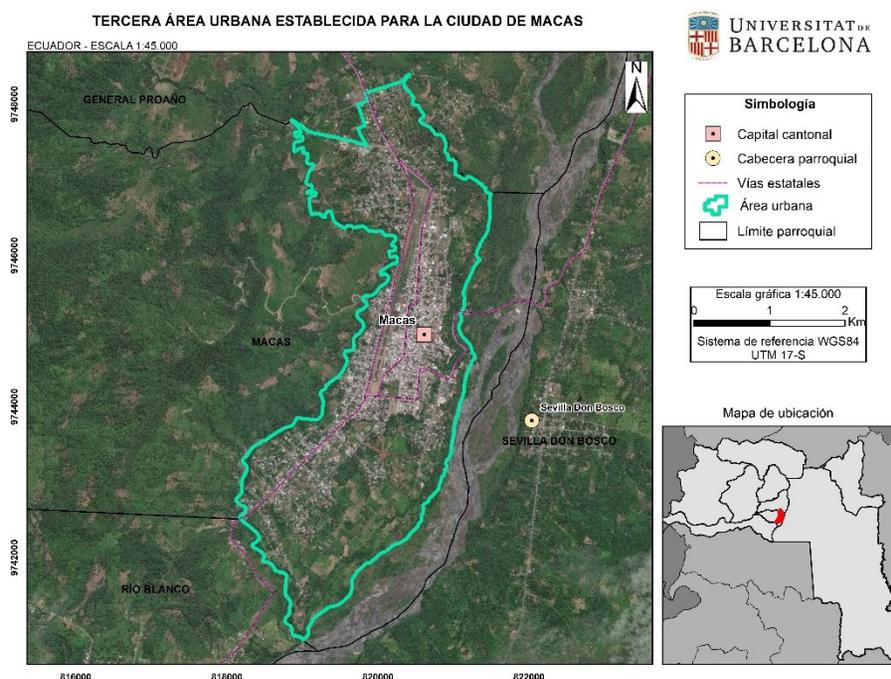


Fuente: adaptado de GAD Morona (2004).

En el PDOT del año 2012, se indicó la necesidad de establecer una nueva área urbana para la ciudad, situación que se mantuvo en el PDOT 2015, para que, posteriormente en el año 2016, se estableciera el límite urbano (actual) para Macas y otras tres capitales parroquiales (GAD Morona, 2016), la misma que se puede observar en la Figura 7.

Figura 7

Mapa del área urbana actual de la ciudad de Macas.

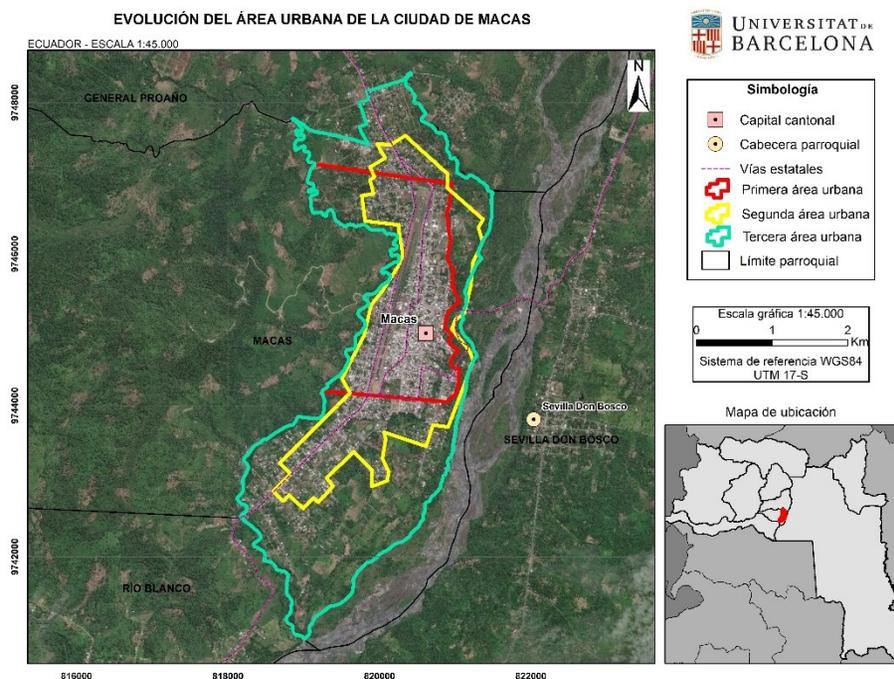


Fuente: adaptado de GAD Morona (2016).

Como se observa en la Figura 7, según el área urbana actual, todavía existen zonas no consolidadas dentro de este polígono, sin embargo, a pesar de que lo lógico sería que primero se ocupen estos terrenos baldíos, la realidad del crecimiento de la ciudad es otra, principalmente en dirección a la parroquia de Gral. Proaño. En la Figura 8, se presentan todas las áreas urbanas de la ciudad, en la que se puede dimensionar la evolución de su límite urbano a lo largo de los años.

Figura 8

Mapa de la evolución del área urbana de la ciudad de Macas.



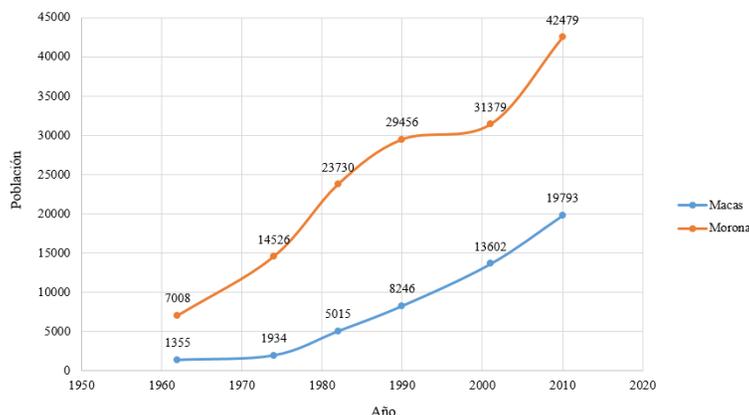
Fuente: elaboración propia.

2.1.5.5 Crecimiento demográfico de la ciudad

El crecimiento demográfico de la ciudad de Macas ha sido dinámico en el tiempo, siguiendo una tendencia positiva al aumento de su población, como lo demuestra las cifras obtenidas desde el primer censo poblacional realizado hasta el último registrado. En la Figura 9 se observa la población censal de la ciudad de Macas y del cantón Morona desde 1962 hasta 2010:

Figura 9

Población censal entre 1962 y 2010 en el cantón Morona y Macas.

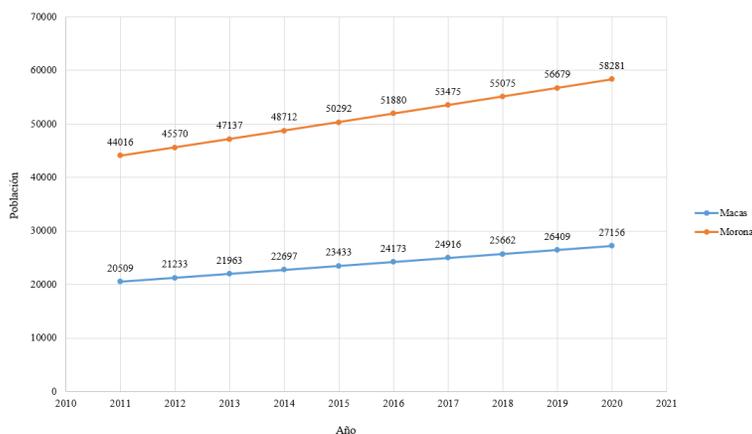


Fuente: (INEC, 2002).

Si bien los datos oficiales del último censo son hasta el 2010, la Secretaría Técnica Planifica Ecuador (STPE) (anterior SENPLADES), realizó una proyección de la población a nivel nacional hasta el año 2020, la cual es la información más actualizada que se cuenta en lo referente a demografía para entender el comportamiento poblacional de la ciudad de Macas. En la Figura 10, se muestra la proyección referencial de la población cantonal y de la ciudad objeto de estudio:

Figura 10

Población referencial proyectada al 2020 del cantón Morona y Macas.



Fuente: (STPE, 2017).

De acuerdo a las estadísticas poblacionales, se observa que Macas ha tenido un crecimiento lineal constante de su población, siendo la más poblada del cantón (donde el 46.59% de los habitantes de Morona, se registran solo en esta urbe al 2010), y de la provincia. Debido a su condición de capital cantonal y provincial, contiene una mayor cantidad de servicios urbanos convirtiéndola en el centro económico, político y económico de Morona Santiago, lo cual ha contribuido a un rápido crecimiento poblacional en esta ciudad, produciendo un problema de expansión urbana irregular que se agrava por la falta de planificación sobre esta temática. Esto ha motivado la presente investigación, no solo por la inexistencia de modelos espaciales que ayuden a la comprensión de la dinámica en que la ciudad crece, sino por la incorporación de estos modelos dentro de la normativa ecuatoriana vigente, como una base técnica para la delimitación del suelo vocacional para recibir esta actividad del hombre.

2.1.5.6 Descripción del área de estudio

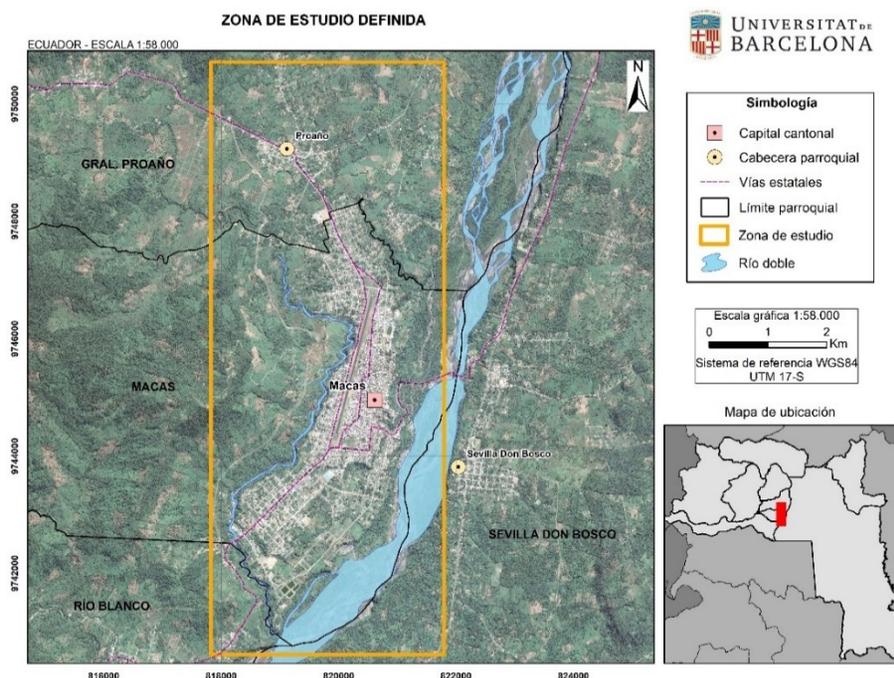
La zona escogida para esta investigación se ubica en la región amazónica del Ecuador, específicamente en el cantón Morona, provincia de Morona Santiago. La ciudad de Macas geográficamente se encuentra a $2^{\circ}18'9.63''$ de Latitud Sur y $78^{\circ}7'7.84''$ de Longitud Oeste (coordenadas geodésicas, sistema de referencia WGS84), y unos 1010 metros de altitud sobre el nivel medio del mar aproximadamente.

Se trata de una llanura de piedemonte extendida al costado occidental del río Upano. Éste cuerpo hídrico, junto con el río Jurumbaino han servido como límites naturales para la expansión de la ciudad, rodeando a la urbe en los costados Oeste, Sur y Este. En la parte Norte de Macas, se encuentra la cabecera parroquial de Gral. Proaño, y entre estos dos asentamientos se ha constituido un espacio de transición disperso y no planificado de construcciones y sin consideraciones como las que se pretende alcanzar en el presente estudio. Por este motivo, el área bajo análisis no solo

es el actual asentamiento de Macas, sino también la superficie circundante a esta, ya que así se puede modelar de una mejor forma y sin sesgarse a la división político – administrativa, como se muestra en la Figura 11, a continuación:

Figura 11

Mapa de ubicación de la zona de estudio.



Fuente: elaboración propia.

2.1.6 Modelos espaciales de crecimiento urbano

Son potentes herramientas que resultan de la interacción de variables internas y externas propias de cada ciudad (Linard et al., 2013), que reflejan los procesos de cambio históricos mediante la identificación de tendencias o patrones de cambio (Aguilera et al., 2010; Cantergiani y Gómez, 2016), facilitando la elaboración de posibles escenarios futuros, para analizar repercusiones ambientales y territoriales relacionadas al planeamiento urbano, la gobernabilidad y el desarrollo sostenible (Avalos et al., 2019).

El sistema urbano, al poseer características sociales y espaciales muy dinámicas, su comportamiento dinámico se convierte en una tarea compleja de estudiar. Es por ello que los modelos espaciales son fundamentales para el entendimiento de este sistema y representar espacialmente las zonas propensas a sufrir cambios en su cobertura y uso. Entre las técnicas de simulación espacial para crecimiento de ciudades se encuentran: autómatas celulares, redes neuronales, regresiones lineales, evaluación multicriterio, basados en agentes, algoritmos genéticos, entre otros.

En el presente estudio, se realizaron distintos modelos de crecimiento urbano mediante diferentes técnicas de simulación multivariable, con el uso de tres softwares (SIG) como son: Idrisi Selva, con su módulo Land Change Modeler; QGIS, con su plugin MOLUSCE; y DINAMICA EGO. En los siguientes apartados se describe cada uno de estos, los cuales fueron agrupados en dos grandes tipos en función de los modelos generados para predecir el cambio futuro, mediante: Cadenas de Markov y Autómatas Celulares.

2.1.6.1 Modelos generados mediante Cadenas de Markov

Una cadena de Markov (MC) o proceso Markoviano, constituye un modelo matemático estocástico en que el estado de un sistema está condicionado por el valor conocido del estado anterior y por la probabilidad de transición de cada estado (Eastman, 2012). El análisis con MC, comparado con técnicas de detección de cambio tradicionales, es una poderosa metodología para el estudio de procesos dinámicos complejos (Ruiz et al., 2010). Además, permite valorar magnitudes y dirección de la conmutación del fenómeno, debido a su capacidad subyacente de estimar tendencias lineales o no, dentro de un grupo de variables (Kazemzadeh et al., 2016).

2.1.6.1.1 Land Change Modeler (LCM)

Es un software incluido en Idrisi desarrollado como una herramienta de predicción de cambios de cobertura terrestre a través de datos empíricos, aplicados a diversos análisis de planificación (Eastman y Toledano, 2018). LCM basa su desarrollo en los cambios de cobertura de dos fechas anteriores, constituyendo un modelo empírico entre las transiciones de las coberturas del suelo y todas las variables explicativas consideradas para el estudio. El modelo de simulación está en función del modelo empírico y la probabilidad de cambio obtenida con una cadena de Markov. El proceso general de predicción con LCM puede resumirse en 5 pasos principales, que son (Eastman, 2012):

➤ **Análisis de cambios**

Ofrece un diagnóstico inicial de las transiciones de cambios de usos de suelo ocurridas entre los ráster de fechas distintas, que representan las ganancias y pérdidas de las diferentes coberturas del suelo en el periodo de tiempo definido. Además, ofrece datos sobre el cambio neto, las transiciones específicas y de persistencia ocurrida por cada cobertura del suelo, con una representación de los cambios mediante un ráster.

➤ **Descripción de la fuerza explicativa de las variables**

Es la fase en donde se definen las variables a intervenir en la predicción, de acuerdo a su poder explicativo. Para ello, en cada transición que se desee simular, las variables seleccionadas son aquellas que se relacionan con un patrón o tendencia espacial que explique el cambio potencial de cobertura del suelo. LCM aplica una prueba de potencial explicativo a las variables a considerar en el modelo, a través de una V de Cramer. Si bien el indicador no asegura un correcto desempeño de la variable seleccionada, es una buena forma de excluirlas, ya que si estas presentan valores

inferiores a 0.15 es motivo de descarte, mientras que valores entre 0.15 – 0.4 pueden ser consideradas, y mayores a 0.4 son buenas.

➤ Cálculo del potencial de transición

Seleccionadas las variables con valor explicativo para el modelo, se procede al cálculo del potencial de transición, donde se crean los mapas de potencial de transición. Un submodelo de transición empírico engloba una serie de estos mapas que pueden constituir una o varias transiciones con las mismas variables determinantes. Dentro de LCM se presentan tres técnicas para modelar cada submodelo de transición, que son: red neuronal mediante un perceptrón multicapa (MLP), regresión logística (LR) y aprendizaje basado en instancias ponderadas por similitud (SimWeight).

➤ Predicción espacial de cambios de cobertura

Definido el mapa de potencial de transición, el cual representa un ráster con cada celda (píxel) asignado un valor de aptitud para cambiar a una cobertura de suelo específica, o, a su vez, mantener el valor en las iteraciones realizadas. Así pues, es factible modelar la cantidad de cambio futuro en cada transición a través de una Cadena de Markov.

En LCM se presentan dos opciones de cambio: un modelo basado en predicciones duras de asignación competitiva de terreno (semejante al de una evaluación multicriterio), y otro basado en predicciones blandas, que arroja un mapa de vulnerabilidad (susceptibilidad), para conmutar por el conjunto de transiciones escogidas.

➤ Test de validación de resultados

Este último proceso es de vital importancia para la selección del modelo que mejor ajuste presente con la realidad, es decir, cuan preciso es el mapa de predicción obtenido con un mapa de

cobertura real. Para esto, LCM cuenta con una estrategia de tabulación cruzada de 3 opciones, esquematizados de la siguiente forma:

$A|B|B$ = Acierto \rightarrow el modelo simuló un cambio en el territorio y éste sí sucedió;

$A|A|B$ = Error \rightarrow el modelo simuló una permanencia en el territorio, empero, sucedió un cambio;

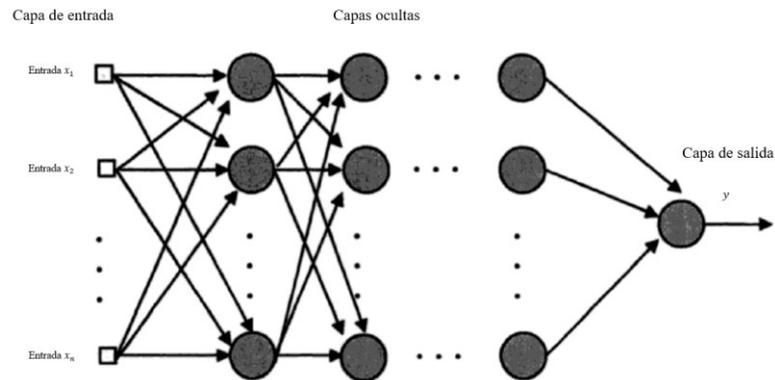
$A|B|A$ = Falsa alarma \rightarrow el modelo simuló un cambio, empero, no sucedió éste.

Para este estudio, y con el fin de encontrar el mejor resultado posible, se evaluaron las tres técnicas que presenta LCM, las mismas que se describen a continuación:

a) Red neuronal artificial de perceptrón multicapa

Una ANN (artificial neural network) es una red interconectada de unidades de procesamiento que emulan el funcionamiento de las neuronas del cerebro humano (Kazemzadeh et al., 2016); esta generalmente no es lineal, y es ideada como una función matemática compleja con la capacidad de cambiar los datos iniciales a cierto valor esperado (Pijanowski et al., 2002).

El perceptrón multicapa (o MLP derivado del inglés Multi-Layer Perceptron) en una red neuronal es el modelo más maduro y primario de LCM (Eastman y Toledano, 2018) capaz de modelar varias transiciones al mismo tiempo (Eastman, 2012). MLP es el método más común de una red neuronal (Albuquerque et al., 2005; Ozturk, 2015). MLP se basa en una capa de entrada, una o más capas ocultas y en una capa de salida (Broese y Löffler, 2004; Park et al., 2011), como se representa en la Figura 12.

Figura 12*Estructura de MLP.*

Fuente: adaptado de Albuquerque et al., (2005).

El algoritmo backpropagation es usado en MLP, el cual comprende dos partes adelante y hacia atrás (forward and backward), con el que se modifican las ponderaciones de conexión entre neuronas. Durante el entrenamiento de la red, cada entrada es alimentada de la capa de entrada y el nodo receptor (elemento calculado) realiza una sumatoria de las señales con sus respectivos pesos de los demás nodos a los que se encuentra conectada en la anterior capa (Megahed et al., 2015). La siguiente expresión representa los datos de entrada para un nodo simple ponderado (Ali Dereli, 2018):

$$net = \sum w_{ij} O_i \quad (1)$$

siendo net la entrada que es recibida por un solo nodo j ; w_{ij} son los pesos entre los nodos i, j ; O_i representa la salida del nodo i . Esta salida que resulta del nodo i se puede calcular de la siguiente forma (Kazemzadeh et al., 2016):

$$O_i = f(net_j) \quad (2)$$

donde f es una función no lineal sigmoidea ejecutada a la suma ponderada de los valores de entrada antes de que pasen a la capa siguiente.

En el caso de Idrisi, MLP en la etapa de entrenamiento analiza cada transición de los periodos de tiempo para computar los pixeles cambiados de un uso a otro. Para ello se requiere definir el tamaño de muestra de cambio y persistencia, cuyo valor por defecto es 10000 (Eastman y Toledano, 2018). Para la simulación, el potencial de transición se concibe como el nivel de activación de las neuronas salientes que significan la probabilidad de transición posterior, asumiendo un ratio de probabilidad de cambio/persistencia (Mozumder et al., 2016). Este proceso lo realiza a través de una cadena de Markov bajo la premisa que la relación de cambio se mantiene inmutable en el tiempo. Con esto, primero se obtiene una tabulación cruzada de todas las transiciones entre los ráster de cada época, y a continuación, se calcula la matriz de probabilidad de transición de la forma (Kemeny y Snell, 1976):

$$A = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ \dots & \dots & \dots \\ \dots & \dots & \dots \\ a_{n1} & a_{n2} & a_{n3} \end{pmatrix} \quad (3)$$

donde A es la superficie cambiada de un estado a otro durante el periodo de tiempo y n representa el total de clases de cobertura del suelo. En cuanto a la validación, MLP reserva la mitad de los datos del entrenamiento para este fin. Tanto la precisión como la habilidad del modelo sobre las persistencias y transiciones combinadas, son mostradas mediante un Puntaje de Habilidad de Heidke, o denominado también Kappa (Cohen, 1960), cuyos valores se encuentran en el rango de -1 a +1, donde 0 sugiere una habilidad (precisión) igual a una asignación aleatoria.

b) Regresión Logística

Este método es incluido en LCM más por proporcionar una gama de alternativas para el usuario, principalmente por razones de investigación (Eastman y Toledano, 2018). El modelo de regresión logística (LR) es relacionado al crecimiento urbano y a las variables (o fuerzas) conductoras para generar una superficie de probabilidad del crecimiento urbano (Achmad et al.,

2015). LR trabaja con una naturaleza de cambio dicotómica (Park et al., 2011), siendo 1 y 0 el valor que representa la existencia o no de la conversión de cobertura respectivamente (Hu y Lo, 2007).

A diferencia de MLP y SimWeight, LR no es un proceso de aprendizaje automático, sino que basa su probabilidad de cambio de una clase a otra siguiendo una curva logística (4) (Kleinbaum, 1994), usando la técnica de máxima verosimilitud (Hamdy et al., 2017), y luego esta probabilidad acumulada de las transiciones de un pixel puede predecirse con el modelo LogReg expresado matemáticamente en (6) (Mozumder et al., 2016).

$$f(z) = \frac{1}{1 + e^{-z}} \quad (4)$$

siendo f la probabilidad que ocurra el cambio y z es la combinación lineal de las variables incluidas en el modelo. Esta combinación lineal puede expresarse de la siguiente forma:

$$z = b_0 + b_1x_1 + b_2x_2 + b_3x_3 + b_4x_4 + \dots + b_nx_n \quad (5)$$

con b_0 como valor del intercepto, $b_i = (i = 0,1,2,3, \dots, n)$ son los coeficientes de la regresión, $x_i = (i = 0,1,2,3, \dots, n)$ representan a las variables independientes del modelo.

$$P(Y = 1|X_1, X_2, \dots, X_k) = \frac{1}{1 + e^{-(\alpha + \sum_{i=1}^k \beta_i X_i)}} \quad (6)$$

donde $P(Y = 1|X_1, X_2, \dots, X_k|)$ es la probabilidad que la variable dependiente Y cambie (es decir, $Y = 1$ dado X_1, X_2, \dots, X_k); X_i son las variables independientes o fuerzas conductoras del cambio; β_i corresponde a los coeficientes para cada variable X_i .

A diferencia de los otros métodos de LCM, LR puede solo modelar una transición a la vez (Eastman, 2012), cuyas muestras para el entrenamiento son escogidas de forma proporcional al número relativo de persistencia/cambio. Por defecto esta proporción es del 10% y se aplica el muestreo aleatorio estratificado o sistemático. En la etapa de simulación, el potencial de transición

se asume como la probabilidad de cambio de forma similar a la cantidad convertida en el periodo de tiempo analizado, y usa las cadenas de Markov para su estimación futura, al igual que en MLP. Finalmente, en la validación del modelo utiliza una medida de Bondad de Ajuste que simboliza el nivel de semejanza entre los valores de la regresión con los del entrenamiento (Eastman y Toledano, 2018).

c) SimWeight

Al igual que MLP, es un método de aprendizaje automatizado, que utiliza una variación del algoritmo K-nearest neighbor (Sangermano et al., 2010). SimWeight basa su cálculo en la obtención de distancias ponderadas en espacio/variable bajo circunstancias conocidas para cada cobertura (clase) (Mozumder et al., 2016). Para la generación de potenciales de transición, se necesita contener dos clases (cambio y persistencia). En cada celda evaluada, el método extrae los K vecinos cercanos para posteriormente computar la distancia en espacio/variable desde las posiciones no conocidas a las instancias de cambio dentro del rango de K (Bununu, 2017).

Para obtener el valor de distancia se usa una función de ponderación exponencial con la que se puede calcular un mapa continuo de pertenencia a cada clase de la forma (Sangermano et al., 2010):

$$M_{change} = \frac{\sum_{i=1}^c \left(1 - \frac{1}{1 + e^{1/d_i}}\right)}{k} \quad (c \leq k) \quad (7)$$

siendo k la cantidad de píxeles más cercanos a una celda, c representa el número de píxeles que cambiaron en el rango de k , d_i es la distancia a una instancia de cambio i . Además, se puede determinar la representatividad de cada peso de las variables al comparar la desviación estándar (SD) de la variable dentro del área que ha conmutado con la SD de la misma variable respecto a el área completa de análisis, que se expresa de la siguiente manera (Sangermano et al., 2010):

$$R_{\text{peso}} = 1 - \frac{SD \text{ \u00e1rea cambiada}}{SD \text{ \u00e1rea total}} \quad (8)$$

Si la SD de la variable dentro de las celdas que conmutaron es m\u00e1s peque\u00f1a que la regi\u00f3n de an\u00e1lisis, esta es relevante para discriminar el cambio, por ende, tendr\u00e1 mayor peso en el modelo, y viceversa (Zubair et al., 2017).

Por su parte, dentro de LCM el modelo toma un tama\u00f1o de muestreo equitativo para el cambio y persistencia, similar a MLP, pero con una cantidad de 1000 por defecto. Esta diferencia se debe a que MLP es un m\u00e9todo iterativo de aprendizaje mientras que SimWeight se trata de una caracterizaci\u00f3n (Eastman y Toledano, 2018). La simulaci\u00f3n, al igual que los modelos antes mencionados, se basa en cadenas de Markov, con unidades del potencial de transici\u00f3n adimensionales. En la \u00faltima etapa, el 50% de las entradas son apartadas para la validaci\u00f3n, usando como indicador el Puntaje de Habilidad de Peirce, que trabaja de forma similar que el Puntaje de Habilidad de Heidke (Eastman, 2012).

2.1.6.2 Modelos generados mediante Aut\u00f3matas Celulares

Un sistema de aut\u00f3matas celulares (CA), consiste en una grilla simple – regular de p\u00edxeles en un n\u00famero finito de estados posibles, y que dependen a su vez del anterior estado de los p\u00edxeles que se encuentran circunscritos en un vecindario (Mitsova et al., 2011), el cual se actualiza con cada paso discreto de tiempo en funci\u00f3n de ciertas reglas para su transici\u00f3n (Torrens y O’Sullivan, 2001).

A pesar de su relativa simple definici\u00f3n, es una herramienta capaz de reproducir diversas din\u00e1micas complejas (Li y Yeh, 2002), que han sido ampliamente utilizadas tanto en diversas tem\u00e1ticas de la planificaci\u00f3n territorial, como en urbanizaci\u00f3n a escala regional (Geertman et al., 2007), din\u00e1micas del uso de la tierra (Almeida et al., 2003), simulaci\u00f3n de crecimiento urbano (Barredo et al., 2004), entre otros.

2.1.6.2.1 DINAMICA EGO

DINAMICA EGO (Environment for Geoprocessing Objects), es un software libre escrito en lenguaje C++ y Java con gran capacidad para diseñar modelos espaciales muy simples hasta dinámicos muy complejo (como el CCUS) (Soares et al., 2002) a través de autómatas celulares, de modelos estadísticos y de agentes para generar cambios en tendencias espaciales (Khatibi et al., 2018). Al ser una plataforma híbrida, facilita a los modelos estadísticos hallar zonas con potencial cambio en función de factores conductores y, también, permite la selección de las funciones de transición de CA para simular dichos patrones (Almeida et al., 2003).

Con este software el usuario puede crear sus propios modelos a través de una serie de algoritmos llamados "functors", los cuales se pueden exportar a otros softwares libres como R studio para aprovechar el potencial estadístico de R con el rendimiento de DINAMICA (Rodrigues y Soares, 2018). El procesamiento en DINAMICA EGO se puede dividir en 6 pasos principales, que son los siguientes:

➤ Obtención de matrices de transición

En esta primera fase, se calcula la cantidad de cambio (número de píxeles) que pasaron de un estado a otro (cobertura del suelo) en el periodo de tiempo analizado. Esta matriz de transición es susceptible a modificación de acuerdo a los objetivos del modelo (Soares et al., 2001). De la matriz se producen dos resultados a considerar: 1) tasa de transición bruta, representa la cantidad de cambio en unidades de superficie; 2) tasa de transición neta, indican el porcentaje de cambio entre periodos de tiempo, al dividir la tasa neta sobre la superficie de la cobertura anterior al cambio dado (Soares et al., 2013). Esto se representa matemáticamente en (9), donde el valor de una variable cualesquiera es la sumatoria de los porcentajes fijos de las otras variables del modelo en el anterior periodo; el porcentaje de píxeles que pasaron de un estado i a j se representa con P_{ij} .

El software modela solo los cambios ocurridos, por lo que no es necesario especificar la diagonal de la matriz, mientras que sus columnas deben sumar la unidad. Finalmente, las matrices resultantes constituyen las tasas de transición para cada tiempo transcurrido, o referidas a una unidad de tiempo del periodo completo (matriz simple y múltiple respectivamente) (Soares et al., 2009).

$$\begin{bmatrix} 1 \\ 2 \\ 3 \\ \vdots \\ j \end{bmatrix}_{t=v} = \begin{bmatrix} P_{11} & P_{21} & P_{31} & \cdots & P_{i1} \\ P_{12} & P_{22} & P_{32} & \cdots & P_{i2} \\ P_{13} & P_{23} & P_{33} & \cdots & P_{i3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ P_{1j} & P_{2j} & P_{3j} & \cdots & P_{ij} \end{bmatrix} * \begin{bmatrix} 1 \\ 2 \\ 3 \\ \vdots \\ j \end{bmatrix}_{t=0} \quad (9)$$

➤ Cálculo de rangos para categorizar variables y coeficientes de pesos de evidencia

Los pesos de evidencia es un método bayesiano incorporado en DINAMICA, según la metodología propuesta por Goodacre et al., (1993) y Bonham (1994), para generar mapas (ráster) de las áreas con mayor probabilidad de transición.

El método se basa en que el resultado de cada variable sobre una transición dada, se computa de forma independiente del resto. Para ello, se convierte a categóricas las variables que son continuas, evitando así alterar la estructura del dato; un delta mínimo (D_x) es definido para producir n incrementos (N_x) y así obtener de X_{min} a $X_{min} + n * D_x$ intervalos. También es necesario establecer la cantidad de pixeles incluidos en un incremento (representados con A_n) múltiplo de n , mientras que d_n simboliza el total de ocurrencias del fenómeno analizado (D) al interior del incremento (Soares et al., 2009). Finalmente, se calculan las cantidades para W^+ , C y S^2 de cada incremento con las siguientes fórmulas:

$$\ln\{D|B\} = \ln\{D\} + W^+ \quad (10)$$

$$W^- = \ln\left(\frac{P\{\bar{B}|D\}}{P\{\bar{B}|\bar{D}\}}\right) \quad (11)$$

$$C = W^+ - W^- \quad (12)$$

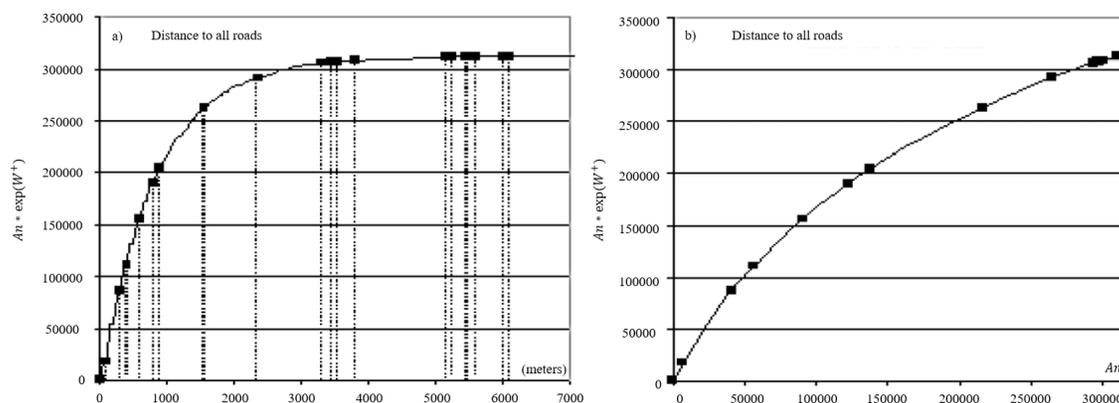
$$S^2 = \frac{1}{\text{Area}(B \cap D)} + \frac{1}{\text{Area}(B \cap \bar{D})} + \frac{1}{\text{Area}(\bar{B} \cap D)} + \frac{1}{\text{Area}(\bar{B} \cap \bar{D})} \quad (13)$$

siendo W^+ , W^- los pesos de evidencia positivo y negativo de un evento D según una tendencia espacial B ; \bar{B} representa la no presencia de B ; C es el contraste que define la correlación espacial global entre B y D , la cual si $|C| > 1.96 S(C)$ al 95% de confianza se considera significativo estadísticamente (Soares et al., 2009).

A partir de esto, es factible graficar un grupo de valores A_n vs $A_n * \exp(W^+)$ cuyos puntos de ruptura están definidos con un algoritmo de generalización de líneas que requiere tres determinaciones: distancia mayor del rango sobre X , ($\max d_x$); distancia menor del rango sobre X , ($\min d_x$); tolerancia angular (ft). Además, para una distancia (d_x) entre dos puntos localizados sobre x , es decir, entre $\min d_x$ y $\max d_x$, el programa coloca otro punto de ruptura (breaking point) siempre y cuando se cumpla con $d_x > \max d_x$, o al momento en que la tolerancia angular es superada (Soares et al., 2002). En la Figura 13, se muestra lo antes mencionado.

Figura 13

A_n vs $A_n * \exp(W^+)$ de distancia a todas las vías (en metros) para definir puntos de ruptura (a); A_n vs $A_n * \exp(W^+)$ de distancia a todas las vías (b).



Fuente: adaptado de Soares et al., (2009).

Si se obtienen pesos de evidencia negativos significa que la categoría impide el cambio de un estado al otro, y si son positivos, lo contrario. Los valores de los pesos obtenidos en primera instancia con (10) y (11) pueden ser optimizados bajo consideración del criterio experto, mejorando el grado de confiabilidad en los modelos de simulación, como por ejemplo con la aplicación de algoritmos genéticos (Soares et al., 2013).

➤ Diagnóstico de correlación espacial

Una de las premisas al trabajar con pesos de evidencias, es que todas las variables que forman parte del estudio sean espacialmente independientes, para lo cual es necesario computar ciertos indicadores que confirmen lo mencionado. DINAMICA incluye una serie de indicadores (Chi cuadrada, Cramer, Contingencia y Entropía conjunta), de los cuales se escogió Cramer (para comparar con el resto de modelos generados en los otros softwares), que trabaja en un intervalo de 0 – 1, donde 1 representa una alta correlación y por ende se deberá descartar una variable del par comparado. Si bien no hay un umbral exacto para descartar una variable, es aconsejable que no se supere el 0.5 (Silvestrini et al., 2011).

➤ Cómputo de la probabilidad de transición

El cambio de un estado a otro de un píxel ocurre en aquellos con una probabilidad de transición más alta; ésta es calculada a través de los pesos de evidencia mediante la siguiente expresión (Soares et al., 2009; Silvestrini et al., 2011):

$$P\{i \Rightarrow j | B \cap C \cap D \dots \cap N\} = \frac{e^{\sum W^+}}{1 + e^{\sum W^+}} \quad (14)$$

Lo que se obtiene con (14) es la probabilidad de que ocurra una transición de un estado inicial (i) a uno final (j), bajo la presencia de un grupo de variables (B, C, D, \dots, N) en cada píxel analizado (Soares et al., 2009).

➤ Predicción de cambios

En esta etapa, se ejecuta el proceso iterativo en función del periodo de tiempo analizado. Para ello, el software usa dos functors especializados (autómatas celulares locales) para la predicción, *Expander* y *Patcher*. El primero se encarga de expandir o contraer parches ya existentes de una cobertura (clase), mientras el segundo genera parches nuevos mediante un mecanismo de semilla y testea pixeles aledaños al lugar seleccionado en la transición (Berberoğlu et al., 2016).

Es necesario especificar el ratio entre estos dos functors y otros parámetros sobre la geometría del parche como son: tamaño medio del parche, variancia e isometría, que en conjunto permiten una mejora en el patrón de distribución espacial de coberturas del territorio (Malek et al., 2015). Un aumento en el tamaño promedio del parche y su varianza repercute en un paisaje más heterogéneo y menos fragmentado (Mas et al., 2013).

Si bien no hay una forma de obtener el valor exacto de estos parámetros, es factible calcular valores próximos a través de indicadores del paisaje como el índice de cohesión, la dimensión fractal y la distancia vecino cercano, los mismos que tienen una relación con los parámetros descritos (Soares et al., 2003), y que se presentan a continuación:

- Índice de cohesión

Representa el grado en que está fragmentado el paisaje según la clase y, por ende, la conectividad de esta. Valores altos, señalan una fragmentación menor, y viceversa. Se expresa matemáticamente como sigue:

$$Cohesión = \left[1 - \frac{\sum_{i=1}^m \sum_{j=1}^n p_{ij}^*}{\sum_{i=1}^m \sum_{j=1}^n p_{ij}^* \sqrt{a_{ij}^*}} \right] * \left[1 - \frac{1}{\sqrt{Z}} \right]^{-1} * 100 \quad (15)$$

donde p_{ij}^* representa al perímetro del parche, Z es la cantidad total de pixeles en el paisaje, a_{ij}^* significa el área que ocupa en función de la cantidad de pixeles (Mcgarical y Marks, 1995).

- Dimensión fractal

Este indicador está relacionado con la complejidad del parche; su valor varía en un intervalo de 1 – 2, donde 1 representa una morfología con perímetros muy simple, y se complejiza a razón de aumentar a 2. Se calcula con la siguiente expresión:

$$FRACT = \frac{2 \ln(0.25 p_{ij})}{\ln(a_{ij})} \quad (16)$$

donde p_{ij} es el perímetro del parche medido en metros y a_{ij} es el área del parche calculada en metros cuadrados (Mcgarical y Marks, 1995).

- Vecino cercano

El valor de distancia al vecino más cercano representa cuan disperso o aislado se encuentra el parche respecto de otro de su misma clase; para su cálculo se consideran los bordes de los parches, y se puede expresar de la forma siguiente:

$$MNN = \frac{\sum_{j=1}^{n'_i} h_{ij}}{n'_i} \quad (17)$$

donde h_{ij} es la distancia al vecino más cercano de la misma clase (medida en metros), y n'_i representa el número de parches de igual clase (Mcgarical y Marks, 1995).

➤ Validación del modelo

Para esta fase, el software emplea los índices de similitud difusa para cada superficie de cambio, obteniendo dos de estas: la primera resulta de confrontar el modelo simulado con el mapa inicial (m1), y el segundo, en cambio, contrapone el mapa original con el mapa inicial (m2) (Soares et al., 2009). Posteriormente, se determina la similitud espacial entre ambos mapas m1 y m2 bajo distintos tamaños de ventana o grados de tolerancia, de esta forma se clasifican los pixeles aledaños al ponderar la distribución y distancia de los pixeles circundantes al analizado (Gounaridis et al., 2018).

Esta vecindad de píxeles es tratada con funciones de decaimiento de dos formas. La primera usa una función de decaimiento exponencial y un tamaño fijo de ventana, mientras que la segunda emplea una función de decaimiento constante y múltiples ventanas (logrando una ponderación de 1 para el total de píxeles incluidos en la ventana) (De Oliveira et al., 2020). Además, se debe considerar una ventana en cantidades impares con el fin de que en el centro se ubique el píxel analizado (Leija et al., 2016). Dos son los valores de similitud que resultan de la anterior comparación (m_1 vs m_2 y viceversa), los cuales escogiendo el porcentaje menor se garantiza no sobredimensionar un posible ajuste imaginariamente alto. Por lo tanto, un valor del 50% o más de similitud en la validación se considera un modelamiento correcto (Troupin y Carme, 2018).

2.1.6.2.2 MOLUSCE

MOLUSCE son las siglas en inglés de Modules for Land Use Change Evaluation, es un complemento desarrollado por la compañía Asia Air Survey (AAS) y que se encuentra de forma gratuita para el software QGIS desde la versión 2.0 en adelante. MOLUSCE permite el modelamiento de fenómenos dinámicos complejos, por lo que puede ser utilizado en CCUS, crecimiento urbano, entre otras aplicaciones (Perović et al., 2018).

El procesamiento con MOLUSCE consta de seis ventanas que son: interfaz de ingreso de datos (mapas de dos periodos de tiempo y variables explicativas), evaluación de la correlación, cálculo de matriz de transición, modelo de entrenamiento del potencial de transición, simulación con autómatas celulares, y validación. Estas subetapas se pueden resumir en cuatro principales, que son descritas a continuación:

➤ **Análisis de los datos**

El software aplica índices para determinar que los datos no estén correlacionados espacialmente. Para ello, presenta tres tipos de indicadores como el Coeficiente de Pearson, el

Coefficiente de Cramer y la Incertidumbre conjunta de información (en este caso se usó Cramer para verificar la condición de independencia espacial). Este es un paso fundamental, sobre todo si se trabaja con LR y MLP; por lo que internamente se realiza una normalización de los datos (que permite alcanzar un mejor entrenamiento y simulación), de la siguiente forma (NextGIS, 2013):

$$X_n = \frac{X - m_x}{\sigma_x} \quad (18)$$

siendo X_n la variable normalizada, X la variable original, m_x la media del valor de la variable sin normalizar, σ_x la desviación estándar de dicha variable. Posterior a esto, se calcula la matriz de transición para cada categoría o clase que contenga el mapa inicial, así como las cantidades en porcentaje de los cambios sufridos en el periodo de estudio.

➤ Cálculo del potencial de transición

Para este paso, MOLUSCE incluye cuatro tipos de métodos que son: red neuronal artificial (con MLP), evaluación multicriterio (MCE), regresión logística (LR) y pesos de evidencia (WoE). El software trabaja con un algoritmo de vecindario Moore para la selección de las celdas que se incluyen en el entrenamiento, donde además en el caso de redes neuronales se especifican los parámetros de ratio de aprendizaje, número de iteraciones, capas ocultas y el momentum (NextGIS, 2013). En este apartado, y por los motivos que serán justificados en el capítulo de metodología y resultados, se procede a describir el fundamento matemático únicamente del modelo con redes neuronales.

El algoritmo backpropagation es implementado en redes neuronales, usando un perceptrón multicapa con una función sigmoïdal, con la que se crea una red del siguiente tipo:

$$M = (C - 1)(2N + 1)^2 + B(2N + 1)^2 \quad (19)$$

donde M representa a la neuronas de salida, $(C - 1)(2N + 1)^2 + B(2N + 1)^2$ las neuronas de entrada, siendo C el número de clases de suelo, N el vecindario de búsqueda, B es la

cantidad de bandas del ráster de factores. Por otro lado, la corrección de las ponderaciones con backpropagation están dadas por:

$$w(n + 1) = r * d_w(n) + m * d_w(n - 1) \quad (20)$$

en que w es el vector propio de los pesos, d_w representa al vector de ponderaciones que cambió, n es el número de iteraciones en el entrenamiento, m simboliza el momentum y r el ratio de aprendizaje de la red neuronal. MLP selecciona de forma aleatoria el 20% de las muestras para la validación y el 80% para su entrenamiento, con un error de ajuste que es expresado matemáticamente como sigue (NextGIS, 2013):

$$E = \frac{t_i - o_i}{d} \quad (21)$$

donde E es error del muestreo realizado, o_i representa los valores reales de los productos de la neurona, t_i es el valor objeto de cada neurona saliente de la muestra escogida.

➤ Simulación

El software usa para este propósito una autómeta celular basada en el modelo Monte Carlo (Rahman et al., 2017), con el que realiza la simulación en base al modelo usado para computar el potencial de transición (en este caso MLP), y genera como resultados tres ráster que corresponden al potencial de transición, la diferencia encontrada entre los potenciales más grandes y el de simulación.

➤ Validación del modelo

Para validar el modelo resultante, el software ofrece tres tipos de indicadores, destacándose el conjunto de estadísticos Kappa, representados con las siguientes ecuaciones (Gantumur et al., 2020):

$$K = \frac{P(A) - P(E)}{1 - P(E)} \quad (22)$$

$$K_{loc} = \frac{P(A) - P(E)}{P_{max} - P(E)} \quad (23)$$

$$K_{hist} = \frac{P_{max} - P(E)}{1 - P(E)} \quad (24)$$

$$P(A) = \sum_{i=1}^c p_{ij} \quad (25)$$

$$P(E) = \sum_{i=1}^c p_{iT} p_{jT} \quad (26)$$

$$P_{max} = \sum_{i=1}^c \min(p_{iT} p_{jT}) \quad (27)$$

siendo p_{ij} correspondiente a la i, j –ésimo píxel de la tabla de contingencia; p_{iT} representa la sumatoria del total de pixeles de la i –ésima fila; p_{jT} simboliza la sumatoria del total de pixeles de la j –ésima columna; c describe la cantidad de clases en el mapa. Además, K significa la exactitud general del modelamiento, K_{loc} representa la capacidad de la predicción para reconocer una ubicación idéntica, K_{hist} es la distribución de frecuencias en que se identificó correctamente una clase. Por lo tanto, a mayor porcentaje de coeficiente Kappa, mejor ajuste del modelo (Aneesha et al., 2020).

2.1.7 Análisis normativo de la planificación territorial y urbana en Ecuador

Es necesario entender el marco legal actual del Ecuador en materia de ordenamiento territorial, para poder relacionar de forma pragmática con los resultados de esta investigación. Para ello, se presenta de manera resumida las normativas que se vinculan con la temática abordada en el estudio.

2.1.7.1 Marco nacional

A raíz de la aprobación de la Constitución de Montecristi en 2008, Ecuador dio un paso hacia la institucionalización de la planificación (y por ende la ordenación del territorio) como parte

fundamental del Estado, constando en los principios generales de la Organización Territorial del Estado y del Régimen de Desarrollo (Título V y VI respectivamente). A pesar de esto, todavía queda un largo camino por recorrer en cuanto a la metodología e instrumentos necesarios para su aplicación (Pauta, 2013).

Como Estado, el país inició en la planificación con Junta Nacional de Planificación y Coordinación Económica (JUNAPLA) en 1954. Posteriormente en 1979, se convirtió en el Consejo Nacional de Desarrollo (CONADE), para luego ser remplazada en 1998 por la Oficina de Planificación (ODEPLAN). Ya en 2004, se creó por primera vez la Secretaría Nacional de Planificación y Desarrollo (SENPLANDES), que se mantuvo hasta el 2019 cuando se cambió a la actual Secretaría Técnica Planifica Ecuador (STPE). Antes de ser aprobada la Constitución del 2008, la ordenación territorial estuvo enmarcada en la antigua Ley Orgánica de Régimen Municipal (con incidencia fuerte sobre la planificación física del territorio, mediante los Planes Reguladores de Desarrollo Físico Cantonal), y que luego pasó a cargo del Ministerio de Ambiente en la anterior Carta Magna de 1998 con la Ley de Gestión Ambiental y su Plan Nacional de Ordenamiento Territorial, que orientaba la planificación como un instrumento para la gestión ambiental.

A continuación, se presenta un resumen de los principales artículos que están relacionados con el ordenamiento territorial en el Ecuador (centrándose en la parte cantonal, ya que le compete la gestión del uso y ocupación del suelo y que es de importancia más adelante para uno de los objetivos de este estudio), en los principales cuerpos legales (en esta temática), existentes hasta la fecha, como son la Constitución, el Código Orgánico de Organización Territorial, Autonomía y Descentralización (COOTAD), y el Código Orgánico de Planificación y Finanzas Públicas

(COPFP), ambos entrados en vigencia desde el 2010. De la LOOTUGS no se abordará en este apartado, debido a que en el siguiente punto, se describirá más a fondo esta ley.

- Constitución de la República del Ecuador

El Art. 241: menciona que la planificación es vinculante para todos los niveles de gobierno, y ésta garantizará la ordenación del territorio.

Art. 264: señala que es competencia exclusiva de las municipalidades: 1) planificar, en articulación con los demás niveles de gobierno, el desarrollo de su territorio y la formulación de sus planes de ordenamiento territorial, y 2) el control sobre el uso y ocupación del suelo cantonal.

Art. 275: cita que, (...) la planificación propiciará la equidad territorial y social (...).

Art. 276: apunta que el régimen de desarrollo tiene entre uno de sus objetivos fomentar una ordenación del territorio (...) integrando actividades económicas, socioculturales, administrativas y de gestión (...).

- COOTAD

Art. 54, literal e: menciona que una de las funciones del GAD cantonal, es elaborar su plan de desarrollo, el de ordenación territorial (...), de forma articulada con los demás niveles de gobierno, realizando periódicamente un seguimiento y rendición de cuentas (...).

Art. 55, literal a: enuncia como competencia exclusiva de las municipalidades, el planificar en conjunto con actores del territorio el desarrollo cantonal y sus respectivos planes de ordenamiento, coordinando entre los niveles de gobierno, para regular el uso y ocupación del suelo (...); literal b: controlar la ocupación y uso del suelo cantonal.

Art. 296: propicia la definición de ordenamiento territorial y recalca que la ordenación del territorio debe ser articulada entre todos los niveles de gobierno.

Art. 297: cita que los objetivos del planeamiento territorial se enmarcan en el a) establecimiento de estrategias territoriales de uso, manejo y ocupación del suelo, b) adopción y estructuración de procedimientos e instrumentos de planificación y gestión para facilitar las actuaciones integrales y coordinar las sectoriales, y c) determinación de programas y proyectos en su jurisdicción.

Art. 299: dictamina que tanto el gobierno central y los demás GAD, deben obligatoriamente articular la realización, contenido y ejecución de sus respectivos planes (nacional y los regionales, provinciales, cantonales, parroquiales, respectivamente), (...).

- COPFP

Art. 1: el objetivo de éste código es el de regular (...) las competencias de planificación (...) en los niveles de gobierno del Estado.

Art. 9: habla de la “planificación del desarrollo” como una forma de garantizar la ordenación del territorio, en concordancia con el Art. 241 de la constitución.

Art.12: enuncia que los GAD tiene la competencia de planificar el desarrollo y la ordenación de su territorio a través de planes y otros instrumentos.

Art. 13: recalca sobre la participación de la ciudadanía en la elaboración de los planes y políticas públicas.

Art. 36: menciona que dentro del Plan Nacional de Desarrollo (PND), se incorporan (punto 6) los lineamientos de planeamiento del territorio, que no es más que la Estrategia Territorial Nacional (ETN).

Art. 41: señala que los “planes de desarrollo” de los diversos GAD (...) poseerán una visión a largo plazo, aplicadas en el marco de sus competencias (Art. 55 del COOTAD).

Art.42: describe los contenidos mínimos que deben contar en los planes de desarrollo de los GAD, siendo estos: diagnóstico del territorio, propuesta y modelo de gestión.

Art. 43: cita que los instrumentos para la planificación del desarrollo son los planes de ordenamiento territorial. Además, define el objeto de estos planes.

Art. 44: enuncia en varios literales las disposiciones generales acerca de los planes de ordenación del territorio de los GAD, los que a nivel cantonal regularán mediante sus planes de ordenación territorial, la ocupación y uso del suelo (literal b), así como la articulación multinivel (literal a y c).

Art. 48: sobre la vigencia de los PDOT, señala que su vigencia es a partir de su expedición (...), y que de forma obligada cada GAD deberá (...) actualizar su plan al comienzo de una nueva gestión.

Art. 49: los PDOT son los referentes para la elaboración de instrumentos de gestión, presupuestos e inversiones de cada GAD.

Art. 50: dictamina que cada GAD debe dar seguimiento y evaluación periódica de las metas estipuladas en sus PDOT.

2.1.7.2 Ley Orgánica de Ordenamiento Territorial, Uso y Gestión de Suelo (LOOTUGS)

La LOOTUGS es la ley por excelencia del ordenamiento territorial en el Ecuador, la misma que se encuentra vigente desde el 2016, y su reglamento desde 2019. En esta se encuentran los instrumentos y directrices para llevar a cabo la actualización del PDOT para el período 2019 – 2023 en el país, sumando como punto más álgido la incorporación de un nuevo instrumento denominado “Plan de Uso y Gestión del Suelo” (PUGS).

En los primeros apartados de la ley, se presenta la definición del ordenamiento territorial, seguido del objeto de esta en el Ecuador (Art. 9 y 10 respectivamente). Además, como se

puntualiza en el Art. 12 (tercer párrafo), los PDOT (y sus planes complementarios) son los instrumentos que aplican al planeamiento del territorio en los GAD (regionales, provinciales, cantonal, parroquiales). Sin embargo, como se presenta en el siguiente apartado, lo que es de relevancia para el estudio se encuentra en los artículos del Título II Capítulo I y Título III Capítulo I de la LOOTUGS.

2.1.7.3 Clasificación y subclasificación del suelo

La LOOTUGS en su Art. 11, párrafo 3 sobre los GAD cantonales menciona que el suelo se clasificará en urbano y rural. La subclasificación del suelo urbano se encuentra en el Art. 18 que lo separa en 3 tipos:

- Suelo urbano consolidado,
- Suelo urbano no consolidado,
- Suelo urbano de protección.

Por su parte, en el Art. 19 del mismo cuerpo legal, divide al suelo rural en 4 tipos, que son:

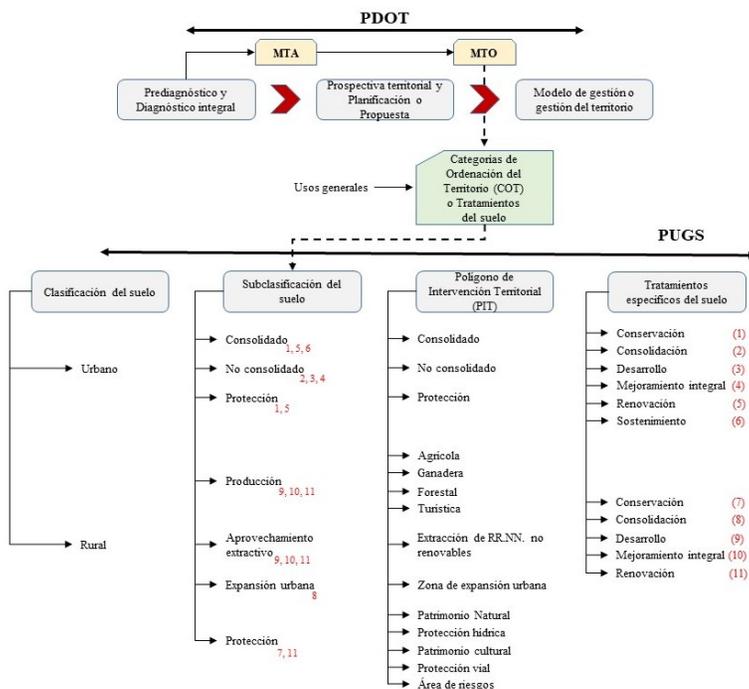
- Suelo rural de producción,
- Suelo rural de aprovechamiento extractivo,
- Suelo rural de expansión urbana,
- Suelo rural de protección.

De esta subclasificación dada por ley, el suelo rural de expansión urbana es el que tiene relación para los fines de este estudio, debido a que su determinación está en función del crecimiento demográfico, social, económico y productivo del cantón (Asamblea Nacional, 2016). También es importante señalar que, su inclusión en el PUGS, condiciona a un tratamiento urbanístico de este suelo con el fin de mejorar, consolidar o desarrollar su urbanización (como se dicta en el Art. 42). Esto último tiene relación con lo citado en el Art. 376 de la Constitución,

donde señala que las municipalidades pueden reservar zonas para el futuro desarrollo y cumplir con el derecho a una vivienda digna (ver Figura 14).

Figura 14

Relación entre PDOT y PUGS acorde a la normativa ecuatoriana.



Fuente: elaboración propia.

2.1.7.4 Marco cantonal

En el territorio del cantón Morona, se han desarrollado 3 planes de ordenamiento territorial (ver sección 2.2.5.3.) y a la fecha de este estudio, se está realizando la actualización del nuevo PDOT para el periodo 2019 – 2023. Todos estos planes, y conforme a la normativa vigente, se orientan hacia una ordenación a escala municipal, y de estos (en principio) se derivarían planes complementarios (en el caso de los PDOT), y planes parciales (en el caso de los PUGS) que se centran de forma más específica a la planeación urbana.

Si se consideran únicamente a los PDOT anteriores, se abarca muy pocas características de planeación urbanística, por su obvia escala de planificación. Un documento más específico, en

cuanto a la descripción y zonificación del área urbana de Macas, es el Plan de Actualización de Uso y Ocupación del Suelo (PAUOS) elaborado en 2016, y aprobado mediante ordenanza recién en el 2019 (GAD Morona, 2019). En este documento se procedió a retomar las zonas de planificación definidas en el PDOT 2004, pero definiendo nuevos usos, retiros, tipología de predios (frente, fondo, tamaño mínimo), altura de pisos permitidos, coeficiente de ocupación y utilización del suelo (COS y CUS respectivamente), así como la delimitación del área urbana consolidada y no consolidada (GAD Morona, 2016).

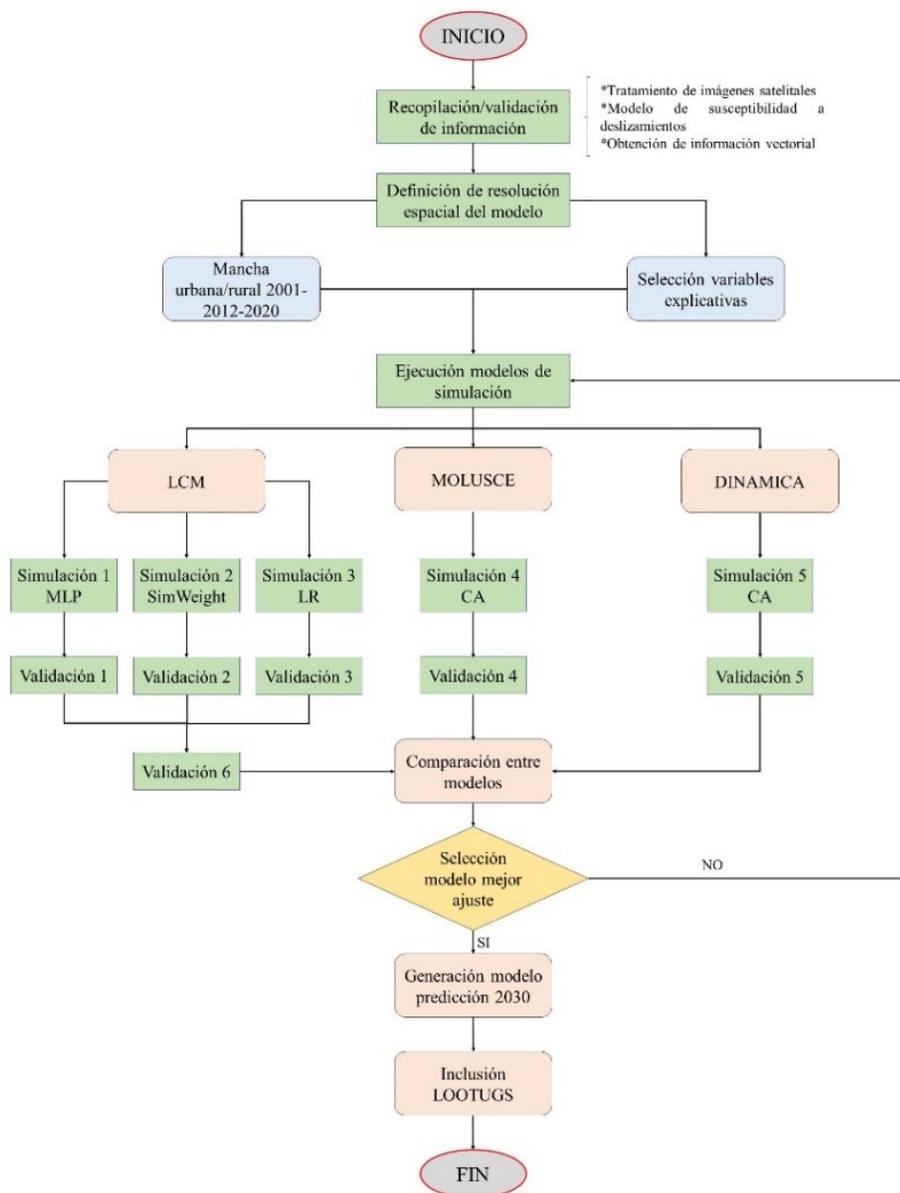
Esta ordenanza (donde aprueba el PAUOS), es la que rige actualmente la “planificación” del área urbana de la ciudad de Macas, siguiendo los lineamientos de uso general y específicos (complementario, restringido, prohibido) que indica la LOOTUGS en sus artículos 22 y 23 respectivamente, y como lo señala en la ordenanza de dicho plan en los artículos 7 y 8.

Capítulo III: Metodología

La metodología seguida en este estudio se resume en el siguiente flujograma de la Figura 15.

Figura 15

Flujograma de trabajo para la generación del modelo de crecimiento urbano de Macas.



Fuente: elaboración propia.

3.1 Generación y tratamiento de información geográfica

Al no existir una base de datos municipal de periodos anteriores sobre la mancha urbana de la ciudad, salvo la del 2019, ha sido necesario la generación y tratamiento de información propia para el estudio. Los pasos a continuación describen el proceso de obtención de los insumos para el modelamiento de crecimiento tendencial urbano, que partieron de la información base desglosada en la Tabla 2:

Tabla 2

Desglosamiento de insumos de partida usados el estudio.

Insumo	Fuente	Año del insumo
Imagen satelital ASTER	Página de la USGS	2001
Imagen satelital Sentinel 2A	Página de Copernicus	2020
Ortofotografía	GAD Morona (Programa SIGTIERRAS)	2012
Vías	GAD Morona	2019
Edificaciones	GAD Morona	2019
Centros educativos	Sistema Nacional de Información –SIN– (Ministerio de Educación)	2014
Centros de salud	Sistema Nacional de Información –SIN– (Ministerio de Salud Pública)	2016
Cuerpos de agua	Geoportal del Instituto Geográfico Militar (IGM)	2013
Pendientes	MDT del Programa SIGTIERRAS	2012
Mercados, espacios recreativos, relleno sanitario, terminal	GAD Morona	2020
Susceptibilidad a deslizamientos	Modelo propio	2020

Fuente: elaboración propia.

3.1.1 Tratamiento de imágenes satelitales

En todo trabajo con imágenes satelitales, es imperante un análisis previo de los datos (Cepeda et al., 2018). Para este estudio, se utilizaron dos imágenes satelitales correspondientes a los años de 2001 y 2020 de los sensores ASTER y MSI (Sentinel 2A) respectivamente. Las imágenes ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) fueron puestas en órbita con el satélite TERRA de la NASA en 1999. Posee 14 bandas espectrales agrupadas en 3 clases VNIR, SWIR, TIR (visible e infrarrojo cercano, infrarrojo de onda corta e infrarrojo térmico respectivamente) (Tabla 3) (Abrams y Hook, 2001).

Tabla 3

Características de una imagen ASTER.

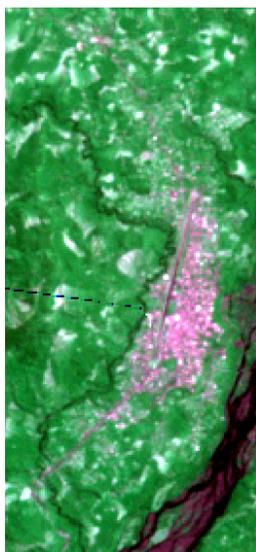
Grupo	Banda	Rango del espectro (μm)	Resolución espacial (m)	Resolución espectral (bits)
VNIR	1	0.52 – 0.60	15	8
	2	0.63 – 0.69		
	3N	0.78 – 0.86		
	3B	0.78 – 0.86		
SWIR	4	1.600 – 1.700	30	8
	5	2.145 – 2.185		
	6	2.185 – 2.225		
	7	2.235 – 2.285		
	8	2.295 – 2.365		
	9	2.360 – 2.430		
TIR	10	8.125 – 8.475	90	12
	11	8.475 – 8.825		
	12	8.925 – 9.275		
	13	10.25 – 10.95		
	14	10.95 – 11.65		

Fuente: (Abrams y Hook, 2001).

Una limitante de las imágenes satelitales en esta zona del Ecuador es la presencia de nubes (Palacios et al., 2019). Aun así, se han podido obtener dos escenas ASTER del 24/08/2001, que cumplen con las condiciones de baja nubosidad. Obtenidas las imágenes, se realizó una georreferenciación y una corrección geométrica de dichas imágenes, ya que este tipo de productos (ASTER L1A) no son aplicados los coeficientes radiométricos ni geométricos, y por ende es requerida una corrección previa al uso de estos insumos (Abrams y Hook, 2001). Estas correcciones se realizaron en el software ENVI, con el que se aplicó el fichero en formato HDF y se generaron tie points para una posterior correlación espacial con la imagen. A continuación, se realizó un mosaico de las dos escenas ASTER para obtener la imagen completa del área de estudio y se trabajó con una combinación de bandas 6-1-3N para resaltar la mancha urbana de la ciudad (Figura 16):

Figura 16

Imagen ASTER del 2001, en combinación 6-1-3 para resaltar la mancha urbana de Macas.



Fuente: elaboración propia.

Por otro lado, las imágenes Sentinel 2A forman parte del programa espacial Copernicus de la Unión Europea, lanzado en 2015 junto con su par Sentinel 2B. Cada escena Sentinel 2A posee 13 bandas espectrales que corresponden a distintos rangos del espectro electromagnético, como se muestra en la Tabla 4:

Tabla 4

Características de una imagen Sentinel 2A.

Grupo	Banda	Rango del espectro (nm)	Resolución espacial (m)	Resolución espectral (bits)
Azul	2	490		
Verde	3	560		
Rojo	4	665	10	
NIR 1	8	842		
Red edge 1	5	705		
Red edge 2	6	740		
Red edge 3	7	783		12
NIR 2	8A	865	20	
SWIR 1	11	1610		
SWIR 2	12	2190		
Aerosol	1	443		
Water vapour	9	940	60	
Cirrus	10	1375		

Fuente: (ESA, 2020).

En este caso, los productos ya poseen una corrección geométrica y se utilizó un layer stack para realizar un juego de bandas 12-11-4 con que se resaltó la parte urbana de la ciudad al 2020 (Figura 17):

Figura 17

Imagen Sentinel 2A de enero/2020, en combinación 12-11-4 para resaltar la mancha urbana de Macas.



Fuente: elaboración propia.

3.1.2 Elaboración de modelo de susceptibilidad a deslizamientos

Un insumo fundamental al momento de considerar el crecimiento urbano de una ciudad es el riesgo por deslizamiento. Si bien existe información oficial sobre zonas propensas a deslizamientos, esta responde a un modelo nacional escala 1:250.000 generado en el 2003 por la Secretaría Nacional de Gestión de Riesgos (SNGR), por lo que el nivel de detalle es muy general. Es por ello, que se optó por elaborar un modelo de susceptibilidad a deslizamientos propio mediante Lógica Fuzzy. Para esto, se usó las siguientes variables: 1) cobertura vegetal, 2) fallas geológicas, 3) geología, 4) morfología, 5) precipitación, 6) ríos, 7) tipo de roca, 8) pendiente, 9) textura del suelo y 10) vías. Fuzzy es una técnica multicriterio que trata de simular el pensamiento humano para producir un razonamiento artificial (Grekousis et al., 2013). Trabaja con la probabilidad de pertenencia de cada pixel a cierta clase, para lo cual utiliza una función de membresía trigonométrica (seno y coseno) que varía de acuerdo a la relación de la variable

explicativa respecto del fenómeno de interés (Palacios y Toulkeridis, 2020). Para el caso de estudio, se utilizó las siguientes funciones de membresía:

$$N = \frac{V_o - V_{min}}{V_{max} - V_{min}} \quad (28)$$

$$\varphi_A(V_o) = \text{sen}\left(\frac{\pi}{2} * N\right) \quad 0 \leq \varphi_A(V_o) \leq 1 \quad (29)$$

$$\varphi_A(V_o) = \text{cos}\left(\frac{\pi}{2} * N\right) \quad 0 \leq \varphi_A(V_o) \leq 1 \quad (30)$$

donde V_o es la variable original, V_{min} y V_{max} corresponden al valor mínimo y máximo respectivamente, $\varphi_A(V_o)$ la función de pertenencia, y N indica la variable normalizada. Para alcanzar una mejor precisión en el modelo difuso, se aplicó con una combinación lineal ponderada (WLC) (Palacios et al., 2018) y un proceso analítico jerárquico (AHP) (Palacios, 2018). Los pesos aplicados a las variables se muestran en la Tabla 5:

Tabla 5

Ponderaciones mediante AHP a variables del modelo de deslizamientos.

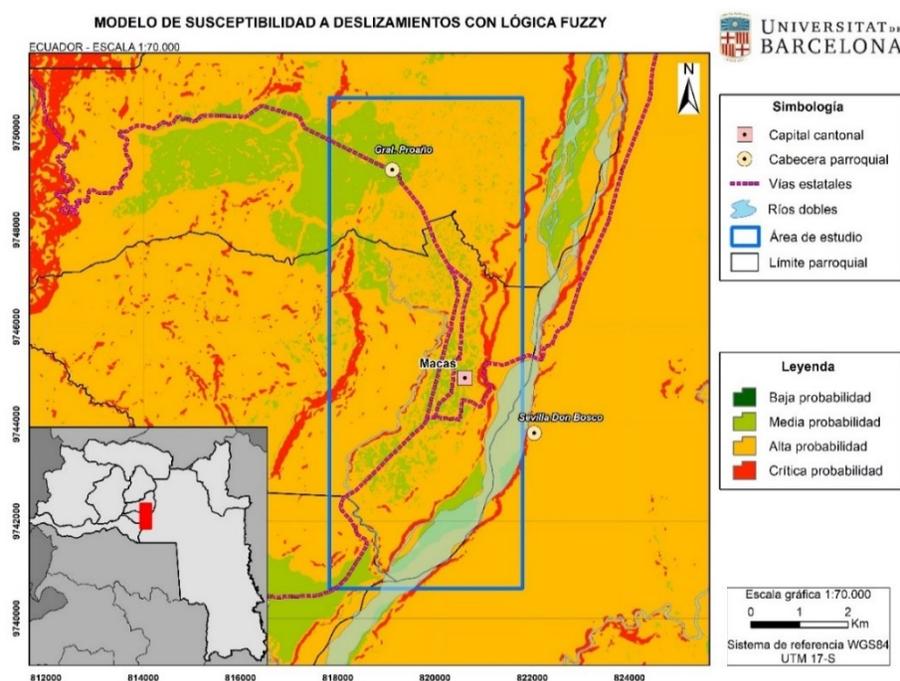
Variable	Peso
Cobertura vegetal	0.0266
Falla geológica	0.2150
Geología	0.0375
Morfología	0.0535
Precipitación	0.1537
Ríos	0.0149
Tipo de roca	0.1087
Pendiente	0.2944
Textura del suelo	0.0764
Vías	0.0193
Ratio consistencia	0.03

Fuente: elaboración propia.

Las variables de ríos, vías y fallas geológicas corresponden a distancias euclidianas, y el resto se ponderaron en función de los atributos de cada una de estas. Para las pendientes se trabajó con el modelo digital del terreno (MDT) del proyecto SIGTIERRAS a una resolución de 3 metros, mientras que las variables cobertura vegetal, geología (formación geológica), morfología (unidad geomorfológica), tipo de roca (litología), y textura del suelo fueron descargadas del geoportal del Ministerio de Agricultura y Ganadería (MAG) a escala 1:25.000. Finalmente, las isoyetas (precipitación) fueron obtenidas de la página del Instituto Nacional de Meteorología e Hidrología (INAMHI) a escala 1:50.000. El modelo resultante se presenta en la Figura 18:

Figura 18

Mapa de susceptibilidad a deslizamientos generado en la zona de estudio.



Fuente: elaboración propia.

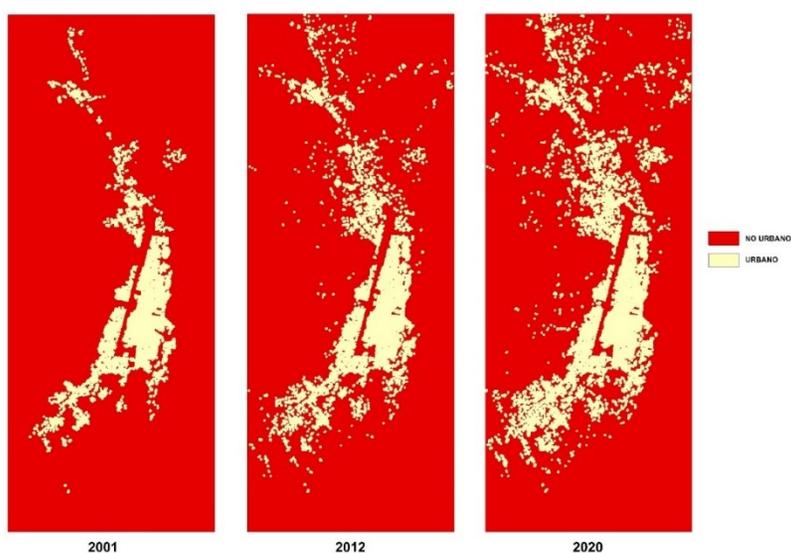
3.1.3 Construcción y recopilación de información vectorial

Una vez elaborados los insumos anteriormente descritos, se procedió a la recopilación de la información vectorial faltante, específicamente en cuanto a las edificaciones que formarán parte de las manchas urbanas de los tres períodos de tiempo establecidos.

Para generar la mancha urbana del 2001, se tomó como base la imagen ASTER de ese año, sobre la cual se fue depurando el shape de las construcciones del año 2019 (siendo el único registro cartográfico oficial que se pudo obtener desde el GAD Morona). En el caso de la mancha urbana del 2012 se trabajó de forma similar a lo mencionado, pero tomando como base una ortofotografía del IGM a escala 1:5000 y que fue facilitada por el municipio. Finalmente, para completar la información del año 2020, se usó la imagen Sentinel 2A para actualizar la mancha urbana a la fecha más reciente. Una vez culminado, se procedió a clasificar el shape de la mancha urbana en dos clases: urbano y no urbano, siendo este último la cobertura sobre la cual se ejecutarán los cambios en las predicciones a través del tiempo (ver Figura 19).

Figura 19

Mancha urbana de Macas, en los tres periodos de tiempo definidos.



Fuente: elaboración propia.

Además, de las bases nacionales oficiales se obtuvieron los shapes de centros educativos y de salud, de ríos y de vías; mientras que del GAD cantonal se consiguieron los polígonos de mercados, espacios de recreación (áreas verdes, parques, canchas cubiertas), relleno sanitario, terminal terrestre, y catastro del año 2019 (como ya se mencionó anteriormente). También fueron solicitadas las coberturas de servicios básicos, sin embargo, el GAD no contaba con información histórica de estos insumos, ni tampoco actualizada. Por tanto, el uso de estas variables conllevaría a una incertidumbre mayor al momento de ingresar dentro del modelo de simulación, en tanto que se prefirió descartarlas.

En resumen, para el modelo de simulación de crecimiento urbano tendencial de la ciudad de Macas, se utilizaron 10 variables explicativas que fueron:

- Susceptibilidad a deslizamientos;
- Distancia a centros educativos;
- Distancia a mercados;
- Distancias a espacios recreativos;
- Distancia al relleno sanitario;
- Distancia a cuerpos de agua;
- Distancia a centros de salud;
- Distancia al terminal;
- Distancia a vías;
- Pendientes.

3.2 Definición de la resolución espacial del modelo de predicción urbano

La determinación de la resolución espacial es una fase muy importante debido a la influencia que tiene el tamaño de celda en la precisión del modelamiento espacial. Existen varios

estudios en distintas variables de la naturaleza que resaltan la significancia que tiene el tamaño de pixel en el resultado de la predicción, como por ejemplo, en variables del suelo (Florinsky y Kuryakova, 2000), datos meteorológicos (Noda y Niino, 2003), corrientes marinas (Molnár y Julien, 2000), y ondulación geoidal (Palacios, 2019), por mencionar algunos.

Para este estudio de caso, el tamaño de pixel se definió en función del tamaño promedio del lote en la ciudad de Macas, de acuerdo a la Ordenanza que pone en vigencia el Plan de Actualización de Uso y Ocupación del Suelo (GAD Morona, 2019), la misma que resulta un lote promedio de 289 m². Según Hengl (2006), se debe considerar la dimensión del objeto espacial más pequeño a ser analizado, lo cual en términos geográficos respondería a un conjunto de no menor a 2x2 píxeles para discriminar a dicho objeto, tanto en largo y ancho (McBratney et al., 2003). Con esto, la resolución espacial adecuada fue un tamaño de pixel de 8.5 metros, que corresponde a la unidad mínima mapeable de una resolución espacial efectiva de cuatro píxeles.

3.3 Modelamiento espacial

3.3.1 Determinación de variables potenciales a usar

Las variables que se expusieron con anterioridad, responden a dos criterios: el primero basado en estudios previos sobre modelamiento urbano que hayan considerado a éstas, y segundo, la disponibilidad de la información con la que se contó para el presente trabajo. Dicho esto, se puede mencionar que los centros educativos, las vías, los mercados, los espacios recreativos, los centros de salud, el relleno sanitario y el terminal, son variables de distancia a elementos relevantes; por otro lado, las pendientes, la susceptibilidad a deslizamientos y los cuerpos de agua, son variables naturales, según la clasificación de Cifuentes y Londoño (2010).

Además, son varios los estudios que han implementado a las pendientes, las vías y los cuerpos de agua en sus modelamientos (Ali Dereli, 2018; Bununu, 2017; Hu y Lo, 2007;

Kazemzadeh et al., 2016; Megahed et al., 2015), así como a los deslizamientos (Ozturk, 2015; Park et al., 2011). Variables condicionantes (distancia a elementos relevantes) según el área de estudio también son consideradas en varios trabajos (Ahmed y Bramley, 2015; Gounaridis et al., 2018; Khatibi et al., 2018; Lahboub et al., 2018; Ren et al., 2019), por lo que se justifican su inclusión en la presente investigación.

3.3.2 Aplicación de MOLUSCE

Antes de ejecutar las seis ventanas en la que se realiza el modelamiento con este complemento, fue necesario convertir a categóricas los ráster de las 10 variables, para lo que se procedió hacer una reclasificación de cada input. Los criterios para la reclasificación de los ráster de distancias a elementos de la ciudad, estuvieron basados en radios de cobertura de servicios mencionados en el PAUOS del GAD Morona; las pendientes se clasificaron en base a la información del PDOT del 2012 del cantón, al igual que la distancia a ríos, las cuales estuvieron en función de las franjas de protección estipuladas en el mismo PDOT; para las vías se respetó la zona de servidumbre que señala el artículo 42 del Reglamento a la Ley Orgánica del Sistema Nacional de Infraestructura Vial del Transporte Terrestre del Ecuador (Asamblea Nacional, 2018), y finalmente, los deslizamientos mantuvieron las categorías de susceptibilidad calculadas (ver Tabla 6).

Tabla 6

Criterios seguidos para la reclasificación de ráster.

Variable	Rango de valor	Categoría
Distancia centros educativos	0 – 100	5
	100 – 300	4
	300 – 600	3
	600 – 1200	2

	>1200	1
	0 – 100	5
	100 – 300	4
Distancia centro salud	300 – 600	3
	600 – 1200	2
	>1200	1
	0 – 500	5
	500 – 1000	4
Distancia mercado	1000 – 1500	3
	1500 – 2000	2
	>2000	1
	0 – 700	5
	700 – 1400	4
Distancia terminal	1400 – 3000	3
	3000 – 5000	2
	>5000	1
	>6000	5
	3000 – 6000	4
Distancia relleno sanitario	1000 – 3000	3
	500 – 1000	2
	0 – 500	1
	0 – 500	5
	500 – 1000	4
Distancia espacios recreación	1000 – 2000	3
	2000 – 4000	2
	>4000	1
	ancho río <3 m → buffer 15 m	
Distancia ríos	ancho río 3 – 10 m → buffer 30 m	1
	ancho río >10 m → buffer 50 m	
	El resto	3
Distancia vías	0 – 25	1

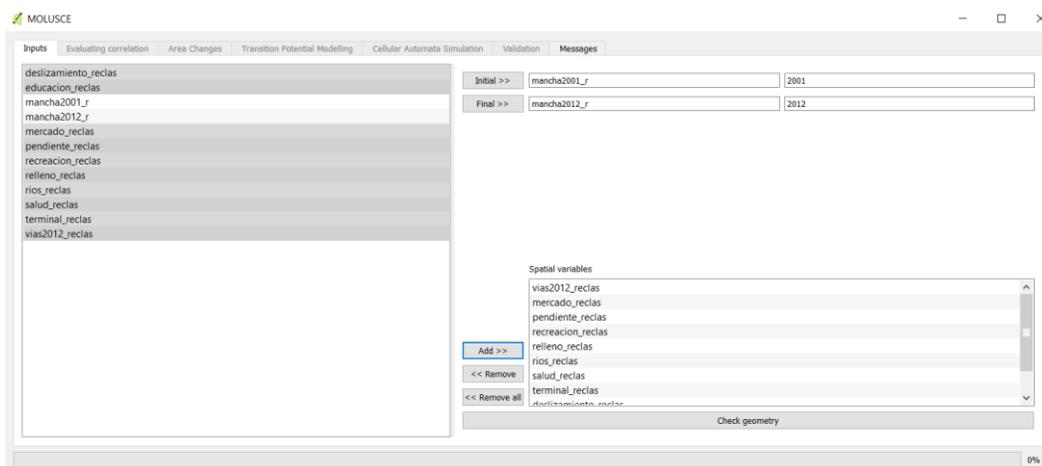
	El resto	3
	<15°	3
Pendiente	15° – 50°	2
	>50°	1
	1.5	3
Susceptibilidad deslizamientos	2.5	2
	3.5	1

Fuente: elaboración propia.

Una vez categorizadas las variables, el siguiente paso fue el ingreso de los datos en la ventana de Inputs (Figura 20), para lo cual todos los ráster deben presentar la misma cantidad de pixeles (filas y columnas), profundidad de bits, y sistema de referencia geográfica.

Figura 20

Ingreso de los ráster en MOLUSCE.



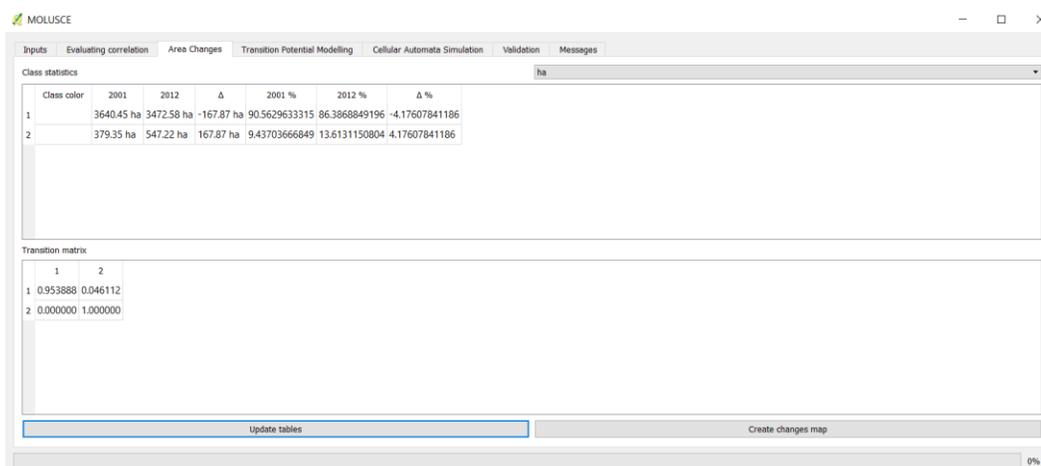
Fuente: elaboración propia.

A continuación, se evalúa la correlación entre las variables, usando Cramer como el indicador para su determinación. Una vez confirmada la independencia espacial entre sus variables, se procedió a calcular la matriz de transición, donde se apreció en unidades de superficie los cambios sufridos en el primer periodo de tiempo (2001 – 2012). Es de vital importancia

verificar que no existan errores en los cambios de transición de una clase a otra, que en este caso son: urbano y no urbano. Por tanto, el único cambio lógico que se puede dar es la transición de no urbano a urbano. En la Figura 21, se indica el entorno del proceso en MOLUSCE para el cálculo de la matriz de transición.

Figura 21

Cálculo de matriz de transición en MOLUSCE.



Fuente: elaboración propia.

Posterior a esto, se realizó el entrenamiento del potencial de transición futuro, para lo cual, se testearon distintos tamaños de vecindario, en este caso se usó con 5, 7 y 9 píxeles, como sugieren algunos autores (Hu y Lo, 2007; Liao et al., 2014; Ziaee et al., 2017). De los 4 métodos que presenta MOLUSCE, se realizaron pruebas previas con cada uno de estos, llegando a la conclusión que el método que mejores condiciones presenta para esta zona de estudio es el de redes neuronales con MLP, razón por la cual en la sección 2.2.6.2.2 se describe el fundamento matemático solo para este método, y el resultado del mismo es el que se comparará con los otros dos softwares.

El siguiente paso fue la predicción usando una autómatas celular basada en el potencial de transición obtenido con MLP. Resultado de esto será el modelo de simulación de crecimiento urbano que viene dado por el número de iteraciones dependientes de los años a predecir (en este

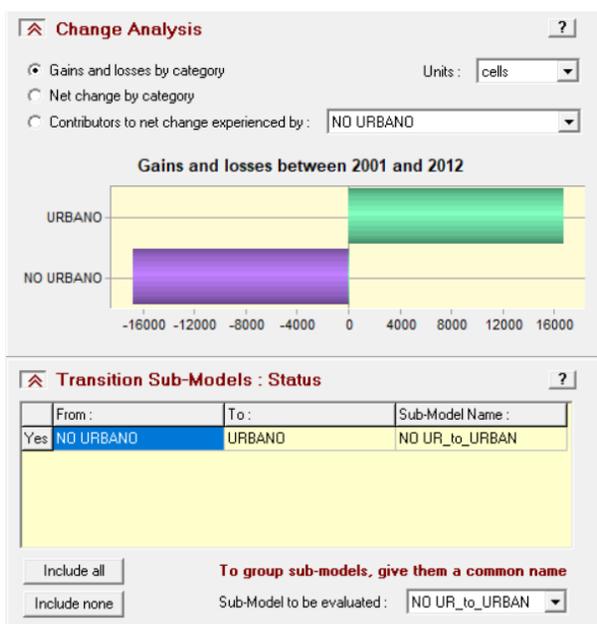
caso 8, ya que se comparó con la mancha urbana del 2020). Finalmente, con el modelo obtenido del paso anterior, se procedió a validar y calcular los indicadores de precisión (Kappa).

3.3.3 Aplicación de LCM

Para los tres métodos usados en LCM se procedió en el mismo orden secuencial descrito en el capítulo de metodología, empezando con el ingreso de los mapas inicial (2001) y final (2012) para obtener la cantidad de cambio ocurrido en el periodo de tiempo estudiado. Al igual que en MOLUSCE, se debe verificar que exista solo el cambio de estado analizado (no urbano a urbano) (Figura 22).

Figura 22

Análisis de cambio y transición ocurrida en LCM.



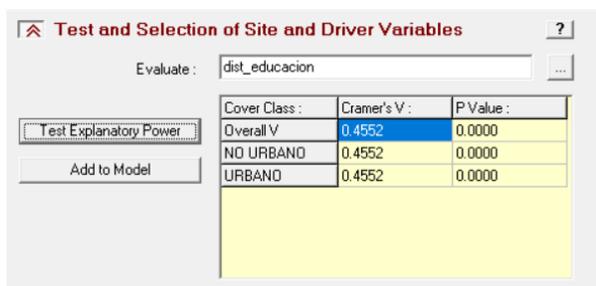
Fuente: elaboración propia.

LCM brinda la posibilidad de probar el valor de potencial explicativo de cada variable en cuanto al modelo de transición analizado. Para esto, el programa usa el indicador V de Cramer, el cual se aplicó al total de variables. En la Figura 23 se aprecia la tabla de contingencia del test en que se calcula el poder explicativo (V de Cramer) y el P – value, éste último relacionado con la

probabilidad de que Cramer no sea tan diferente de 0, teniendo en cuenta que un valor alto de P – value indicaría la eliminación segura de una variable (Eastman, 2012).

Figura 23

Ejemplo del test de Cramer en LCM.



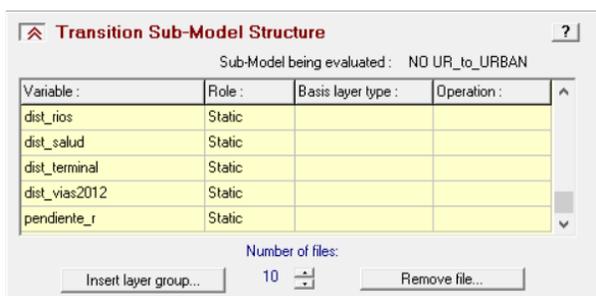
Cover Class :	Cramer's V :	P Value :
Overall V	0.4552	0.0000
NO URBANO	0.4552	0.0000
URBANO	0.4552	0.0000

Fuente: elaboración propia.

Una vez probado el potencial explicativo de cada variable, se procedió a estructurar el modelo de transición para el caso de estudio (no urbano a urbano), donde se ingresaron las 10 variables explicativas del modelo. Para 9 de las 10 variables no hubo necesidad de realizar una transformación, pero en el caso de la susceptibilidad a deslizamientos (que es una variable categórica) se requirió aplicar una transformación de Probabilidad de Evidencia para que la variable tenga una relación lineal con el potencial de transición (Eastman, 2012). En la Figura 24, se indica cómo se ingresaron el total de variables a la estructura del modelo de transición:

Figura 24

Estructura del modelo de transición integrado con sus variables explicativas.



Variable :	Role :	Basis layer type :	Operation :
dist_rios	Static		
dist_salud	Static		
dist_terminal	Static		
dist_vias2012	Static		
pendiente_r	Static		

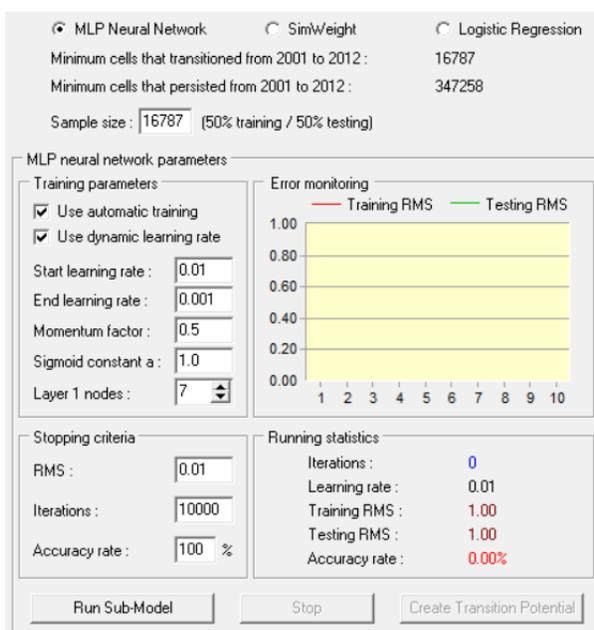
Number of files: 10

Fuente: elaboración propia.

A continuación, se calculó el potencial de transición, para lo cual se aplicaron los tres métodos que presenta LCM (MLP, LR, SimWeight). En primer lugar, se aplicó la red neuronal artificial con MLP usando el algoritmo supervisado backpropagation en modo automático, con los valores especificados en la sección 2.2.6.1.1 literal a, es decir, una velocidad de aprendizaje inicial de 0.01 y final de 0.001, con un total de 10000 iteraciones. El RMS del entrenamiento se fijó a 100, lo que implica una reducción a la mitad de las velocidades de aprendizaje (inicial y final) en el caso de que se presenten altas variaciones en el entrenamiento obligando al reinicio del proceso (Figura 25).

Figura 25

Modelo de entrenamiento del potencial de transición con MLP.



Fuente: elaboración propia.

El siguiente modelo usado fue regresión logística (LR), con el cual se usó un porcentaje del 10% para el muestreo seleccionado a través de un aleatorio estratificado, como lo recomienda

Eastman (2012), en los parámetros para este método. En la Figura 26 se muestra la configuración de la estructura del modelo de transición:

Figura 26

Modelo de entrenamiento del potencial de transición con LR.

MLP Neural Network SimWeight Logistic Regression

Minimum cells that transitioned from 2001 to 2012 : 16787
Minimum cells that persisted from 2001 to 2012 : 347258

Apply sampling

Stratified random sampling Sampling proportion: 10 %
 Systematic sampling

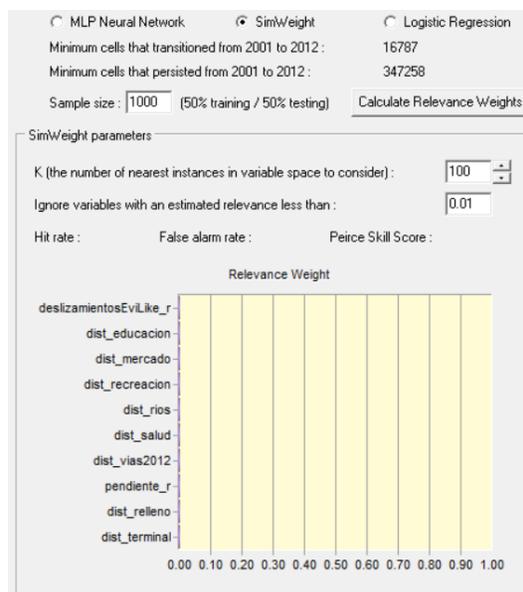
Run Sub-Model

Fuente: elaboración propia.

Finalmente, se aplicó SimWeight, que al igual que MLP, se recomienda trabajar con el 50% de los datos para el entrenamiento y validación, pero con la diferencia de un tamaño de muestra más pequeño (en este caso 1000). Además, la distancia espacio/variable a considerar en cada instancia fue de 100 y el umbral de relevancia para descartar las variables menor a 0.01 (Eastman, 2012) (Figura 27).

Figura 27

Modelo de entrenamiento del potencial de transición con SimWeight.



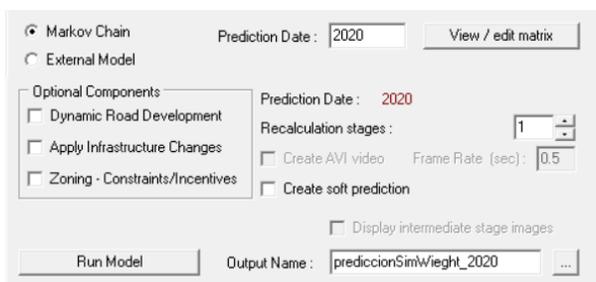
Fuente: elaboración propia.

El siguiente paso fue computar la probabilidad de transición futura para el tercer periodo de tiempo (2020), donde la cadena de Markov fue calibrada para la fecha de predicción deseada. En este estudio, para los tres métodos aplicados (MLP, LR, SimWeight) se utilizó una predicción dura, a través de una asignación multi – objetiva o MOLA (Multi – objective Land Allocation), que asigna a cada pixel una ubicación en la categoría demandante (en este caso, el suelo urbano), tomando como base el potencial de transición simulado con el proceso markoviano.

Al igual que se observó en MOLUSCE, con LCM no se generan los mapas intermedios, es decir que en el periodo de 2001 a 2012 no se produce un mapa nuevo para cada año, ya que éste último se mantiene constante, sino que entiende la lógica expresada en la tasa de cambios y simula el cambio futuro para la tercera fecha (2020). En la Figura 28 se muestra un ejemplo de lo realizado:

Figura 28

Cadena de Markov y asignación de cambio con SimWeight.



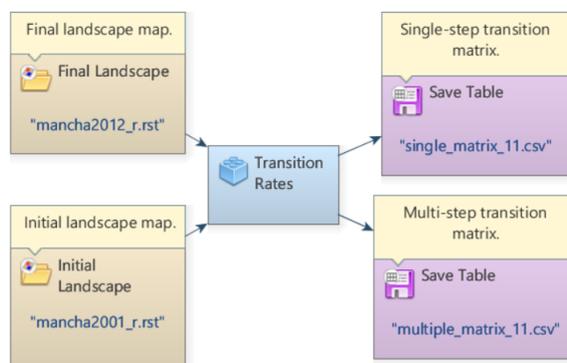
Fuente: elaboración propia.

3.3.4 Aplicación de DINAMICA EGO

Para el modelado del crecimiento urbano con DINAMICA EGO se siguió las etapas mostradas en la sección 2.2.6.2.1, las mismas que se describen en este apartado. El primer paso fue el cálculo de las matrices de transición, para lo cual se ingresaron los ráster de las manchas urbanas de los años inicial (2001) y final (2012) conectados al functor *Transition Rates* con el tiempo transcurrido entre períodos especificado, que en este caso fue de 11 años, para obtener la matriz de transición simple y múltiple. El modelo para calcular las matrices de transición se observa en la Figura 29.

Figura 29

Modelo para el cálculo de matrices de transición.

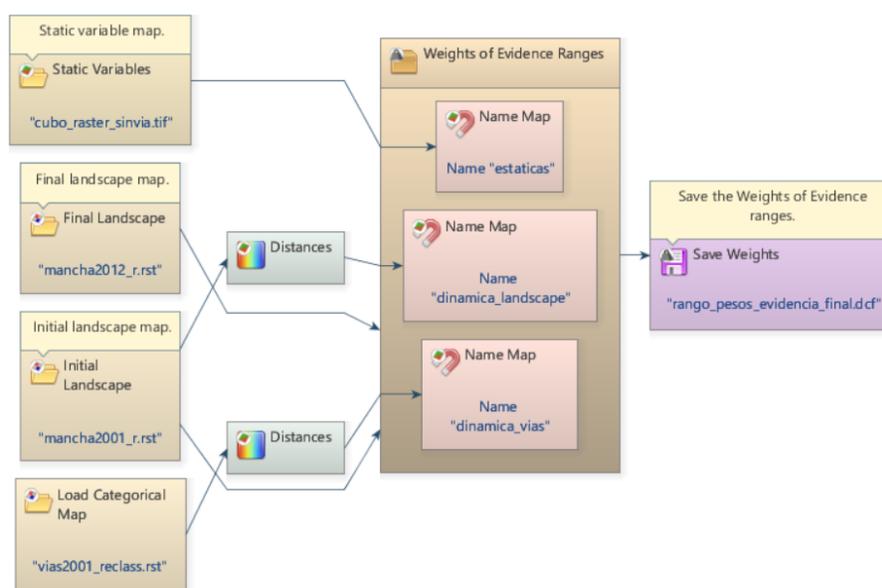


Fuente: elaboración propia.

Posteriormente, se procedió a generar el cubo ráster con las variables categóricas y continuas que formarán parte del modelo de simulación. En este caso, se consideraron 9 de las 10 variables dentro del cubo ráster como variables estáticas, y únicamente a la cobertura de vías como variable dinámica. Una vez obtenido el cubo ráster, se prosiguió con la computación de los rangos de los pesos de evidencia, donde se incluyeron los ráster de los períodos inicial y final, las variables estáticas del modelo (cubo ráster) y las vías, como se observa en la Figura 30, cuyo producto es la asignación a cada viable de los rangos de los pesos de evidencia.

Figura 30

Modelo para calcular los rangos de pesos de evidencia.



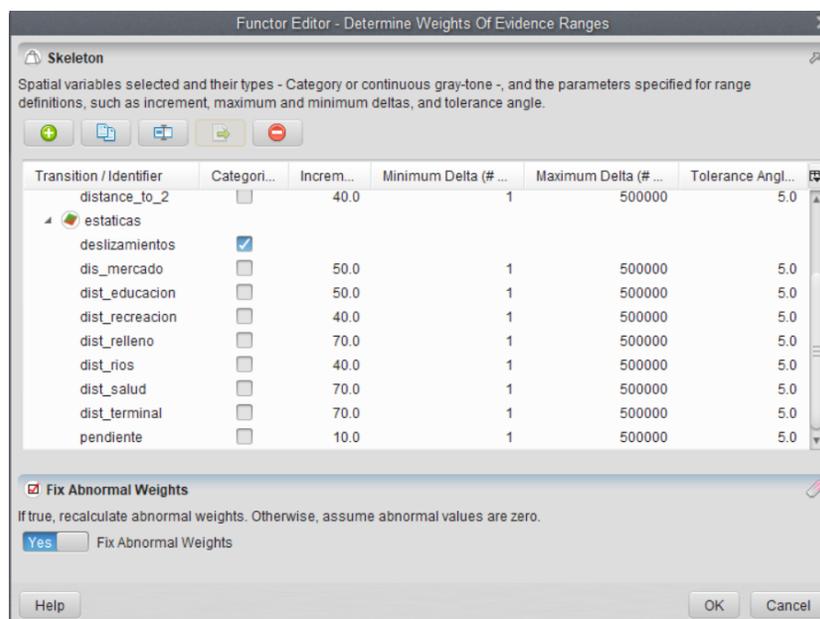
Fuente: elaboración propia.

El software utiliza para este paso el functor *Determine Weights of Evidence Ranges*, donde se debe indicar al modelo cuales son las variables dinámicas, categóricas y estáticas, así como ciertos parámetros como los puntos de quiebre de los rangos en las variables continuas, y la transición evaluada (de no urbano -1- a urbano -2-). Además, fueron requeridos los valores de delta máximo (*maxdx*) y mínimo (*mindx*), ángulo de tolerancia, cuyos valores fueron los

sugeridos por Soares et al., (2009), de 1 y 500000 celdas para *mindx* y *maxdx* respectivamente, así como un ángulo de tolerancia de 5°. Por otro lado, los incrementos fueron definidos conforme la cantidad de rangos resultantes para cada variable, con valores de 10 para la pendiente, 20 en la distancia a lo urbano, 40 en la distancia a vías, áreas de recreación y ríos, 50 en la distancia a mercados y centros de educación, y 70 en la distancia a relleno sanitario, centros de salud y terminal. En la variable categórica (susceptibilidad a deslizamientos) no es necesario especificar estos parámetros, como se observa en la Figura 31.

Figura 31

Parámetros considerados en los rangos de pesos de evidencia.

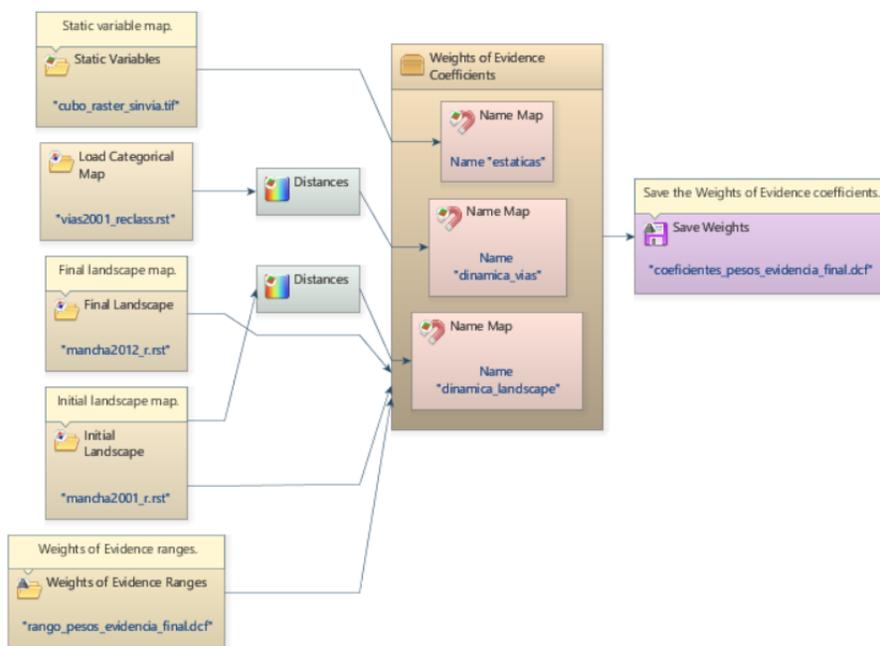


Fuente: elaboración propia.

A continuación, se realizó el modelo para calcular los coeficientes de los pesos de evidencia obtenidos en el paso anterior, para lo cual se tuvo como datos de entrada los ráster de los periodos inicial y final, las variables estáticas representadas en el cubo ráster, las vías incluidas como variable dinámica y los rangos de los pesos de evidencia previamente calculados (Figura 32).

Figura 32

Modelo para calcular los coeficientes de los pesos de evidencia.

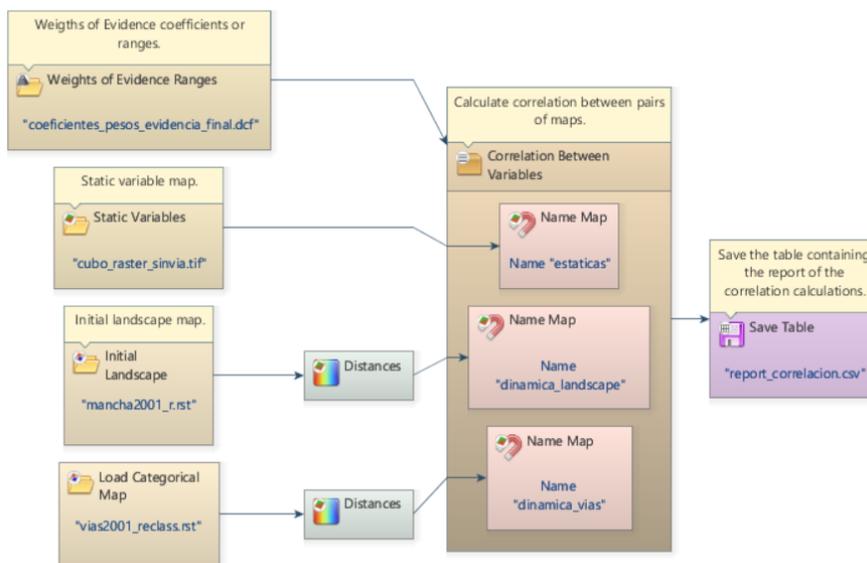


Fuente: elaboración propia.

Un paso fundamental es el análisis de correlación de las variables, ya que la independencia espacial entre las mismas es un requisito obligatorio en los modelos de simulación, principalmente cuando se trabaja con pesos de evidencia. Se procedió a generar un modelo para comprobar que las variables usadas sean espacialmente independientes una de otra (Figura 33). En este caso, se requirió el análisis de las variables estáticas dentro del cubo ráster, y la variable dinámica (distancia a vías); además, se especificó la transición analizada (no urbano a urbano) y los coeficientes de los pesos de evidencia para categorizar las variables continuas. El producto de este análisis es una tabla con los diversos indicadores de independencia espacial, donde se tomó en cuenta el valor de Cramer (al igual que en MOLUSCE), para verificar la independencia de las variables que se tomarán en cuenta para el modelamiento del crecimiento urbano.

Figura 33

Modelo de correlación espacial.



Fuente: elaboración propia.

El siguiente paso fue la simulación del crecimiento urbano para el periodo de tiempo inicial, es decir, 2001 a 2012, donde fueron requeridos los insumos de ráster urbanos inicial y final, matriz de transición múltiple, los mapas de evidencia de cada variable y los coeficientes de los pesos de evidencia convertidos a un grupo de tablas a través del functor *Lookup Table Group*.

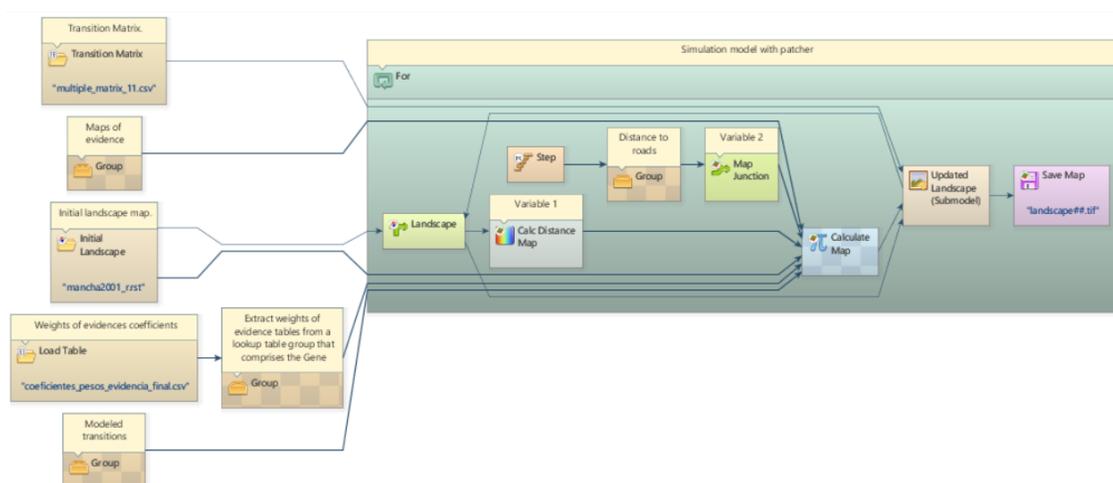
La calibración del modelo de simulación fue procesada en 11 iteraciones correspondientes al tiempo transcurrido en los años inicial (2001) y final (2012). Para cada iteración fue calculada la probabilidad de transición mediante la ecuación (14) con el functor *Calculate Map*, y que ingresa al functor *Allocate Transitions*, donde se encuentran las autómatas celulares representadas en los functors *Patcher* y *Expander*.

Dentro del functor de autómatas celulares, fue necesario definir ciertos parámetros de la relación *Expander/Patcher*, para lo cual se utilizó el software Fragstats en que se calcularon los valores del tamaño medio del parche, varianza del parche e isometría relacionados con el

crecimiento urbano desde un enfoque de fragmentación del paisaje. Los resultados obtenidos en Fragstats, arrojaron un tamaño promedio del parche de 0.8 ha, varianza del tamaño del parche de 1.7 ha y una isometría del parche de 1.1 para la autómatas *Expander*, mientras que para la autómatas *Patcher* se asignaron los mismos valores de tamaño promedio y varianza del parche, cambiando únicamente el valor de la isometría del parche en 2. En la Figura 34, se muestra el modelo generado para la simulación inicial del crecimiento urbano de Macas.

Figura 34

Modelo de predicción para el periodo de calibración del crecimiento urbano.



Fuente: elaboración propia.

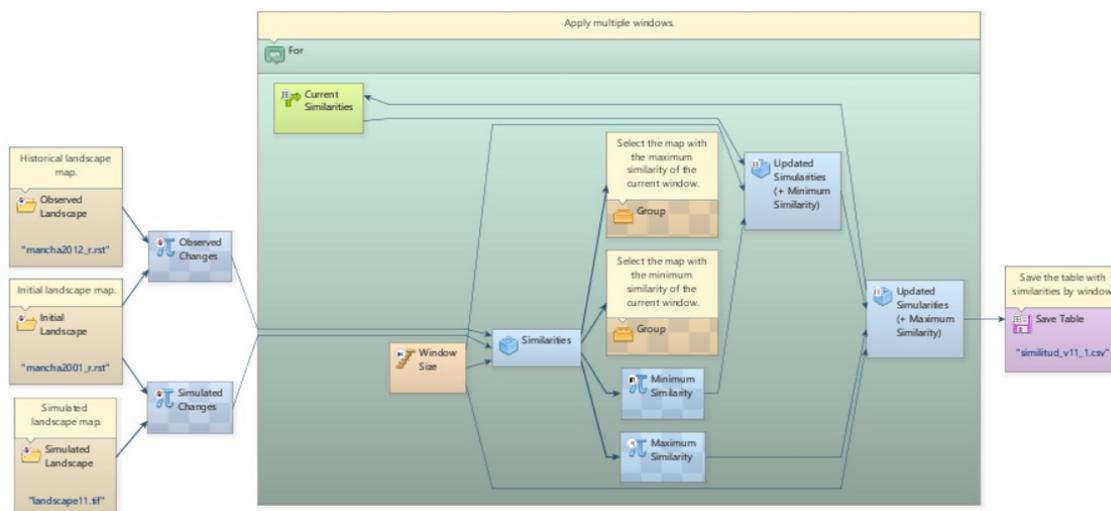
En la predicción con las autómatas celulares en DINAMICA, es necesario definir un ratio entre *Expander/Patcher*. En este estudio se realizaron pruebas con distintos valores de ratio, desde 0.1 a 0.9, con el fin de determinar el comportamiento dinámico del crecimiento de la ciudad. Además, como se observa en el modelo de la Figura 34, las vías son ingresadas como variable dinámica, las mismas que de acuerdo al periodo de tiempo se incluirán los tres ráster de la variable (2001, 2012, 2020).

El ráster obtenido es una mancha urbana simulada al año 2012, en función de los parámetros configurados en los pasos anteriores. Una de las formas de verificar el grado de ajuste del resultado de la simulación, es a través del valor de mínima similitud con diferentes umbrales de ajuste (ventanas), estableciendo una función de decaimiento. El máximo grado de tolerancia representa una ventana mínima en que los ráster comparados (original 2012 y simulado 2012), deben tener una similitud $>50\%$ para ser considerablemente semejantes.

Un modelo de mínima similitud fue elaborado, con un tamaño de ventana de 11 celdas que asemejan un área aproximada de una manzana promedio en la ciudad de Macas. El modelo hace uso del functor *Calc Reciprocal Similarity Map*, que empareja las manchas: inicial (2001), final (2012) y simulado (2012) produciendo estadísticos con las similitudes encontradas entre estos mapas de cambio. El ajuste de la ponderación de cada celda es concentrado en la ventana más pequeña gracias a la función de decaimiento. Al trabajar con procesos iterativos, es recomendable trabajar con las similitudes mínimas con el fin de no llevar a un sobredimensionamiento o sobreespecialización en la simulación del crecimiento urbano. La Figura 35 muestra el modelo de mínima similitud llevado a cabo.

Figura 35

Modelo de mínima similitud.



Fuente: elaboración propia.

En el análisis realizado con los distintos valores de *Expander/Patcher*, se definió un ratio de 0.1, con que se alcanzó la mayor similitud entre la mancha original del 2012 y la generada en DINAMICA. Sin embargo, el valor de mínima similitud no logró el porcentaje sugerido para considerar un buen ajuste del modelo. Debido a esto, se aplicó un método alternativo para mejorar los resultados obtenidos, a través de la optimización de los coeficientes de los pesos de evidencia con algoritmos genéticos.

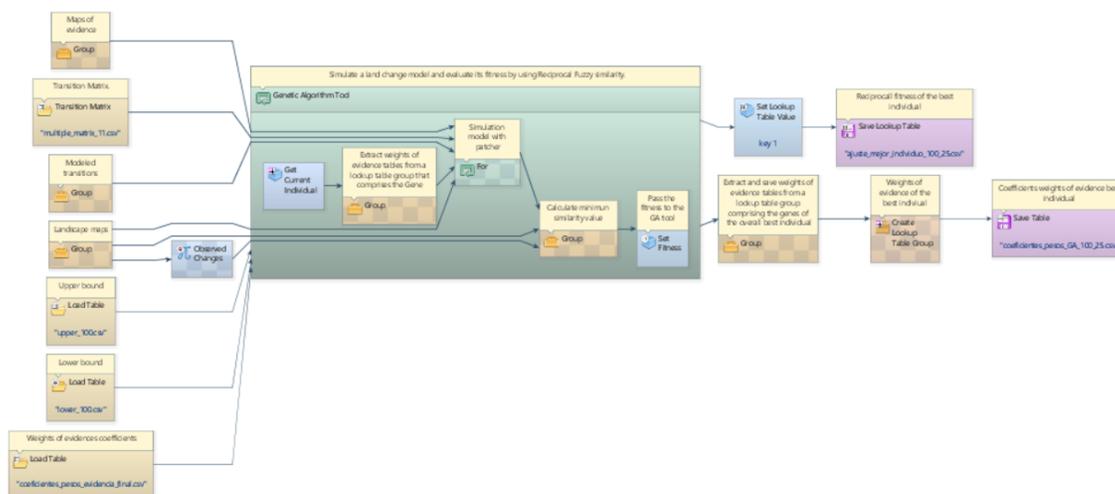
Los algoritmos genéticos (AG), es una técnica de optimización numérica basada en la teoría de evolución darwiniana. Fue ideada por Holland (1975) y desarrollada años más tarde por otros autores (Forrest, 1996; Goldberg, 1989, entre otros). Esta técnica heurística considera a un conjunto de individuos o cromosoma que representan una solución posible a la resolución de un problema, mientras que el grupo de individuos configura una población. AG evalúa el desempeño de todos los individuos inicialmente existentes en la solución del problema para consiguiente, escoger el par de cromosomas con mejor rendimiento (x,y). Mediante una función de cruce o

recombinación produce una solución “z” con las características heredadas de sus cromosomas padres. A continuación, el algoritmo hace mutar los valores (genoma) con una función que genera aleatoriamente un nuevo individuo para ser evaluado su desempeño en un proceso iterativo, que se detiene hasta alcanzar un criterio de número máximo de generaciones (McCall, 2005).

En DIMANICA EGO, se cuenta con la herramienta de algoritmos genéticos, constituido por dos functors principales: *Get Current Individual* y *Set Fitness*. Los coeficientes iniciales de cada variable son los parámetros del modelo AG, que conforman un alelo. Estos valores son ingresados en una tabla separada para formar un gen, y el conjunto de estos genes constituye un cromosoma. El primer functor (*Get Current Individual*) se encarga de producir los individuos para una generación donde sus coeficientes de los parámetros de todos los cromosomas entran al modelo. Cada individuo es evaluado por la función dentro del modelo que considera el desempeño de estos en la solución del problema. Es necesario la especificación del número de generaciones y población por cada generación (individuos) para que las iteraciones culminen. Finalmente, el segundo functor (*Set Fitness*) es el responsable de seleccionar el individuo con mejor desempeño, y que será el que alcance la optimización en sus coeficientes para la solución del problema (Soares et al., 2013). En la Figura 36 se muestra el modelo AG para el caso de estudio.

Figura 36

Modelo de algoritmos genéticos con niveles de tolerancias.



Fuente: elaboración propia.

En el modelo de la Figura 36, se consideraron niveles de tolerancia o límites para mejorar la mutación de los pesos de evidencia, tanto superior como inferior. Según Soares et al., (2009), se sugiere utilizar un límite de tolerancia del $\pm 120\%$ del peso de evidencia con el fin de reducir la sobre-especialización del modelamiento, ya que se podría llegar a una similitud elevada en la etapa inicial (calibración) y demasiado baja en la etapa final (validación). Por ello, se realizaron distintas pruebas con varios niveles de tolerancia: $\pm 60\%$, 80% , 90% , 100% , 120% , 130% , 140% , 150% . También se analizó con distintos números de individuos y generaciones dentro del modelo de AG, como fueron 10, 15, 20, 25 respectivamente. Los resultados de esta optimización, son los coeficientes ajustados (genes optimizados) y el ajuste del mejor individuo que mostró.

Una vez identificado el límite óptimo, así como el número de individuos y generaciones que mejores resultados mostraron, los coeficientes optimizados fueron ingresados en el modelo de la Figura 34 para posteriormente, calcular la mínima similitud en la fase de calibración (Figura 35).

3.3.5 Comparación entre modelos

Para la comparación de los modelos de simulación de crecimiento tendencial urbano, se calcularon distintos estadísticos que coadyuven a determinar cuál de los modelos generados en este estudio, representa de mejor manera la dinámica de crecimiento de la ciudad de Macas. En los diversos softwares usados, se presentaron tres tipos de indicadores de ajuste, como son el coeficiente Kappa (obtenido en MOLUSCE), ROC (calculado en Idrisi) y mínima similitud o índice de similitud difusa (computado en DINAMICA). De forma general, los tres métodos mencionados trabajan en función de la concurrencia espacial encontrada entre el modelo original y simulado, empero, la mínima similitud permite evaluar esta coincidencia a través de tolerancias (ventanas) diferentes, por lo que faculta al investigador en considerar el grado de ajuste para su modelo.

En este caso, se calculó la mínima similitud para los resultados obtenidos con los diferentes softwares, tomando como modelo base el ráster del año 2020, debido a que tanto en MOLUSCE como Idrisi, no se generan modelos de la calibración (2012), sino únicamente de la validación.

3.3.6 Selección del modelo óptimo para modelar el crecimiento urbano

La selección del modelo más óptimo para generar la simulación de crecimiento urbano de Macas al año horizonte propuesto (2030), se centra en los resultados obtenidos en la sección anterior. El modelo que mejor resultado alcance en el indicador de ajuste calculado, representará de forma correcta la dinámica de crecimiento urbano tendencial de la ciudad.

Capítulo IV: Análisis y Discusión de Resultados

Las tres fechas usadas como referencia para el presente estudio, que fueron: 2001, 2012, 2020, responden a dos cuestiones fundamentales: la disponibilidad de los datos, y a que se trató de mantener un intervalo de tiempo casi igual, en este caso, de 10 años entre fechas. Así pues, se pueden manejar condiciones similares de la dinámica existente en la ciudad.

Como primer punto a analizar es el cambio temporal que ha sufrido la mancha urbana (suelo urbano) a lo largo de 20 años, que se resumen en la Tabla 7.

Tabla 7

Cambio temporal de la mancha urbana de la ciudad de Macas.

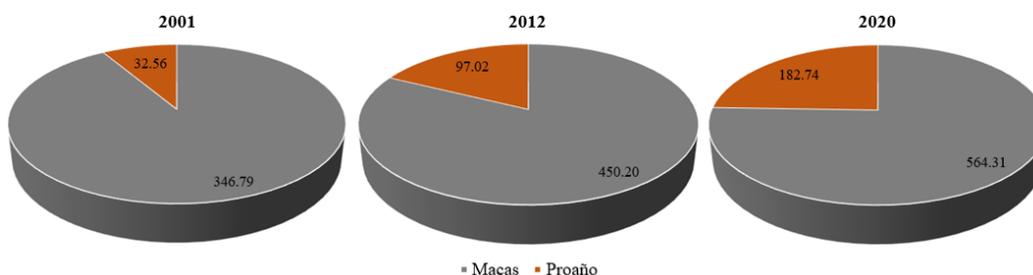
Año de referencia	Área mancha urbana (ha)
2001	379.35
2012	547.22
2020	743.09

Fuente: elaboración propia.

De los valores mostrados en la Tabla 7 se puede señalar que ha existido un aumento de aproximadamente 367.7 ha desde 2001 a 2020, con un ratio de crecimiento de 0.69 entre el primer periodo de tiempo (2001 – 2012), y 0.73 para el segundo (2012 – 2020). En cuanto a la superficie urbana por parroquia, en este caso Macas y Gral. Proaño, se puede constatar el crecimiento del área urbana de forma casi regular (Figura 37).

Figura 37

Superficie en hectáreas de la mancha urbana en las parroquias de Macas y Proaño.



Fuente: elaboración propia.

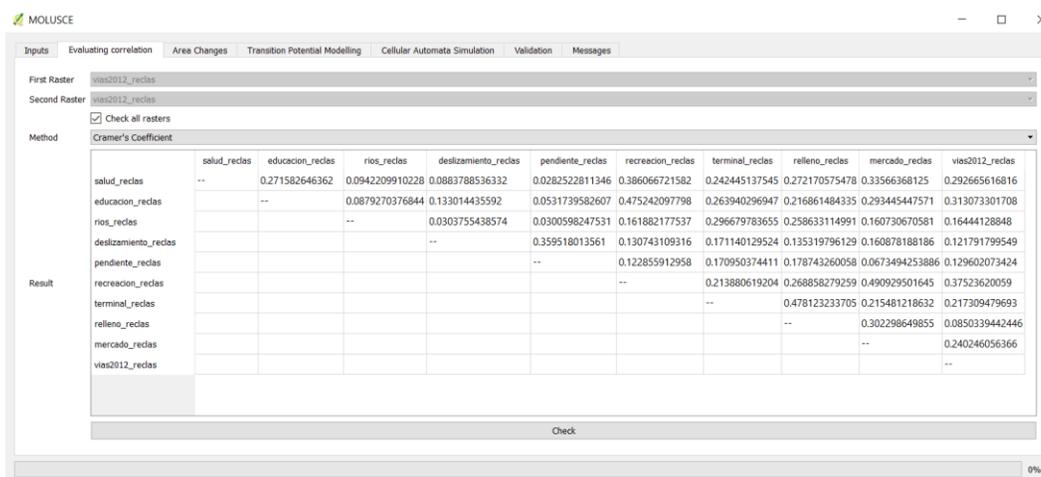
Con esta premisa se procedió a describir los resultados obtenidos con cada uno de los softwares usados.

4.1 Resultados con MOLUSCE

En la fase de calibración, es decir en el primer intervalo de tiempo (2001 – 2012), los valores de las variables incluidas en el modelamiento indicaron que éstas son independientes espacialmente mediante el coeficiente de Cramer, al no superar los 0.5. En la Figura 38 se presentan los valores del indicador obtenidos, con los que se asegura que las variables no están correlacionadas entre sí.

Figura 38

Coficiente de Cramer obtenidos con los inputs del modelo en MOLUSCE.

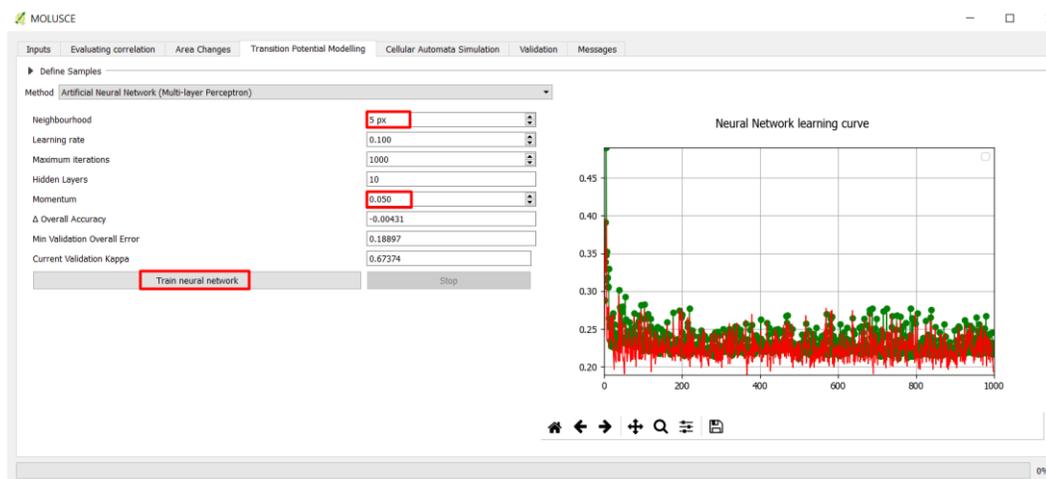


Fuente: elaboración propia.

De acuerdo a los resultados de la matriz de transición (ver Figura 21), un 4.17% de superficie cambió de no urbano a urbano en este periodo. Con ello, se siguió al entrenamiento del potencial de transición mediante redes neuronales (MLP) donde se realizó una comparación entre tamaños de vecindario. En esto caso, las curvas de entrenamiento de la red se comportaron de forma distinta (ver Figuras 39, 40, 41).

Figura 39

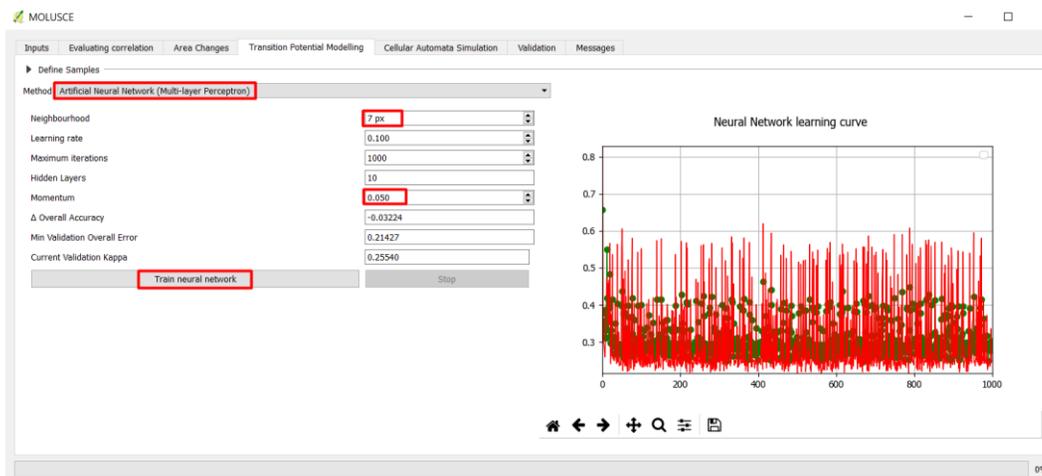
Curva de aprendizaje de la red neuronal con 5x5 de tamaño de vecindario.



Fuente: elaboración propia.

Figura 40

Curva de aprendizaje de la red neuronal con 7x7 de tamaño de vecindario.



Fuente: elaboración propia.

Figura 41

Curva de aprendizaje de la red neuronal con 9x9 de tamaño de vecindario.

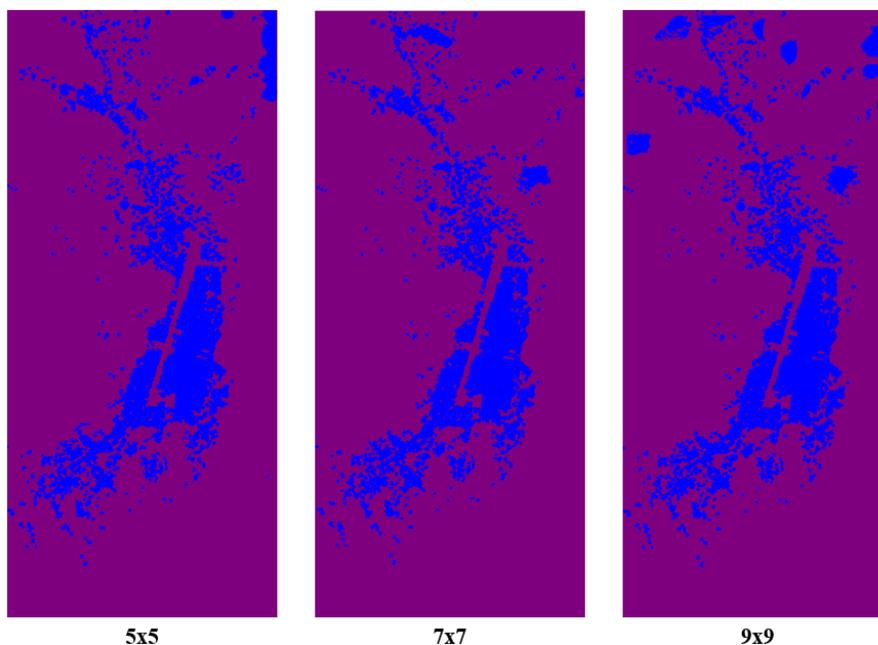


Fuente: elaboración propia.

Según los resultados alcanzados, presentó una velocidad de aprendizaje rápida (por la existencia de picos), así como una mejor semejanza entre los valores de entrenamiento (en verde) y de validación (en rojo), con los vecindarios de 5 y 7 píxeles, infiriendo un aprendizaje estable del entrenamiento de la red. En la Figura 42, se observan los modelos simulados para cada vecindario probado:

Figura 42

Resultados de la simulación con CA según el tamaño del vecindario.



Fuente: elaboración propia.

Además, se calcularon los estadísticos de precisión que resultaron de la validación efectuada con el ráster del tercer periodo (2020). Aquí se comprobó que el modelo que mejor se ajusta con la realidad del área de estudio fue con un vecindario de 7 píxeles. En la Tabla 8 se resumen los valores obtenidos de la simulación en MOLUSCE.

Tabla 8

Resultados de la validación del modelo simulado en MOLUSCE.

Indicador	Modelo con 5x5	Modelo con 7x7	Modelo con 9x9
% de exactitud	94.392	94.908	93.647
Kappa general	0.797	0.814	0.775
Kappa de histograma	0.849	0.833	0.891
Kappa de locación	0.938	0.977	0.871

Fuente: elaboración propia.

Este modelo obtenido con MLP fue comparado con los otros modelamientos resultantes de las 3 técnicas adicionales que presenta MOLUSCE, definiendo que el mejor de ellos fue el obtenido con redes neuronales – MLP, razón por la cual no se ahondó en las otras técnicas. Sin embargo, fue importante realizar el cotejo entre metodologías de entrenamiento de la transición, ya que, desde el punto de vista investigativo y experimental del procedimiento llevado a cabo para el área de estudio, garantiza una comparación de los mejores resultados con los diversos softwares empleados en este trabajo.

4.2 Resultados con LCM

El proceso común en los tres métodos aplicados en LCM, es en primera instancia definir el potencial explicativo de las variables a ser incorporadas en el modelo, para lo que se aplicó una V de Cramer. Vale la pena aclarar, que este indicador no asegura el correcto desempeño energético de la variable dentro de los requerimientos matemáticos de cada técnica, sin embargo, si ayuda para descartar variables innecesarias a la estructura del modelamiento. Dicho esto, en la Tabla 9 se presentan los valores de V de Cramer obtenidos para cada variable:

Tabla 9

Valores de V de Cramer a las variables consideradas en LCM.

Variable	V de Cramer	P – value
Distancia a centros educativos	0.4552	0
Distancia a centros de salud	0.4325	0
Distancia a mercados	0.3643	0
Distancia al terminal	0.3172	0
Distancia al relleno sanitario	0.2127	0
Distancias a espacios recreativos	0.5077	0
Distancia a cuerpos de agua	0.2786	0
Distancia a vías	0.5484	0

Pendientes	0.1968	0
Susceptibilidad a deslizamientos	0.1592	0

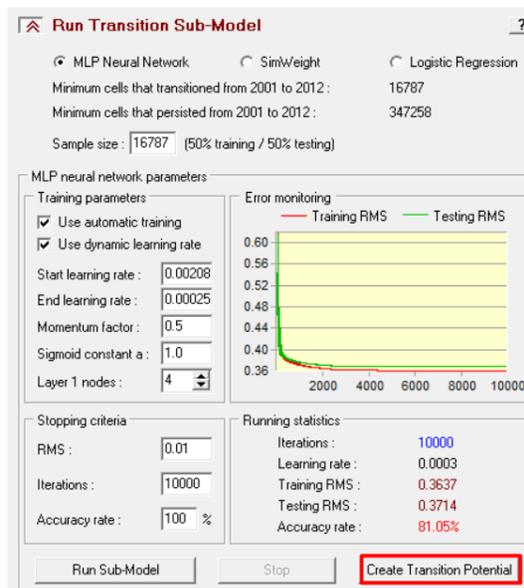
Fuente: elaboración propia.

El poder de asociación de cada variable (fila) con la clase a modelar (columna) corresponden correctamente explicando el comportamiento del uso urbano, debido a que todos los valores del indicador son mayores a 0.15 e incluso mayores a 0.4 (Eastman, 2012). Asimismo, el P – value fue bajo, lo que descarta la posibilidad de eliminar a cualquiera de las variables propuestas. Por tal motivo, las 10 variables fueron usadas en cada técnica de modelamiento dentro de LCM.

Para el caso de redes neuronales con MLP, se procedió a entrenar la red con los parámetros descritos anteriormente, obteniendo la curva de aprendizaje como se muestra en la Figura 43:

Figura 43

Estructura del modelo de aprendizaje de MLP.

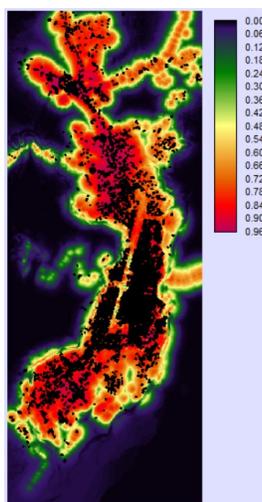


Fuente: elaboración propia.

De este paso se obtuvo un mapa del potencial de transición donde se refleja la probabilidad de que cada píxel pertenezca a una clase, es decir, el potencial de cambio del estado no urbano a urbano. Este mapa (Figura 44) muestra sus valores en un rango de 0 – 1 siendo uno la probabilidad máxima de cambio, y viceversa.

Figura 44

Mapa del potencial de transición contenido con MLP.



Fuente: elaboración propia.

Finalmente, se procede al cálculo con la cadena de Markov para el año simulado (en este caso 2020), con el cual se procederá a validar la estimación. En la Tabla 10 se muestra las probabilidades de cambio obtenidas del proceso markoviano:

Tabla 10

Probabilidades de transición de la cadena de Markov para MLP.

Uso/Uso	No urbano	Urbano
No urbano	0.9662	0.0338
Urbano	0	1

Fuente: elaboración propia.

Los valores obtenidos en la tabla anterior sugieren que el uso no urbano tiene una probabilidad de convertirse en uso urbano del 0.0338, y de permanecer como uso no urbano del 0.9662. Por su lado el uso urbano posee una probabilidad nula de cambiar a suelo no urbano y a su vez de permanecer siempre como suelo urbano. Aunque el valor de cambio de no urbano a urbano sea aparentemente bajo, es lo que la red neuronal logró alcanzar y lo asume como el valor mejor ajustado que refleja la realidad del crecimiento urbano de Macas.

En el caso de la regresión logística aplicada, los coeficientes de la regresión individual se muestran en la Tabla 11 siguiente:

Tabla 11

Coefficientes de la regresión logística.

Variable	Coefficiente
Intercepto	-2.58889272
Susceptibilidad a deslizamientos (sd)	0.29121299
Distancia a centros educativos (de)	-0.00031606
Distancia a mercados (dm)	0.00080038
Distancias a espacios recreativos (der)	-0.00168669
Distancia al relleno sanitario (dr)	0.00031083
Distancia a cuerpos de agua (dc)	0.00030360
Distancia a centros de salud (ds)	0.00037069
Distancia al terminal (dt)	-0.00023449
Distancia a vías (dv)	-0.00985766
Pendientes (p)	-0.03303046

Fuente: elaboración propia.

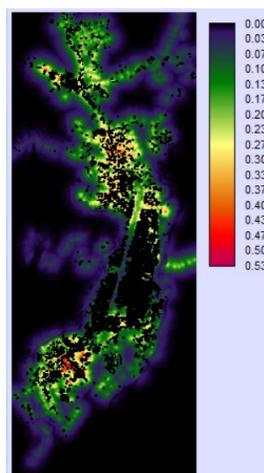
Estos valores forman parte de la ecuación de regresión, conformada de la siguiente forma:

$$\begin{aligned}
 LR = & -2.58889272 + 0.29121299 * sd - 0.00031606 * de + 0.00080038 * dm \\
 & - 0.00168669 * der + 0.00031083 * dr + 0.00030360 * dc + 0.00037069 \\
 & * ds - 0.00023449 * dt - 0.00985766 * dv - 0.03303046 \\
 & * p
 \end{aligned}
 \tag{31}$$

De los coeficientes de la regresión se observó que la variable considerada como más significativa para el modelo con LR fue la susceptibilidad a deslizamientos, seguido de las pendientes y vías, pero de forma inversa (signo negativo), castigando el peso del pixel conforme aumenta su inclinación o se aleja de la mancha urbana respectivamente. Al igual que en MLP, se obtiene como resultado el mapa del potencial de transición con LR, con valores en un rango de 0 – 1, donde la unidad expresa la probabilidad máxima de cambio (Figura 45):

Figura 45

Mapa del potencial de transición contenido con LR.



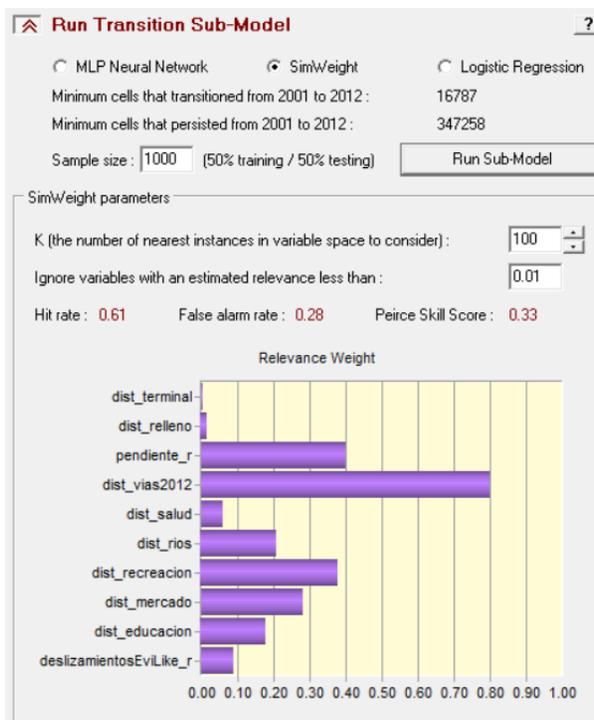
Fuente: elaboración propia.

Además, los valores obtenidos en la matriz de probabilidad de cambio calculada con la cadena de Markov, permanecen iguales a los mostrados en la Tabla 9.

En cuanto al tercer método (SimWeight), se procedió a obtener las ponderaciones en base a los parámetros establecidos anteriormente para esta técnica, obteniendo como resultado mayores pesos de relevancia para las vías, pendientes y distancias a espacios recreativos. Por lo tanto, estos son los que mayor aportan al modelamiento (Figura 46).

Figura 46

Pesos de relevancia para las variables incluidas en SimWeight.

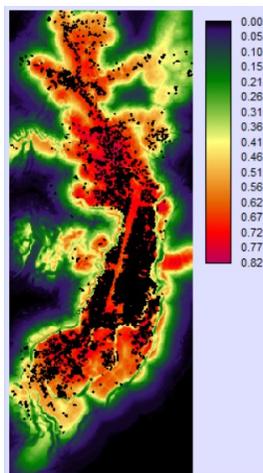


Fuente: elaboración propia.

El resultado del proceso anterior es un mapa de potencial de transición, el mismo que se presenta en la Figura 47:

Figura 47

Mapa del potencial de transición contenido con SimWeight.



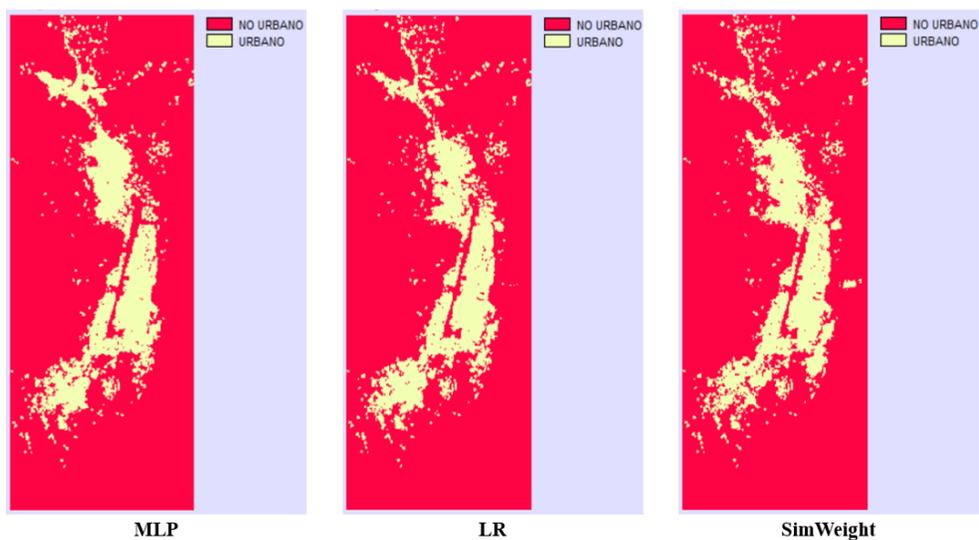
Fuente: elaboración propia.

Al igual que en los dos casos anteriores, el mapa de la figura anterior representa la probabilidad de cambio de un pixel de un estado a otro, en este caso de no urbano a urbano, en un intervalo de valores de 0 a 1. La matriz de probabilidad de cambio computada con la cadena de Markov se mantuvo igual al de los métodos preliminares a este.

Una vez aplicados los tres métodos propuestos en el LCM, se obtuvieron los modelos de simulación de crecimiento urbano de la ciudad de Macas al año 2020, los mismos que fueron comparados con el ráster de este periodo para validar a cada una de las predicciones (Figura 48).

Figura 48

Modelos de predicción del crecimiento urbano de Macas en LCM.

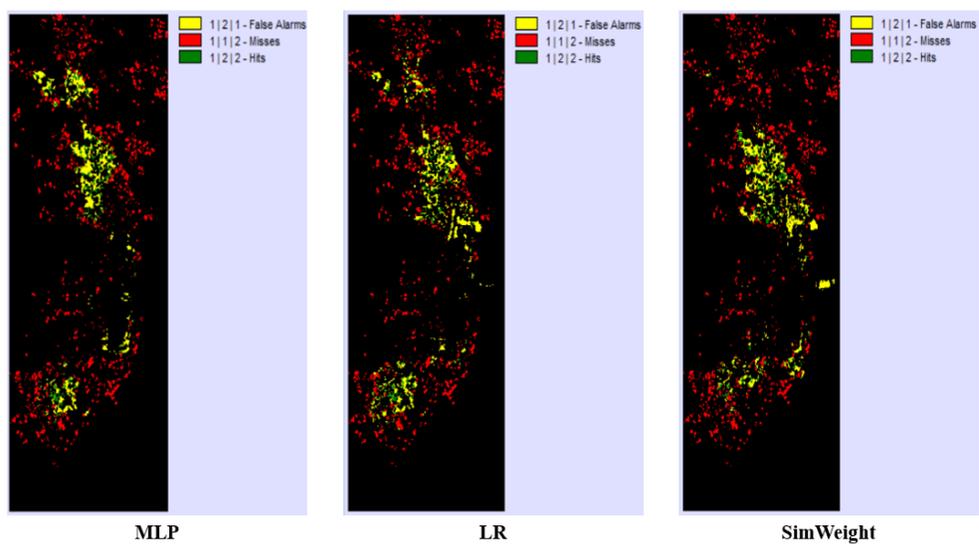


Fuente: elaboración propia.

La validación de los modelos obtenidos se aprecia en la Figura 49:

Figura 49

Resultados de la validación de modelos de predicción en LCM.



Fuente: elaboración propia.

Si bien se puede emitir un juicio de valor en cuanto a qué modelo fue el que mejor estimó el crecimiento urbano de Macas usando el test de tabulación cruzada (Figura 49), es preferible tener un valor cuantitativo para evitar sesgos en la elección del modelo que mejor ajuste alcanzó. Para ello, se procede al cálculo de la Característica Operativa Relativa (ROC - Relative Operating Characteristic), que permite comparar una superficie booleana de la realidad (en este caso el ráster del tercer periodo de tiempo del año 2020), con una superficie de susceptibilidad (representada por los mapas de transición obtenidos en cada método) (Eastman, 2012). ROC se mide en un intervalo de 0 – 1, siendo 1 un ajuste perfecto, 0.5 uno ajuste aleatorio, y 0 la inexistencia del ajuste (Hamdy et al., 2017). En la tabla siguiente, se resumen los valores obtenidos de esta prueba de bondad de ajuste para cada modelo:

Tabla 12

Valores del ROC para los modelos de simulación obtenidos.

Método	ROC
MLP	0.778
LR	0.683
SimWeight	0.782

Fuente: elaboración propia.

En base a ROC se pudo determinar que el modelo de simulación futura obtenida con el método SimWeight, fue el que mejor representa la realidad del crecimiento urbano de la ciudad de Macas y, por ende, este modelo será comparado con los otros modelos resultantes de los dos softwares restantes.

4.3 Resultados con DINAMICA EGO

Como primer resultado, se obtuvieron las matrices de transición simple y múltiple que representan las tasas de cambio para el periodo de tiempo inicial (2001 – 2012), en que el cambio de uso no urbano a urbano fue de 4.61%, mientras que existió una tasa de cambio anual del uso analizado del 0.43%. La Tabla 13 resume lo descrito en este párrafo.

Tabla 13

Matrices de transición obtenidas.

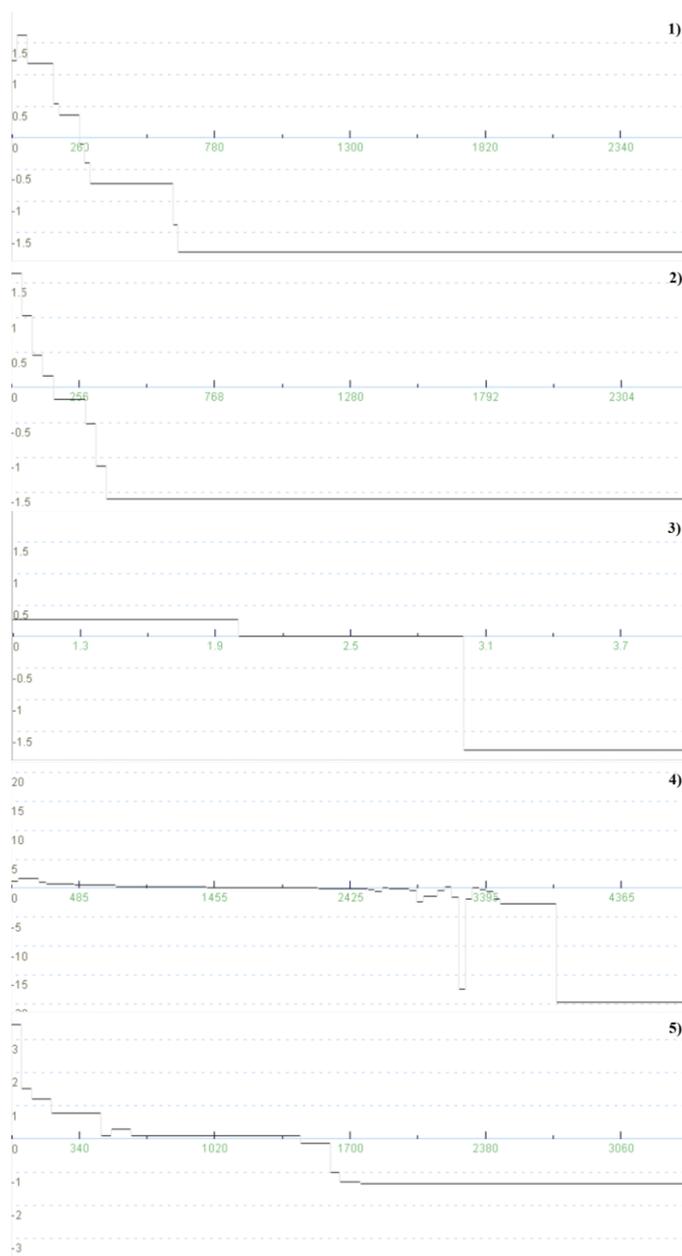
Uso de suelo	Transición simple		Transición múltiple	
	No urbano	Urbano	No urbano	Urbano
No urbano	X	0.0461	X	0.0043
Urbano	0	X	0	X

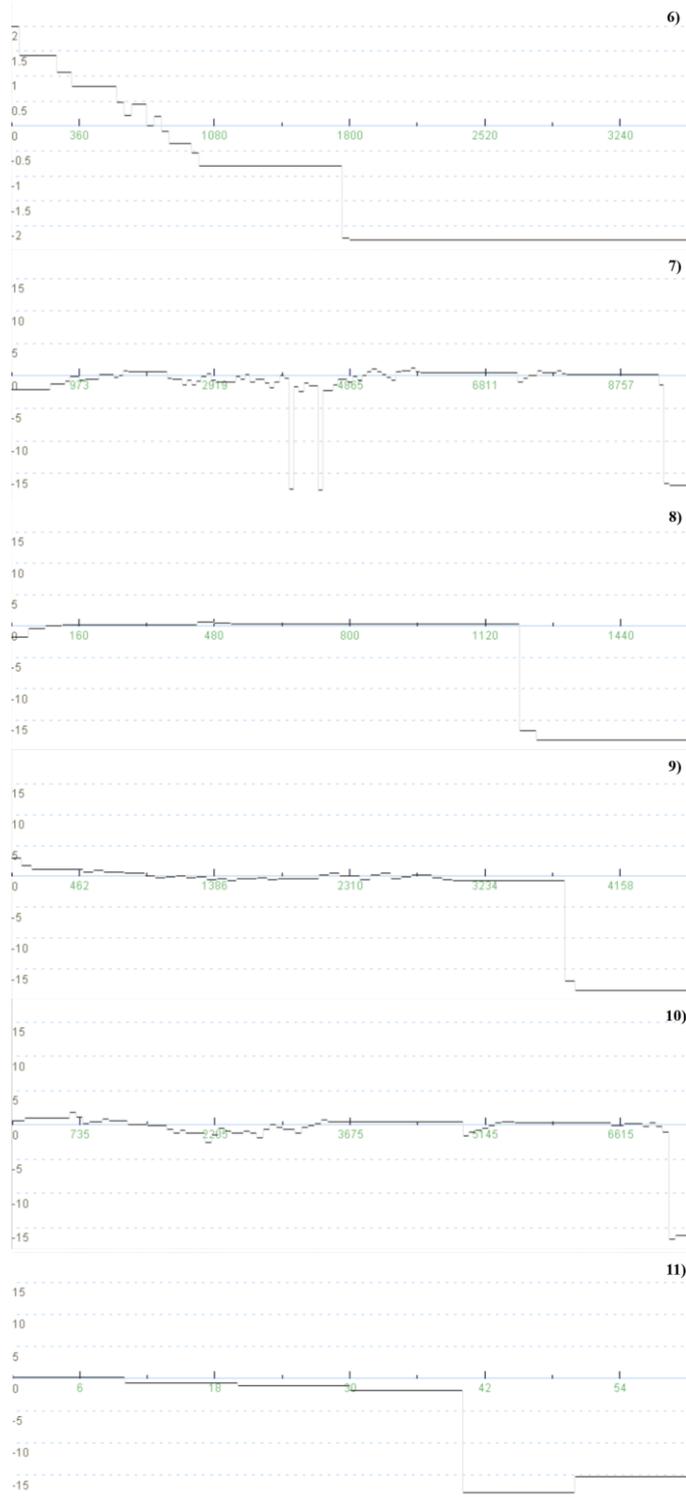
Fuente: elaboración propia.

Los coeficientes calculados para los rangos de los pesos de evidencia determinados, son representados gráficamente en la Figura 50, donde el eje de las abscisas refleja los valores de cada variable, mientras que el eje de las ordenadas señala el coeficiente del peso de evidencia, cuya combinación resulta en los puntos de quiebre encontrados al analizar las variables en los rangos propuestos. Los valores positivos sugieren que el peso de evidencia favorece el crecimiento urbano de la ciudad y viceversa.

Figura 50

Representación gráfica de coeficientes de pesos de evidencia para las variables incluidas: 1) distancia a suelo urbano, 2) distancia al viario, 3) susceptibilidad a deslizamientos, 4) distancia a mercados, 5) distancia a centros educativos, 6) distancia a espacios recreativos, 7) distancia a relleno sanitario, 8) distancia a cuerpos de agua, 9) distancia a centros de salud, 10) distancia al terminal, 11) pendientes.





Fuente: elaboración propia.

A continuación, se aplicó un análisis de correlación espacial para descartar cualquier dependencia entre las variables usadas. En DINAMICA se calculó el indicador de Cramer, con un

total de 55 comparaciones de todas las variables incluidas en el modelo. En la Tabla 14 se resumen las cantidades más elevadas para cada variable.

Tabla 14

Valores de Cramer obtenidos del análisis de correlación.

Variable primaria	Variable secundaria	Cramer
Distancia al suelo urbano	Distancia a vías	0.341
Distancia a vías	Distancia a espacios recreativos	0.261
Susceptibilidad a deslizamientos	Pendiente	0.486
Distancia a mercados	Distancia a espacios recreativos	0.277
Distancia a centros educativos	Distancia a espacios recreativos	0.319
Distancia a espacios recreativos	Distancia a centros de salud	0.244
Distancia a relleno sanitario	Distancia a relleno sanitario	0.358
Distancia a cuerpos de agua	Distancia a terminal	0.199
Distancia a centros de salud	Distancia a terminal	0.221
Distancia a terminal	Pendiente	0.168

Fuente: elaboración propia.

Como se observa en la tabla anterior, los valores más altos en cualquiera de las variables escogidas para el modelamiento no superan los 0.5, por lo que se las puede considerar como independientes espacialmente, y por consiguiente, es justificado su incorporación en el modelo de crecimiento urbano de Macas propuesto.

Los parámetros calculados en el software Fragstats bajo el enfoque de fragmentación del paisaje sirvieron para definir el accionar de las autómatas celulares *Expander* y *Patcher*. Al analizar los valores para cada periodo, se pudo obtener una media para aproximar el tamaño del parche, así como su varianza, considerando para ello el área del parche, en cambio para la isometría del parche se tomó la dimensión fractal del parche. La cantidad resultante para el *Expander* de la dimensión fractal fue de 1.1, el mismo que significa una forma simple del parche por estar cercano

a la unidad; mientras que para el *Patcher* se propuso una isometría de 2, para representar un parche de una forma lo menos complicada posible. En cuanto a las distancias mínimas entre vecinos, la longitud promedio fue de 43.69 metros entre cada parche, el que fue incrementándose con cada periodo. Además, el índice de cohesión del parche obtenido de la media en los tres años analizados, fue de 98.75 lo cual indicaría un paisaje (mancha urbana) fragmentado ligeramente; sin embargo, esto puede deberse a que el área comprendida por la mancha urbana es pequeña en comparación a la zona de estudio, lo que ayudaría a que su valor sea extremadamente alto. En la Tabla 15 se resumen los valores calculados para los parámetros de fragmentación del paisaje, utilizados en el modelamiento.

Tabla 15

Estadísticas de los parámetros calculados de fragmentación del paisaje.

Período analizado	Tamaño del parche (ha)		Índice de dimensión fractal	Índice de cohesión	Distancia vecino más cercano
	Media	Varianza			
2001	1.165	3.265	1.073	98.84	34.54
2012	0.569	0.852	1.056	98.57	49.08
2020	0.629	1.121	1.058	98.85	47.46
Promedio	0.8	1.7	1.1	98.75	43.96

Fuente: elaboración propia.

Uno de los análisis más importantes antes de la simulación del crecimiento tendencial, fue la determinación del ratio *Expander/Patcher* para el presente estudio de investigación. Para ello se basó en los resultados del modelo de la Figura 34 y que fueron validados por la mínima similitud alcanzada. En este trabajo se probaron distintos ratios, desde 0.1 que corresponde a una baja expansión de parches existentes y alta generación de parches nuevos, hasta 0.9 que responde a una

alta expansión de parches existentes y baja generación de parches nuevos. Los resultados de la mínima similitud fueron obtenidos con el modelo de la Figura 35, y se resumen en la Tabla 16.

Tabla 16

Resultados de mínima similitud para la relación Expander/Patcher.

Ratio Expander/Patcher	Mínima similitud
0.1	0.248
0.2	0.238
0.3	0.234
0.4	0.239
0.5	0.200
0.6	0.212
0.7	0.222
0.8	0.204
0.9	0.186

Fuente: elaboración propia.

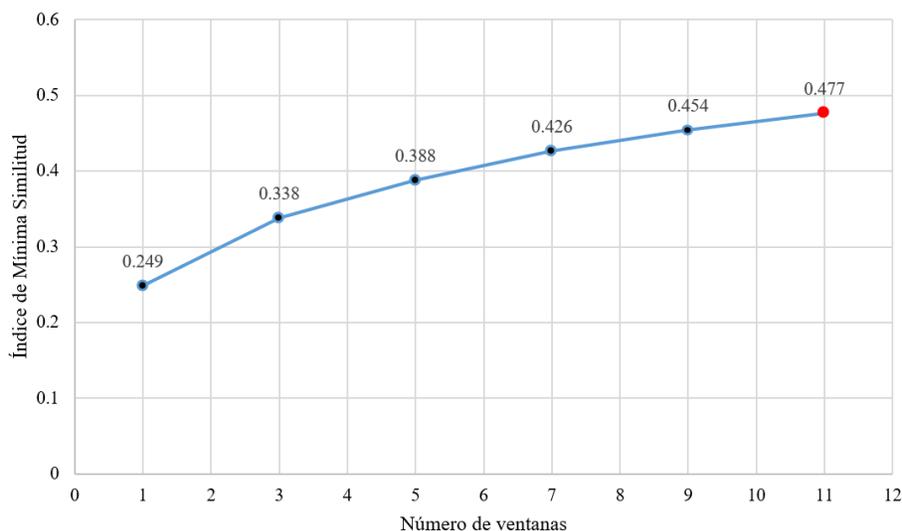
Según los resultados anteriores, el ratio que mejores condiciones presenta para el área de estudio corresponde a un valor de 0.1, lo que se traduce a un comportamiento predominante para la generación de nuevos parches, antes que la expansión de los existentes. Esto guarda lógica con las manchas urbanas de Macas obtenidas, principalmente en los años del 2012 y 2020, en las que se encuentran áreas urbanas dispersas y alejadas del clúster principal del suelo urbano, por lo que la autómatas celular analiza y predice el comportamiento del crecimiento de la ciudad bajo un principio de creación de nuevos núcleos urbanos.

Una vez definido el ratio para las autómatas celulares, se procede a analizar los resultados de esta primera simulación de crecimiento en el periodo de entrenamiento (2001 – 2012), mediante las distintas ventanas o niveles de tolerancia propuesto, que en este estudio se definieron un total

de 11, donde la primera ventana representa un nivel de tolerancia mínimo y que disminuye conforme se aumenta el número de ventanas. En la Figura 51 se observa el comportamiento del ajuste hallado en la validación de la etapa de entrenamiento del modelo con DINAMICA.

Figura 51

Resultados de la mínima similitud en la etapa de calibración del modelo.



Fuente: elaboración propia.

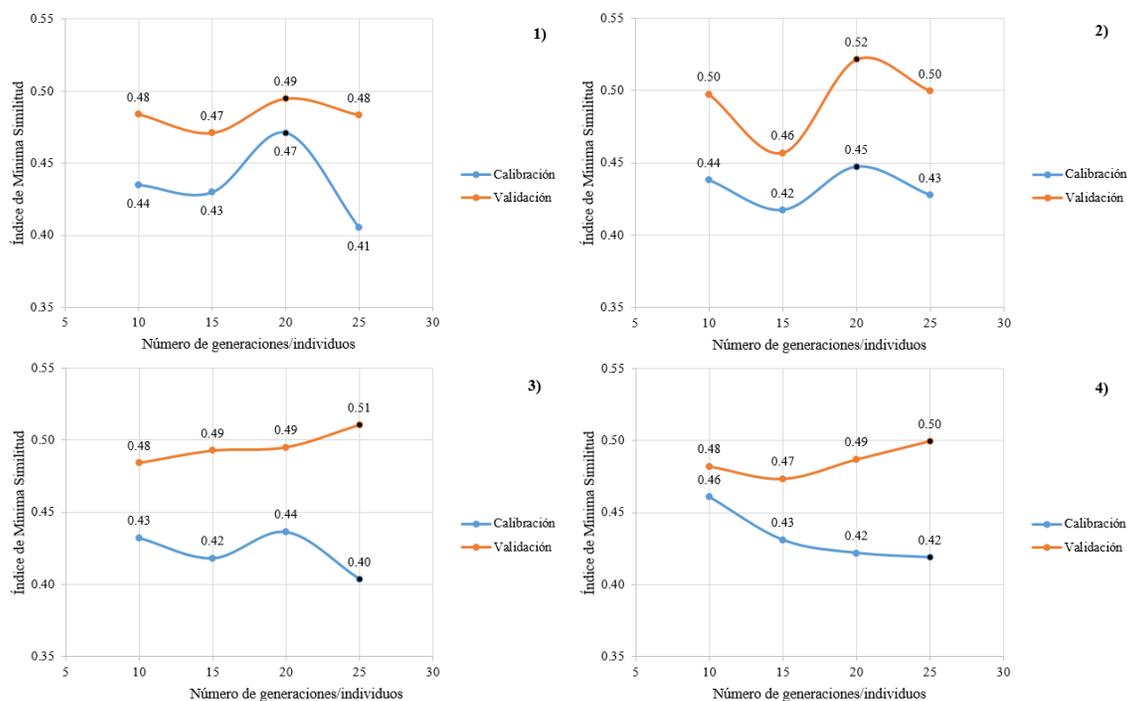
Como se observa en la figura anterior, el valor del índice de ajuste propuesto aumenta conforme el número de ventanas, debido al nivel de tolerancia que permite en su vecindario de búsqueda para validar. El número de ventanas fue definido para aproximar al tamaño de una manzana estándar en la ciudad (10000 m²), es decir, que el alcance de precisión del modelo con una ventana de 11 píxeles, responde a una simulación de crecimiento urbano por manzanas. Sin embargo, se busca reducir en lo mayor posible la superficie de predicción con un mejor ajuste en función al número de ventanas. Además, según lo mencionado por Piontekowski et al., (2012) para considerar un correcto ajuste del modelo de simulación, se debe alcanzar una similitud de al menos 50%, por lo que, los resultados del modelamiento de crecimiento de la Figura 51 sugieren la

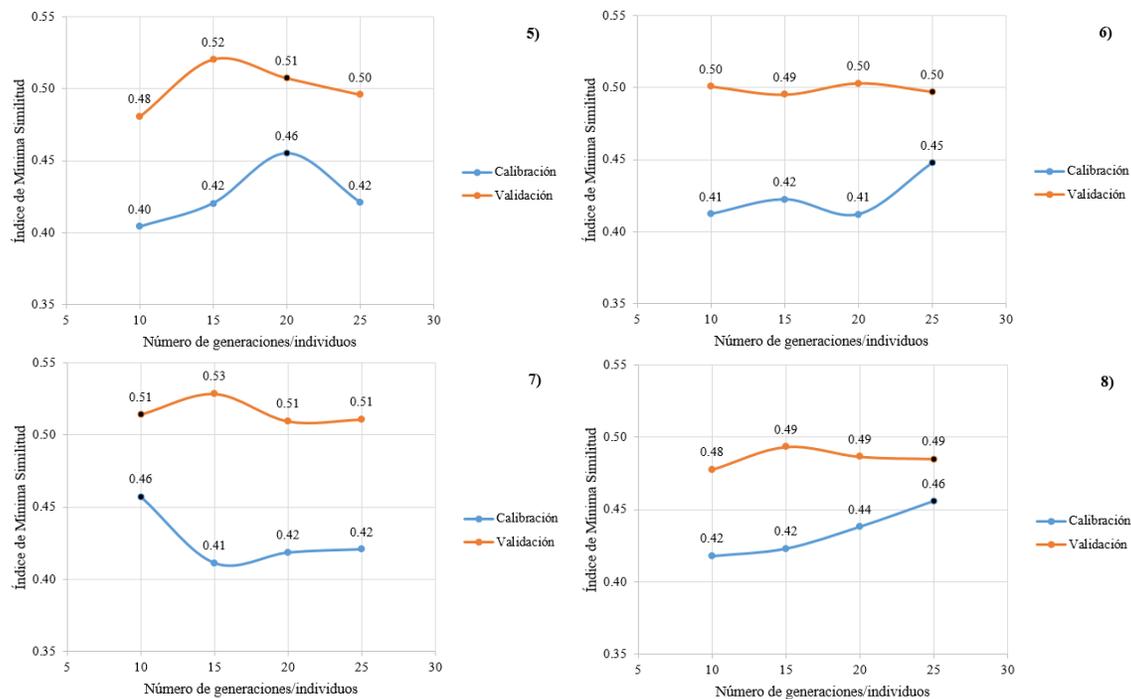
necesidad de optimizar y mejorar la simulación realizada, para lo cual se aplicó el método heurístico de algoritmos genéticos.

Mediante algoritmos genéticos, se realizaron varios escenarios para optimizar los coeficientes de los rangos de los pesos de evidencia, asignando para ello, distintos niveles de tolerancia o límites como son: $\pm 60\%$, 80% , 90% , 100% , 120% , 130% , 140% , 150% , cada uno con diversos números de generaciones e individuos (ver Figura 36), obteniendo como resultado nuevos coeficientes que sirvieron de input en el modelamiento de la calibración y validación. En la Figura 52 se muestra los resultados de la mínima similitud alcanzada en ambas etapas de la simulación de crecimiento urbano.

Figura 52

Comparación de resultados de mínima similitud entre límites de tolerancia vs. número de generaciones/individuos: 1) $\pm 60\%$, 2) $\pm 80\%$, 3) $\pm 90\%$, 4) $\pm 100\%$, 5) $\pm 120\%$, 6) $\pm 130\%$, 7) $\pm 140\%$, 8) $\pm 150\%$.





Fuente: elaboración propia.

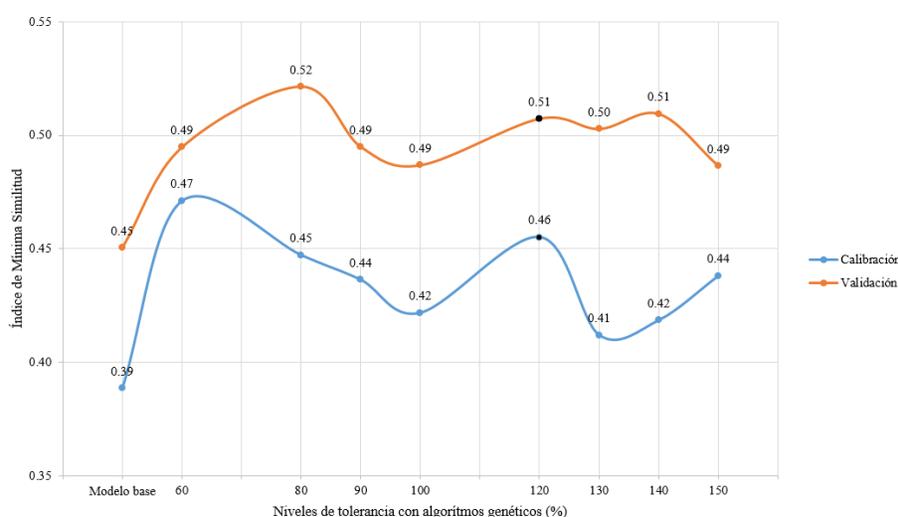
Como se observa en la figura anterior, en todos los casos analizados, la etapa de calibración es menor a la de validación, lo que representa que el modelamiento no presentó sobre especialización. Además, considerando que se asignó un número igual de generaciones e individuos, las gráficas demuestran que el comportamiento de la similitud no tiene relación con la cantidad de generaciones o individuos, sino más bien que va a depender del caso de estudio y la forma en que las autómatas entienden la dinámica de crecimiento. Es así que, de los resultados mostrados en la Figura 52, los valores de mayor índice de mínima similitud se alcanzan con 20 generaciones/individuos, y con los niveles de tolerancia de $\pm 80\%$ y 120% . En el escenario de $\pm 80\%$, se obtuvo en la etapa de calibración un 45% de similitud con el ráster original del año 2012, mientras que en la etapa de validación alcanzó el 52% de similitud con el ráster original del año 2020. Por su lado, con el escenario de $\pm 120\%$ se obtuvo un 46% de similitud en la etapa de calibración y un 51% de similitud en la validación de la simulación. En ambos casos, los modelos alcanzan el porcentaje mínimo de similitud (50%) para ser estadísticamente válidos, sin embargo,

en el segundo caso ($\pm 120\%$) se logró una menor diferencia de los índices de mínima similitud entre las etapas de calibración y validación, por lo que se escogió este límite como el mejor para este estudio.

Vale la pena mencionar que, se probaron otros valores de número de generaciones e individuos con 30 y hasta 50 en ambos casos, sin embargo, el coste computacional es demasiado elevado, sumado a que los resultados de mínima similitud no mejoraron, sino que decayeron o no hubo mayor diferencia, por lo que se descartaron valores mayores a 25 generaciones/individuos. Otro de los factores de gran relevancia al usar algoritmos genéticos, es la reducción en el número de ventanas en la validación de la mínima similitud, lo cual se refleja en la Figura 53, donde se compararon los resultados del modelo base (sin algoritmos genéticos) y los modelos optimizados con AG en sus distintos niveles de tolerancia con 20 generaciones/individuos, donde el tamaño mínimo de ventana que se obtuvo fue de 7×7 , alcanzando la precisión requerida para validar la simulación de crecimiento tendencial urbano de Macas.

Figura 53

Comparación de resultados de validación con un tamaño de ventana de 7 píxeles.

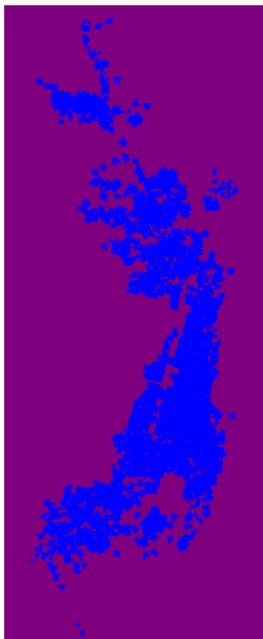


Fuente: elaboración propia.

En la figura anterior se puede confirmar claramente el cambio que existe entre el modelo sin utilizar algoritmos genéticos y los modelos que aplican este método de optimización, ya que el porcentaje logrado en la etapa de calibración de las simulaciones con AG se aproximan al valor de similitud alcanzado en la validación del modelo base, mientras que los valores de la validación de las simulaciones con AG superan ampliamente al modelo base (sin AG), por lo que se pudo mejorar el modelo de crecimiento urbano para la ciudad de estudio. El ráster resultante del proceso llevado a cabo en DINAMICA EGO se muestran en la Figura 54.

Figura 54

Modelo de predicción del crecimiento urbano de Macas en DIMANICA con algoritmos genéticos.



Fuente: elaboración propia.

4.4 Modelo óptimo de crecimiento urbano

Este apartado se centra en determinar cuál de los tres modelos generados con los distintos softwares y métodos, es el que mejores condiciones presenta, para lo que se procedió al cálculo y

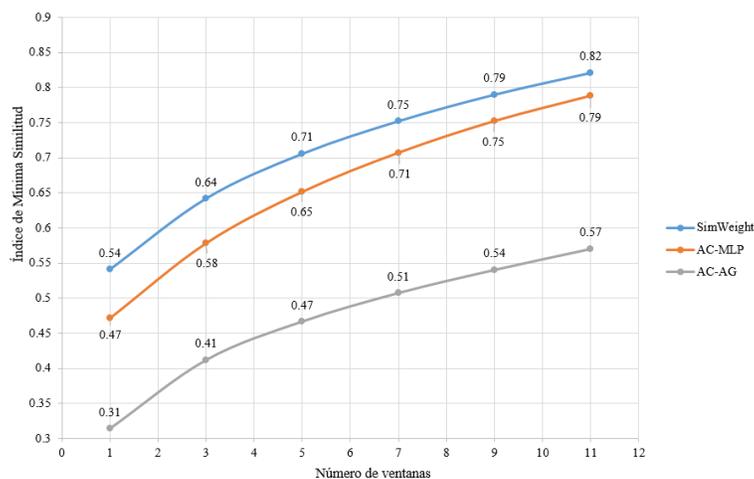
comparación del índice de mínima similitud, debido a que, como se explicó anteriormente, permite la validación del modelo con diferentes umbrales de ajuste (ventanas). Para ello, se compararon los modelos resultantes del estudio como son: autómatas celulares con perceptrón multicapa o MLP de MOLUSCE, SimWeight de Idrisi (LCM), y autómatas celulares con algoritmos genéticos de DINAMICA EGO.

En el caso de LCM y MOLUSCE, no se genera un nuevo ráster para la fase de calibración (2012), sino que el programa toma como base este ráster y solo produce un modelo para la fase de validación (2020). Lo opuesto sucede con DINAMICA que, en cambio, sí crea un ráster para la etapa de la calibración. Con esta premisa, la selección del modelo óptimo para el caso de estudio, fue el que alcanzó el valor más alto de similitud en la etapa de validación, entre el ráster original (2020) y el ráster generado (2020).

En la Figura 55 se muestran el comportamiento del ajuste mediante mínima similitud de los modelos generados con MOLUSCE, LCM y DINAMICA.

Figura 55

Selección del modelo óptimo para la simulación de crecimiento urbano futuro del lugar de estudio.



Fuente: elaboración propia.

En la figura anterior, se observa gráficamente la similitud que lograron los diversos modelos obtenidos en este trabajo de investigación. Se puede apreciar claramente que tanto los modelos generados con autómatas celulares (AC) con perceptrón multicapa (MLP) y SimWeight son los que mayor similitud presentan con el ráster base del año 2020. El modelo de SimWeight es el que muestra un mejor desempeño en la validación, ya que tiene el 54% de similitud al nivel de tolerancia más exigente de una ventana, y aumenta conforme el número de ventanas llegando a 75% y 82% con siete y once píxeles respectivamente. Por su parte, el modelo de MOLUSCE (AC – MLP) se acerca al porcentaje mínimo para aceptar el modelamiento con el límite más riguroso de ajuste, con el 47%, y al igual que el anterior modelo, su índice de mínima similitud se incrementa con el número de ventanas, siendo 71% con un tamaño de siete ventanas y 79% con once ventanas. Finalmente, el modelo obtenido con DIMANICA (AC – AG) es el que menor valor refleja en los estadísticos de similitud, con un 31% en el tamaño de una ventana, 51% con siete y 57% con once ventanas.

Si consideramos la resolución espacial del modelo (8.5 m) y el tamaño de ventana de 11 píxeles, la simulación arroja parches de nuevo suelo urbano a nivel de manzana, resultando en este caso, que todos los modelos pasan del 50% de similitud para ser aceptado el nuevo ráster. Este escenario se repite hasta un tamaño de ventana de 7 píxeles, donde el modelo de AC – AG no alcanza el porcentaje mínimo de similitud con un menor número de ventanas, mientras que los ráster generados con AC – MLP y SimWeight pasan la prueba hasta un tamaño de ventana de dos, donde el único que ajusta su modelo con más del 50% es SimWeight, respondiendo a la cuarta pregunta que orientó este trabajo.

Una posible explicación a lo mencionado en los párrafos anteriores, es que tanto en LCM como en MOLUSCE, el modelamiento parte del ráster del año intermedio (2012) hacia adelante,

por lo que es una “ventaja” el reducir los posibles errores o poca fuerza explicativa de las variables elegidas para el entrenamiento del modelo. Esto último no se puede generalizar, ya que dependerá de la morfología de la mancha urbana, su dispersión en el espacio y las variables que se incluyan en las simulaciones de cada estudio. En el caso de DINAMICA EGO, la flexibilidad que brinda el software para que el investigador pueda configurar el modelo con parámetros propios es una potencialidad para este tipo de análisis, además, de que se produce un ráster para cada etapa de la simulación, con lo que de cierto modo es un indicativo para inferir cuan explicativas son las variables que se están usando.

En el caso de la ciudad de Macas, la mancha urbana presentaba pequeños polígonos de suelo urbano lejos del clúster principal; esta determinante quizás no tuvo muchas repercusiones en el modelamiento con LCM o MOLUSCE, empero, con DINAMICA al ser un entrenamiento más experto desde la etapa de calibración, los pequeños polígonos urbanos produjeron mayores sesgos en la capacidad de las autómatas celulares en entender la dinámica del crecimiento urbano de la urbe.

Además, las variables incluidas en la simulación, a pesar de aprobar los diferentes test estadísticos (V de Cramer, e índice de Cramer), se podría inferir que en el caso de DINAMICA, las variables no fueron lo suficientemente explicativas para que generen una mejor calibración y, por ende, su validación. Por otro lado, vale la pena señalar que, las variables que ingresaron en el modelamiento de MOLUSCE y LCM fueron reconocidas como estáticas en su totalidad, y esto se debe a que en el primer método no permite la inclusión de otra clase de variable; en LCM si existe la opción de trabajar con variables dinámicas, sin embargo, se requiere ingresar valores específicos desconocidos y que necesitan de un criterio más experto. Solo en DINAMICA se configuró las vías como variable dinámica.

De los tres métodos aplicados: AC – MLP, AC – AG y SimWeight, para la simulación de crecimiento urbano de Macas, el aprendizaje basado en instancias ponderadas por similitud (SimWeight), fue el que escogido como el modelo más idóneo por los resultados alcanzados en la validación del modelo. Esta técnica no paramétrica, obtuvo un mejor desempeño en la generación del potencial de transición, y puede deberse a la matemática usada para reconocer las variables irrelevantes al modelo (Tahir et al., 2007), ya que SimWeight multiplica a cada variable por una ponderación proporcional a la capacidad de discriminar una transición o clase (píxeles persistentes y cambiantes) (Gómez et al., 2007), lo cual realiza mediante la ecuación (8). Además, gracias a su estructura simple de cómputo, solo necesita el valor de k para su trabajo, simplificando el cálculo del potencial de transición sin la necesidad de ajustar demasiados parámetros, como en el caso de MLP o AC – AG. El valor de k fue de 100, ya que según Sangermano et al., (2010), optimiza el rendimiento de predicción del modelo con el tiempo que tarda en su obtención, lo que se vio reflejado en el valor de ROC comparado a MLP (de LCM) y el índice de mínima similitud versus a AC – MLP y AC – AG.

Una de las ventajas que se pudo notar en el modelo de SimWeight frente al resto de técnicas aplicadas, es que gracias a su ponderación basada en la capacidad de detección del cambio de las variables, se puede determinar claramente cuáles fueron las que aportaron en mayor medida al potencial de transición del crecimiento urbano de Macas, siendo la distancia a vías, pendientes y distancia a espacios recreativos las más importantes. Además, este mismo análisis, permite discriminar aquellas variables que no aportan energía al modelo o que son irrelevantes al cambio de clase, como fueron la distancia al terminal y relleno sanitario (ver Figura 46).

Desde un punto de vista más general del presente estudio, se puede decir que, en cuanto a las cuatro técnicas que presenta MOLUSCE, el modelo obtenido con redes neuronales – MLP

combinado con autómatas celulares (AC – MLP) fue el que mejor resultado alcanzó, motivo por el cual fue escogido para compararlo con los otros modelamientos. El hecho de que AC – MLP haya sido el que ajustó de mejor forma el crecimiento urbano de Macas (en MOLUSCE), concuerda con lo hallado en los resultados de LCM, ya que de sus tres métodos: LR, MLP y SimWeight, las redes neuronales con MLP alcanzaron el segundo mejor rendimiento, conclusión similar a la que llegó Eastman et al., (2005), quienes compararon varias técnicas (pesos de evidencia, probabilidades empíricas, regresión logística y redes neuronales – MLP), y determinaron que MLP modeló de mejor forma el potencial de transición. Sin embargo, para este caso de estudio, SimWeight obtuvo un mejor rendimiento que MLP por las determinaciones mencionadas en el párrafo anterior, y en consecuencia, fue seleccionado como el modelo óptimo para modelar el crecimiento tendencial urbano de Macas. Por su parte DINAMICA EGO permitió una configuración más experta de los parámetros del estudio, empero, debido a las circunstancias propias de la mancha urbana de la ciudad, pudieron haber sesgado el comportamiento de las autómatas celulares, resultando en un modelo de crecimiento aceptable estadísticamente (según la mínima similitud con un tamaño de hasta siete ventanas), pero menos preciso, en comparación a AC – MLP y SimWeight. Finalmente, el modelo de crecimiento tendencial urbano para Macas al año 2030 obtenido con SimWeight, se observa en la Figura 56. La matriz de probabilidades de cambio al año horizonte que resulta de la cadena de Markov, se muestran en la Tabla 17.

Tabla 17

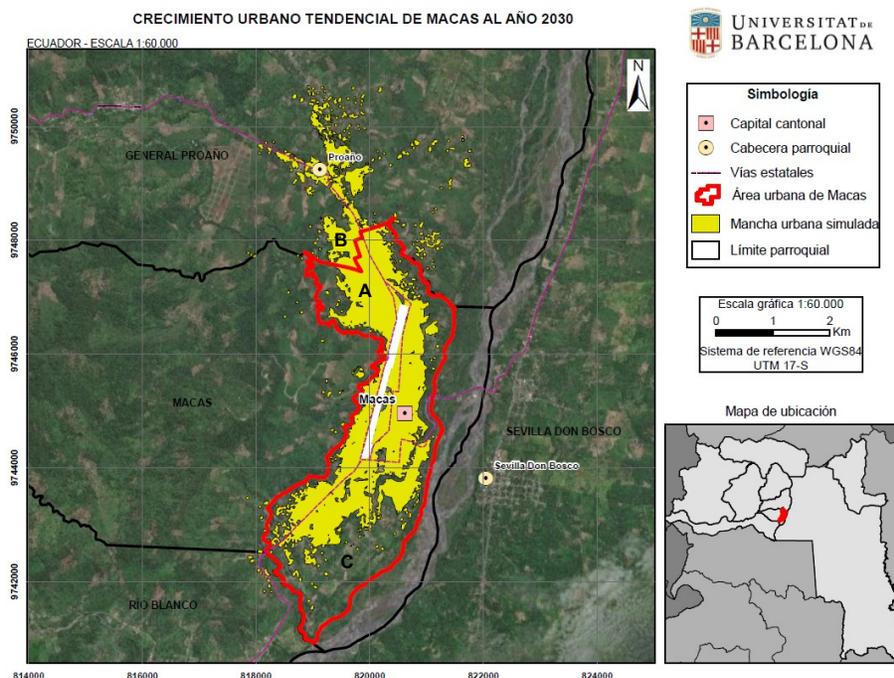
Probabilidades de transición con MC para SimWeight al 2030.

Uso/Uso	No urbano	Urbano
No urbano	0.9256	0.0744
Urbano	0	1

Fuente: elaboración propia.

Figura 56

Modelo resultante de crecimiento urbano mediante SimWeight.



Fuente: elaboración propia.

Del modelo generado para el crecimiento tendencial de Macas, se evidencia que la dinámica de expansión de la mancha urbana horizontal es hacia el Norte de la urbe, especialmente en la parte Noroccidental del área urbana de la ciudad, donde se encuentran los barrios: La Florida, Sangay, Norte, 5 de Octubre y Jardín del Upano (punto A de la Figura 56), y en la zona contigua al polígono urbano de Macas que pertenece a la parroquia de General Proaño (punto B de la Figura 56). Además, se denota que la tendencia de ocupación del suelo urbano, deja espacios vacantes sin urbanizar, principalmente al sur la ciudad (barrios El Rosario y Remigio Madero), lo cual puede deberse a la presencia del relleno sanitario en este sector (punto C de la Figura 56).

Para entender de mejor manera cómo ha venido aumentando la mancha urbana de Macas en el tiempo, se utilizó el índice de expansión del paisaje o Landscape expansion index (LEI), el cual fue propuesto por Liu et al., (2010) para estudiar el cambio multitemporal de los patrones del

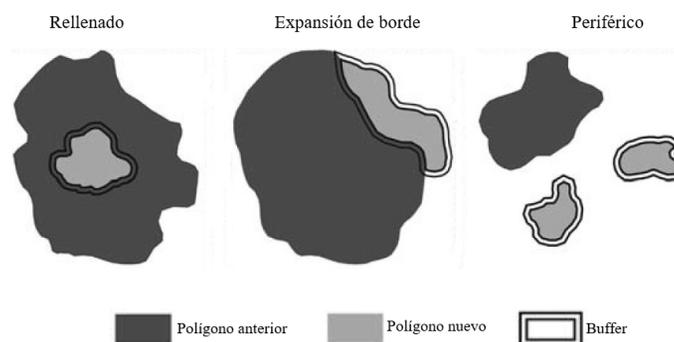
paisaje urbano. LEI permite analizar con mayor facilidad el proceso de cambio del parche urbano y su forma de hacerlo, mediante una examinación de las características del buffer alrededor de los polígonos urbanos anteriores y nuevos. Para ello, aplica la siguiente fórmula:

$$LEI = \frac{A_o}{A_o + A_v} * 100 \quad (32)$$

donde A_o es el área del buffer intersecado con una clase del suelo (urbano), A_v es el área del buffer que interseca con la clase de suelo vacante (no urbano). El valor de LEI está entre $0 \leq LEI \leq 100$, y permite identificar tres tipos de expansión del paisaje más importantes, como son: rellenado, periférico, y expansión de borde (hay más variantes, pero se derivan de estos) (Wilson et al., 2003). El rellenado ocupa los espacios libres dentro de un polígono anterior, el periférico se forma separado del polígono anterior, y la expansión de borde está adyacente al polígono anterior (ver Figura 57). También se calculó el índice de expansión medio (MEI), el mismo que promedia el valor de LEI de los nuevos polígonos de suelo urbano, sobre el número total de parches, y sirve como un parámetro para cuantificar la compactación o expansión tendencial del paisaje, con un valor más grande o pequeño, respectivamente (Liu et al., 2010).

Figura 57

Tipologías de expansión del paisaje.



Fuente: adaptado de Liu et al., (2010).

Se examinó el tipo de expansión ocurrido en Macas en los tres periodos de tiempo, 2001 – 2012, 2012 – 2020 y 2020 – 2030. El resumen de los resultados de LEI se muestra en la Tabla 18.

Tabla 18

Caracterización de la tipología de expansión del paisaje en Macas.

	2001 – 2012		2012 – 2020		2020 – 2030	
	Área (ha)	%	Área (ha)	%	Área (ha)	%
Rellenado	0.022	0.013	71.292	34.831	162.286	91.638
Expansión de borde	74.634	44.631	83.631	40.859	12.156	6.864
Periférico	92.569	55.356	49.758	24.310	2.653	1.498
MEI	4.663		18.454		26.187	

Fuente: elaboración propia.

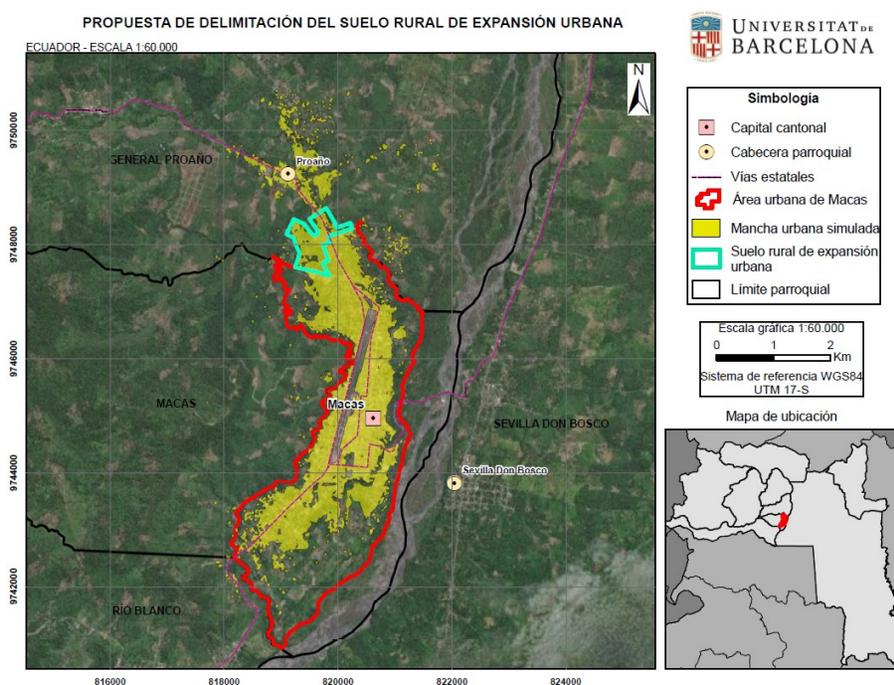
Según los valores de la tabla anterior, se tiene que en el primer periodo, la mancha urbana de Macas creció de una forma predominantemente dispersa en el territorio, seguida de una expansión de borde y muy poco relleno. El segundo periodo de tiempo la expansión de borde es ligeramente mayor, seguido del relleno, y una disminución en el periférico. Mientras que en el periodo horizonte del estudio (año 2030), se prevé que la tipología de relleno sea la principal, continuado por una expansión de borde y poca dispersión. El valor de MEI, además sugiere que el mayor incremento de la mancha urbana se presenta en el periodo de tiempo 2001 – 2020 y para el año 2030 se prevé una expansión no tan abrupta.

Basado en el análisis de LEI, se puede tomar como referencia la caracterización del paisaje urbano de Macas para cubrir uno de los objetivos específicos del presente trabajo, que fue la propuesta de una delimitación de suelo rural de expansión urbana, como lo estipula la LOOTUGS. Llama la atención que, ni en ley ni en su reglamento, no se proporciona un estándar urbanístico o lineamiento para definir esta subclasificación del suelo, por lo que es uno de los vacíos pendientes

en la normativa ecuatoriana vigente. En este sentido, con el resultado de la Figura 56 y tomando como premisa que la tipología de expansión del paisaje para el 2030 sería de relleno, el suelo rural de expansión urbana estaría definido en el área adscrita a la zona urbana actual de la ciudad en su parte Norte, como se muestra en la Figura 58.

Figura 58

Propuesta de delimitación del suelo rural de expansión urbana.



Fuente: elaboración propia.

El área de este polígono propuesto es de 57.98 ha, de las cuales el 57.93% (33.59 ha) se asientan sobre suelo apto para el pastoreo y el 42.07% (24.39 ha) restante, es suelo antropizado, por lo que no habría un impacto considerable a la cobertura vegetal circundante de la ciudad. Además, si se considera el total del área de estudio, la superficie que abarca la mancha urbana en 2020 (743.09 ha) y en el año horizonte (795.56 ha), se tiene una tasa de crecimiento de 5.24 ha/año; mientras que, si se analiza únicamente el área urbana actual de la ciudad, la superficie que cubre la mancha urbana en 2020 (537.45 ha) y 2030 (621.46 ha), se tiene una tasa anual de cambio de

8.4 ha. En la Tabla 19, se resume el cambio temporal de la superficie de la mancha urbana de Macas hasta el año horizonte, dando respuesta a una pregunta orientadora del estudio.

Tabla 19

Superficie de la mancha urbana de Macas en el periodo de estudio.

Año de referencia	Área mancha urbana (ha)	%
2001	379.35	9.45
2012	547.22	13.64
2020	743.09	18.52
2030	795.56	19.83

Fuente: elaboración propia.

El resultado de este estudio, es un insumo fundamental para un análisis de prospectiva territorial, ya que si bien, el modelo propone una tendencia a crecer fuera del área urbana actual de la ciudad, esto dependerá del modelo de ciudad que se quiera alcanzar. Por ello, a pesar de ser factible una propuesta de delimitación del suelo rural de expansión urbana bajo el supuesto del crecimiento tendencial, no quiere decir que sea lo ideal para la planificación urbana de Macas, debido a que, solo considerando la superficie del polígono urbano actual (1175.78 ha), la mancha urbana del 2030 y manteniendo la tasa de cambio calculada (8.4 ha/año), existiría suelo urbano vacante para aproximadamente 20 años más (sin considerar el suelo de protección, determinado en el PAUOS). La importancia de esta investigación, radica en que brinda un soporte técnico – científico para la toma de decisiones, y la generación de políticas que conduzcan a un modelo de ciudad deseado y sostenible en el tiempo, adhiriéndose a los nuevos paradigmas, como el crecimiento hacia adentro de Medellín (Quesada, 2006), la supermanzana (Rueda, 2009), u otras formas de planeamiento urbano.

Capítulo V: Conclusiones y Recomendaciones

5.1 Conclusiones

- De los tres métodos de modelación espacial multivariable utilizados en este estudio: autómatas celulares con redes neuronales – perceptrón multicapa (AC – MLP), autómatas celulares con algoritmos genéticos (AC – AG) y aprendizaje basado en instancias ponderadas por similitud (SimWeight), el índice de mínima similitud mostró que todos son estadísticamente aceptables hasta un nivel de tolerancia con siete ventanas, de seis a dos ventanas sólo se ajustaron AC – MLP y SimWeight, y al nivel más riguroso de similitud, únicamente el modelo SimWeight es el que alcanzó el límite mínimo para ser validado, por lo que fue el mejor modelo en esta investigación.
- Con el método SimWeight se determinó que las variables con mayor incidencia en la expansión urbana de Macas, son la cercanía a vías, las pendientes y la distancia a espacios recreativos, respondiendo así a una de las preguntas orientadoras de la investigación.
- Mediante la probabilidad de transición obtenida con la cadena de Markov y SimWeight, se generó el modelo de crecimiento urbano tendencial para Macas al año 2030, cumpliendo con el objetivo del estudio, el mismo que sugiere una orientación hacia la parte Norte de la ciudad.
- Con el modelamiento de la mancha urbana, fue factible delimitar una propuesta para el suelo rural de expansión urbana, que resulta de los patrones actuales de ocupación, por lo que se puede decir, que la hipótesis planteada es verídica. Sin embargo, a pesar de identificar cual sería el suelo urbano en el futuro, es necesario considerar otros criterios que ayuden a delimitar este polígono, como el índice de edificabilidad, densidad

poblacional, y principalmente el modelo de ciudad que se espera tener, puesto que, esto influirá en las políticas dictadas para el desarrollo de la urbe.

- El resultado de la simulación, se enmarca dentro de un análisis prospectivo, el cual es una herramienta válida para la planificación urbana de Macas, la misma que permitirá a los tomadores de decisiones, prever posibles escenarios y corregir las falencias que han existido en la ordenación del territorio. Una gran oportunidad para la inclusión de este tipo de investigaciones, se tiene en la presente actualización del PDOT y PUGS del cantón, que se está desarrollando a la fecha de esta investigación.

5.2 Recomendaciones

- En este estudio se definieron dos categorías de suelo para el análisis de transición: urbano y no urbano, por lo que sería interesante realizar el mismo procedimiento con más de dos clases y determinar cuál de las coberturas del suelo existentes es la que se afectaría en mayor medida.

Referencias

- Abrams, M., y Hook, S. (2001). *ASTER Users Handbook*. California. Jet Propulsion Laboratory/California Institute of Technology.
- Achmad, A., Hasyim, S., Dahlan, B., y Aulia, D. (2015). Modeling of urban growth in tsunami-prone city using logistic regression: Analysis of Banda Aceh, Indonesia. *Applied Geography*, 62, 237-246. doi:10.1016/j.apgeog.2015.05.001
- Aguilera, F., Gómez, M., y Cantergiani, C. (2010). Instrumentos de simulación prospectiva del crecimiento urbano. *Ciudad y Territorio Estudios Territoriales*, XLII (165-166), 481-495.
- Aguilera, F., Valenzuela, L., y Bosque, J. (2010). Simulación de escenarios futuros en la aglomeración urbana de Granada a través de modelos basados en Autómatas Celulares. *Boletín de la Asociación de Geógrafos Españoles*, (54), 271-300.
- Ahmed, S., y Bramley, G. (2015). How will Dhaka grow spatially in future?-Modelling its urban growth with a near-future planning scenario perspective. *International Journal of Sustainable Built Environment*, 4, 359-377. doi:10.1016/j.ijbe.2015.07.003
- Albuquerque, A., Melo, J., y Dória, A. (2005). Evolutionary computation and parallel processing applied to the design of multilayer perceptrons. En N. Nedjah, y L. Mourelle (eds.), *Evolvable Machines: Theory and Practice (Studies in Fuzziness and Soft Computing)* (pp. 181-203). Heidelberg: Springer-Verlag.
- Ali Dereli, M. (2018). Monitoring and Prediction of Urban Expansion Using Multilayer Perceptron Neural Network by Remote Sensing and GIS Technologies: A Case Study From Istanbul Metropolitan City. *Fresenius Environmental Bulletin*, 27 (12A), 9336-9344.

- Allen, J., y Lu, K. (2003). Modeling and prediction of future urban growth in the Charleston Region of South Carolina: A GIS-based integrated approach. *Conservation Ecology*, 8 (2), 2. doi:10.5751/ES-00595-080202
- Almeida, M., Batty, M., Vieira, A., Câmara, G., Soares, B., Cerqueira, G., y Pennachin, C. (2003). Stochastic cellular automata modeling of urban land use dynamics: empirical development and estimation. *Computers, Environment and Urban Systems*, 27 (5), 481-509. doi:10.1016/S0198-9715(02)00042-X
- Álvarez, G. (2010). El crecimiento urbano y estructura urbana en las ciudades medias mexicanas. *Quivera*, 12 (2), 94-114.
- Aneesha, B., Shashi, M., y Deva, P. (2020). Future land use land cover scenario simulation using open source GIS for the city of Warangal, Telangana, India. *Applied Geomatics*. doi:10.1007/s12518-020-00298-4
- Arsanjani, J. (2011). *Dynamic land use/cover change modelling: Geosimulation and multiagent-based modelling*. Berlín: Springer Science & Business Media.
- Arsanjani, J., Kainz, W., y Mousivand, A. (2011). Tracking dynamic land-use change using spatially explicit Markov Chain based on cellular automata: The case of Tehran. *International Journal of Image and Data Fusion*, 2 (4), 329-345. doi:10.1080/19479832.2011.605397
- Asamblea Constituyente. (2008). *Constitución de la República del Ecuador 2008*. Montecristi: Registro Oficial 449 de 20-oct-2008.
- Asamblea Nacional. (2010). *Código Orgánico de Organización del Territorio, Autonomía y Descentralización, COOTAD*. Quito: Registro Oficial Suplemento 303.

Asamblea Nacional. (2010). *Código Orgánico de Planificación y Finanzas Públicas, COPFP*.

Quito: Registro Oficial Suplemento 306.

Asamblea Nacional. (2016). *Ley Orgánica de Ordenamiento Territorial, Uso y Gestión de Suelo*.

Quito: Registro Oficial N° 790.

Asamblea Nacional. (2018). *Reglamento a la Ley Orgánica del Sistema Nacional de Infraestructura Vial del Transporte Terrestre*. Quito: Registro Oficial Suplemento 278.

Avalos, A., Gómez, M., Aguilera, F., y Flores, F. (2019). Simulación del crecimiento urbano de la zona metropolitana Tepic-Xalisco, México. *Estudios Geográficos*, 80 (287), e021. doi:10.3989/estgeogr.201938.018

Barredo, J., Demicheli, L., Lavalle, C., Kasanko, M., y McCormick, N. (2004). Modelling Future Urban Scenarios in Developing Countries: An Application Case Study in Lagos, Nigeria. *Environment and Planning B: Planning and Design*, 31 (1), 65-84. doi:10.1068/b29103

Barreira, P., Gómez, M., y Aguilera, F. (2015). Simulación del crecimiento urbano y modelos basados en autómatas celulares: el uso de parcelas catastrales vectoriales a partir de la teoría de grafos. En J. Riva, P. Ibarra, R. Montorio, y M. Rodrigues (eds.), *Análisis espacial y representación geográfica: innovación y aplicación* (pp. 511-520). Zaragoza: Universidad de Zaragoza-AGE.

Barruecos, D. (1959). *Historia de Macas*. Cuenca: Editorial Don Bosco.

Bazant, J. (2010). Expansión urbana incontrolada y paradigmas de la planeación urbana. *Espacio Abierto*, 475-503.

Benabent, M. (2019). La clasificación urbanística del espacio de transición urbano/rural en la legislación del suelo del Ecuador. *Eídos*, 14 (1), 3-19. doi:10.29019/eidos.v14i1.603

- Benabent, M., y Vivanco, L. (2019). La experiencia de los Planes de Desarrollo y Ordenamiento Territorial cantonales en Ecuador. *Estoa*, 8 (15), 133-144. doi:10.18537/est.v008.n015.a11
- Berberoglu, S., Akın, A., y Clarke, K. (2016). Cellular automata modeling approaches to forecast urban growth for Adana, Turkey: A comparative approach. *Landscape and Urban Planning*, 153, 11-27. doi:10.1016/j.landurbplan.2016.04.017
- Bonham, G. (1994). *Geographic Information Systems for Geoscientists: Modelling with GIS* (1era ed., Vol. 13). Pergamon: Ottawa.
- Broese, E., y Löffler, H. (2004). Artificial neural network. En D. Raabe, F. Roters, F. Barlat, y L. Chen (eds.), *Continuum Scale Simulation of Engineering Materials: Fundamentals-Microstructures-Process Applications* (pp. 185-198). Weinheim: Wiley-VCH Verlag.
- Bununu, Y. (2017). Integration of Markov chain analysis and similarity-weighted instance-based machine learning algorithm (SimWeight) to simulate urban expansion. *International Journal of Urban Sciences*, 21 (2), 217-237. doi:10.1080/12265934.2017.1284607
- Cabrero, F. (2017). Arqueología amazónica en Ecuador: Avances en una zona poco explorada. *SATHIRI*, 12 (1), 197-211.
- Cadavid, G. (2009). Ruralidad en contextos metropolitanos, un desafío en procesos de planeación, ordenamiento territorial y gestión. *Revista Soluciones de Postgrado EIA*, (4), 243-266.
- Cantergiani, C., y Gómez, M. (2016). Diseño de un modelo basado en agentes para simular el crecimiento urbano en el Corredor del Henares (Comunidad de Madrid). *Boletín de la Asociación de Geógrafos Españoles*, (70), 25-283.
- Cárdenas, S., y Cueva, R. (2004). *Cronología del Cantón Morona*. Quito: Editorial Pedro Jorge Vera, Casa de la Cultura Ecuatoriana.

- Carrera, T. (1987). *Historia de la Tierra de los Macas*. Macas: Instituto de Historia Eclesiástica Ecuatoriana.
- CEPAL. (2013). *Guía: Análisis del sistema urbano regional para el ordenamiento territorial*. Santiago: Centro de Documentación y Publicaciones, CEDOC, SUBDERE.
- Cepeda, M., Palacios, I., Tierra, A., y Kirby, E. (2018). Multiresolution analysis in the visible spectrum of Landsat-TM images through Wavelet Transform. *Geographia Technica*, 13 (1), 20-29. doi:10.21163/GT_2018.131.03
- Cerda, J. (2007). *La expansión urbana discontinua analizada desde el enfoque de accesibilidad territorial aplicada a Santiago de Chile* [Tesis de maestría, Universidad Politécnica de Cataluña].
- Cifuentes, P., y Londoño, J. (2010). Análisis del crecimiento urbano: Una aproximación al estudio de los factores de crecimiento de la ciudad de Manizales como aporte a la planificación. *Gestión y Ambiente*, 13 (1), 53-66.
- Cohen, J. (1960). Coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20 (1), 37-46. doi:10.1177/001316446002000104
- CONALI. (2018). *Límites de la organización territorial del Estado: Niveles Provincial y Cantonal*. Quito: Secretaría Técnica del Comité Nacional de Límites Internos.
- Costales, A., y Costales, P. (1998). *Historia de Macas en el Departamento del Sur y la República (1822-1922)*. Quito: Casa de la Cultura Ecuatoriana.
- Costales, P., y Costales, A. (1996). *Historia colonial del Gobierno de Macas* (1era. ed.). Quito: Casa de la Cultura Ecuatoriana.
- De Guerrero, M. (2011). *La ciudad existente: delimitación del suelo urbano y en sustitución de urbanizado*. Madrid: Iustel.

- De Oliveira, B., Da Costa, E., Carvalho, S., y Maia, P. (2020). Land use dynamics and future scenarios of the Rio Doce State Park buffer zone, Minas Gerais, Brazil. *Environ Monit Assess*, 192, 39. doi:10.1007/s10661-019-8016-9
- Eastman, J. (2012). *Idrisi Selva. Guía para SIG y Procesamiento de Imágenes*. <http://clarklabs.org/wp-content/uploads/2016/10/IDRISI-Selva-Spanish-Manual.pdf>
- Eastman, J., y Toledano, J. (2018). A Short Presentation of the Land Change Modeler (LCM). En M. Camacho, P. M., M. J., y E. F., *Geomatic Approaches for Modeling Land Change Scenarios. Lecture Notes in Geoinformation and Cartography* (pp. 499-505). Cham: Springer. doi:10.1007/978-3-319-60801-3_36
- Eastman, J., Van Fossen, M., y Solorzano, L. (2005). Transition potential modeling for land cover change. En D. Maguire, J. Batty, y M. Goodchild (eds.), *GIS, Spatial Analysis and Modeling* (pp. 357-386). Redlands: ESRI Press.
- ESA. (2020). *Spatial Resolution Sentinel-2 MSI*. <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi/resolutions/spatial>
- Esteban, J. (1998). *Elementos de ordenación urbana* (1era. ed.). Madrid: Edicions UPC.
- Esteban, J. (2011). *La ordenación urbanística: conceptos, herramientas y prácticas*. Barcelona: Publicacions Acadèmiques Digitals de la UPC.
- Feng, H., Liu, H., y Lü, Y. (2012). Scenario prediction and analysis of urban growth using SLEUTH model. *Pedosphere*, 22 (2), 206-216. doi:10.1016/S1002-0160(12)60007-1
- Florinsky, I., y Kuryakova, G. (2000). Determination of grid size for digital terrain modelling in landscape investigations - exemplified by soil moisture distribution at a micro-scale. *International Journal of Geographical Information Science*, 14 (8), 815-832. doi:10.1080/136588100750022804

- Forrest, S. (1996). Genetic algorithms. *ACM Computing Surveys*, 28, 77-88.
- GAD Morona. (2004). *Actualización del Plan de Desarrollo Estratégico Cantonal, Morona 2004*. Macas.
- GAD Morona. (2012). *Plan Cantonal de Desarrollo y Ordenamiento Territorial Morona 2012-2020*. Macas.
- GAD Morona. (2015). *Actualización del Plan Cantonal de Desarrollo y Ordenamiento Territorial Morona 2015-2019*. Macas.
- GAD Morona. (2016). *Ordenanza de actualización de la delimitación de la zona urbana de la ciudad de Macas, cabecera cantonal de Morona y de creación del área urbana y de expansión urbana de las cabeceras parroquiales de General Proaño, San Isidro y Río Blanco*. Macas.
- GAD Morona. (2016). *Plan de Actualización de Uso y Ocupación del Suelo, Macas 2016*. Macas.
- GAD Morona. (2019). *Ordenanza que sanciona el Plan de Actualización del Uso y Ocupación del Suelo de la ciudad de Macas, PAUOS-M*. Macas.
- Gantumur, B., Wu, F., Vandansambuu, B., Tsegmid, B., Dalaibaatar, E., y Zhao, Y. (2020). Spatiotemporal dynamics of urban expansion and its simulation using CA-ANN model in Ulaanbaatar, Mongolia. *Geocarto International*, 1-16. doi:10.1080/10106049.2020.1723714
- Geertman, S., Hagoort, M., y Ottens, H. (2007). Spatial-temporal specific neighbourhood rules for cellular automata land-use modelling. *International Journal of Geographical Information Science*, 21 (5), 547-568. doi:10.1080/13658810601064892
- Gil de Pareja, C. (2011). *Transformación de suelo. La práctica del planeamiento y su gestión* (1er. ed.). Murcia: Fund. Universitaria San Antonio.

- Goldberg, D. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Reading: Addison-Wesley.
- Gómez, D. (2002). *Ordenación Territorial* (2da ed.). Barcelona: Ediciones Mundi-Prensa.
- Gómez, D., y Gómez, M. (2016). Marco conceptual para la ordenación territorial y reflexiones sobre el proceso ecuatoriano en la materia. *Autonomías y Desarrollo Territorial y Urbanístico: Memorias del IX simposio nacional de desarrollo urbano y planificación territorial* (pp. 45-67). Cuenca.
- Gómez, O., Morales, E., y González, J. (2007). Weighted Instance-based learning using representative intervals. En A. Gelbukh, K. Morales, y A. Fernando (eds.), *Advances in Artificial Intelligence: Proceedings of the Sixth Mexican International Conference on Artificial Intelligence* (Vol. 4827, pp. 420-430). Aguascalientes: Springer-Verlag.
- Goodacre, A., Bonhamr, G., Agterberg, F., y Wright, D. (1993). A statistical analysis of the spatial association of seismicity with drainage patterns and magnetic anomalies in western Quebec. *Tectonophysics*, 217 (3-4), 285-305. doi:10.1016/0040-1951(93)90011-8
- Gounaridis, D., Choriantopoulos, I., y Koukoulas, S. (2018). Exploring prospective urban growth trends under different economic outlooks and land-use planning scenarios: The case of Athens. *Applied Geography*, 90, 134-144. doi:10.1016/j.apgeog.2017.12.001
- Grekousis, G., Manetos, P., y Photis, Y. (2013). Modeling urban evolution using neural networks, fuzzy logic and GIS: The case of the Athens metropolitan area. *Cities*, 30, 193-203. doi:10.1016/j.cities.2012.03.006
- Hamdy, O., Zhao, S., Salheen, M., y Eid, Y. (2017). Analyses the Driving Forces for Urban Growth by Using IDRISI®Selva Models Abouelreesh — Aswan as a Case Study. *International Journal of Engineering and Technology*, 9 (3), 226-232. doi:10.7763/IJET.2017.V9.975

- Hengl, T. (2006). Finding the right pixel size. *Computers & Geosciences*, 32 (9), 1283-1298.
doi:10.1016/j.cageo.2005.11.008
- Holland, J. (1975). *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. Cambridge: MIT Press.
- Hu, Z., y Lo, C. (2007). Modeling urban growth in Atlanta using logistic regression. *Computers, Environment and Urban Systems*, 31, 667-688. doi:10.1016/j.compenvurbsys.2006.11.001
- INEC. (2002). *Difusión de Resultados Definitivos del VI Censo de Población y V de Vivienda 2001 – Julio 2002: Provincia de Morona Santiago*.
https://www.ecuadorencifras.gob.ec/documentos/web-inec/Bibliotecas/Fasciculos_Censales/Fasc_Provinciales/Fasciculo_Morona.pdf
- INEC. (2010). *Estimaciones y Proyecciones de Población*. <https://sni.gob.ec/proyecciones-y-estudios-demograficos>
- Kazemzadeh, A., Zanganeh, S., Salvati, L., y Neisani, N. (2016). A spatial zoning approach to calibrate and validate urban growth models. *International Journal of Geographical Information Science*, 31 (4), 763-782. doi:10.1080/13658816.2016.1236927
- Kemeny, J., y Snell, J. (1976). *Finite markov chains*. New York: Springer.
- Khatibi, A., Pourebrahim, S., y Danehkar, A. (2018). A cellular automata model for monitoring and simulating urban land use/cover changes toward sustainability. *Journal of Environmental Engineering and Landscape Management*, 26 (1), 1-7.
doi:10.3846/16486897.2017.1284666
- Kleinbaum, D. (1994). *Logistic regression: A self-learning text*. New York: Springer.
- Lahboub, Y., Bachaoui, E., El Harti, A., y El Ghmari, A. (2018). Multi-level Cellular Automata-based housing allocation model for small cities in developing countries: a case study of

- Kasba-Tadla city, in Morocco. *International Journal of Urban Sustainable Development*, 1-18. doi:10.1080/19463138.2018.1461628
- Leija, E., Reyes, H., Flores, J., y Sahagún, F. (2016). Cambios en la cubierta vegetal, usos de la tierra y escenarios futuros en la región costera del estado de Oaxaca, México. *Madera y Bosques*, 22 (1), 125-140.
- Li, X., y Gong, P. (2016). Urban growth models: progress and perspective. *Science Bulletin*, 61 (21), 1637-1650. doi:10.1007/s11434-016-1111-1
- Li, X., y Yeh, A. (2002). Neural-network-based cellular automata for simulating multiple land use changes using GIS. *International Journal of Geographical Information Science*, 16, 323-343. doi:10.1080/13658810210137004
- Liang, X., Liu, X., Li, X., Chen, Y., Tian, H., y Yao, Y. (2018). Delineating multi-scenario urban growth boundaries with a CA-based FLUS model and morphological method. *Landscape and Urban Planning*, 177, 47-63. doi:10.1016/j.landurbplan.2018.04.016
- Liao, J., Tang, L., Shao, G., Qiu, Q., Wang, C., Zheng, S., y Su, X. (2014). A neighbor decay cellular automata approach for simulating urban expansion based on particle swarm intelligence. *International Journal of Geographical Information Science*, 28 (4), 720-738. doi:10.1080/13658816.2013.869820
- Linard, C., Tatem, A., y Gilbert, M. (2013). Modelling spatial patterns of urban growth in Africa. *Applied Geography*, 44, 23-32. doi:10.1016/j.apgeog.2013.07.009
- Liu, X., Li, X., Chen, Y., Tan, Z., Li, S., y Ai, B. (2010). A new landscape index for quantifying urban expansion using multi-temporal remotely sensed data. *Landscape Ecology*, 25 (5), 671-682. doi:10.1007/s10980-010-9454-5

- Long, Y., Han, H., Lai, S., y Mao, Q. (2013). Urban growth boundaries of the Beijing Metropolitan Area: Comparison of simulation and artwork. *Cities*, 31, 337-348. doi:10.1016/j.cities.2012.10.013
- López, M. (2015). El sistema de planificación y el ordenamiento territorial para Buen Vivir en el Ecuador. *Geosp – Espaço e Tempo*, 19 (2), 296-311.
- Malek, Ž., Boerboom, L., y Glade, T. (2015). Future Forest Cover Change Scenarios with Implications for Landslide Risk: An Example from Buzau Subcarpathians, Romania. *Environmental Management*, 56 (5), 1228-1243. doi:10.1007/s00267-015-0577-y
- Mas, J., Soares, B., Pontius, R., Farfán, M., y Rodrigues, H. (2013). A Suite of Tools for ROC Analysis of Spatial Models. *ISPRS International Journal of Geo-Information*, 2 (3), 869-887. doi:10.3390/ijgi2030869
- McBratney, A., Mendonça, M., y Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117 (1-2), 2-52. doi:10.1016/S0016-7061(03)00223-4
- McCall, J. (2005). Genetic algorithms for modelling and optimization. *Journal of Computational and Applied Mathematics*, 184, 205-222. doi:10.1016/j.cam.2004.07.034
- Megarical, K., y Marks, B. (1995). *Fragstats: spatial pattern analysis program for quantifying landscape structure*. Portland: Gen Tech. Report PNW-GTR-351. Department of Agriculture, Forest Service, Pacific Northwest Research Station.
- Megahed, Y., Cabral, P., Silva, J., y Caetano, M. (2015). Land Cover Mapping Analysis and Urban Growth Modelling Using Remote Sensing Techniques in Greater Cairo Region - Egypt. *ISPRS International Journal of Geo-Information*, 4 (3), 1750-1769. doi:10.3390/ijgi4031750

- 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. doi:10.1016/j.landurbplan.2010.10.001
- Molnár, D., y Julien, P. (2000). Grid-size effects on surface runoff modeling. *Journal of Hydrologic Engineering*, 5 (1), 8-16. doi:10.1061/(ASCE)1084-0699(2000)5:1(8)
- Mozumder, C., Tripathi, N., y Losiri, C. (2016). Comparing three transition potential models: A case study of built-up transitions in North-East India. *Computers, Environment and Urban Systems*, 59, 38-49. doi:10.1016/j.compenvurbsys.2016.04.009
- Musaoglu, N., Tanik, A., y Kocabas, V. (2005). Identification of Land-Cover Changes Through Image Processing and Associated Impacts on Water Reservoir Conditions. *Environmental Management*, 35, 220–230. doi:10.1007/s00267-003-0270-4
- NextGIS. (2013). *MOLUSCE – quick and convenient analysis of land cover changes*. <https://nextgis.com/blog/molusce/>
- Noda, A., y Niino, H. (2003). Critical grid size for simulating convective storms: a case study of the del city supercell storm. *Geophysical Research Letters*, 30 (16), 1-4. doi:10.1029/2003GL017498
- ONU. (2015). *Objetivos de desarrollo sostenible*. <http://geogra.uah.es/simurban/index.php/ct-menu-item-15>
- ONU Habitat. (2014). *Planeamiento Urbano para Autoridades Locales*. Santiago: UN-Habitat.
- Ozturk, D. (2015). Urban Growth Simulation of Atakum (Samsun, Turkey) Using Cellular Automata-Markov Chain and Multi-Layer Perceptron-Markov Chain Models. *Remote Sensing*, 7, 5918-5950. doi:10.3390/rs70505918

- Palacios, I. (2018). Evaluación multicriterio para la ubicación de un relleno sanitario en la ciudad de Macas, a través de la ponderación de sus variables con el Proceso Analítico Jerárquico, AHP. *Revista de Ciencias de Seguridad y Defensa*, 3 (3), 83-94.
- Palacios, I. (2019). *Generación de un modelo de predicción de la variable ondulación geoidal, para la zona rural del cantón Guayaquil, mediante el uso del método Cokriging* [Tesis de grado, Universidad de las Fuerzas Armadas ESPE].
- Palacios, I., y Leiva, C. (2019). Evidencia de la relación entre Arqueoastronomía y Geodesia satelital en el Cerro Catequilla, Ecuador. *Revista de Arqueología Americana*, (36), 177-193. doi:10.35424/rearam.36.2018.389
- Palacios, I., y Leiva, C. (2020). Establecimiento del estado de conservación en yacimientos arqueológicos mediante UAVS Estudio de caso: Cerro Catequilla. *La Zaranda de Ideas*, 2 (17), 6-20.
- Palacios, I., y Toulkeridis, I. (2020). Evaluation of the susceptibility to landslides through diffuse logic and analytical hierarchy process (AHP) between Macas and Riobamba in Central Ecuador. *2020 Seventh International Conference on eDemocracy & eGovernment (ICEDEG)* (pp. 201-207). Buenos Aires: IEEE. doi:10.1109/ICEDEG48599.2020.9096879
- Palacios, I., Castro, B., y Rodríguez, F. (2019). Almacenamiento de carbono como servicio ambiental en tres reservas naturales del Ecuador. *Revista Geoespacial*, 16 (1), 1-14.
- Palacios, I., Ushiña, D., y Carrera, D. (2018). Identificación de Cangahuas para su recuperación mediante estudio multicriterio y constatación in situ en comunas del volcán Ilaló. *Congreso de Ciencia y Tecnología ESPE* (Vol. 13, pp. 9-12). Sangolquí. doi:10.24133/cctespe.v13i1.649

- Park, S., Jeon, S., Kim, S., y Choi, C. (2011). Prediction and comparison of urban growth by land suitability index mapping using GIS and RS in South Korea. *Landscape and Urban Planning*, 99 (2), 104-114. doi:10.1016/j.landurbplan.2010.09.001
- Pauta, F. (2013). *Ordenación territorial y urbanística: Un camino para su aplicación en el Ecuador*. Cuenca: Universidad de Cuenca.
- Pazmiño, E. (2017). Desarrollo cultural prehispánico en el valle del Alto Upano: Análisis Cerámico del Sitio “La Lomita”, Morona Santiago, Ecuador. *Antropología Cuadernos de investigación*, (8), 149-165. doi:10.26807/ant.v0i8.131
- Perović, V., Jakšić, D., Jaramaz, D., Koković, N., Čakmak, D., Mitrović, M., y Pavlović, P. (2018). Spatio-temporal analysis of land use/land cover change and its effects on soil erosion (Case study in the Oplenac wine-producing area, Serbia). *Environmental Monitoring and Assessment*, 190 (11), 675. doi:10.1007/s10661-018-7025-4
- Pijanowski, B., Brown, D., Shellito, B., y Manik, G. (2002). Using neural networks and GIS to forecast land use changes: a Land Transformation Model. *Computers, Environment and Urban Systems*, 26, 552-575.
- Piontekowski, V., da Silva, S., Mendoza, E., de Souza Costa, W., Ribeiro, F., y Ribeiro, C. (2012). Modelagem do desmatamento para o Estado do Acre utilizando o programa Dinamica EGO. *Simpósio de Geotecnologias no Pantanal* (pp. 1064-1075). Bonito: Embrapa Informática Agropecuária/INPE.
- PND. (2017). *Plan Nacional de Desarrollo 2017-2021-Toda una Vida*. https://www.planificacion.gob.ec/wp-content/uploads/downloads/2017/10/PNBV-26-OCT-FINAL_0K.compressed1.pdf

- Porras, P. (1987). *Investigaciones arqueológicas a las faldas de Sangay*. Quito: Arte Gráficas Señal.
- Quesada, H. (2006). *De la expansión urbana al crecimiento hacia adentro. Acercamiento evaluativo del "modelo" de crecimiento hacia adentro a través del estudio de dos polígonos ubicados en el centro de Medellín, Colombia* [Tesis de maestría, Universidad Nacional de Colombia].
- Rahman, M., Tabassum, F., Rasheduzzaman, M., Saba, H., Sarkar, L., Ferdous, J., Uddin, S., y Zahedul, A. (2017). Temporal dynamics of land use/land cover change and its prediction using CA-ANN model for southwestern coastal Bangladesh. *Environmental Monitoring and Assessment*, 189 (11), 565. doi:10.1007/s10661-017-6272-0
- Ren, Y., Lü, Y., Comber, A., Fu, B., Harris, P., y Wu, L. (2019). Spatially explicit simulation of land use/land cover changes: Current coverage and future prospects. *Earth-Science Reviews*, 190, 398-415. doi:10.1016/j.earscirev.2019.01.001
- Rodrigues, H., y Soares, B. (2018). A Short Presentation of Dinamica EGO. *Lecture Notes in Geoinformation and Cartography*, 493-498. doi:10.1007/978-3-319-60801-3_35
- Rostain, S. (1999). Secuencia arqueológica en montículos del Valle del Upano en la Amazonía ecuatoriana. *Bulletin de l'Institut Français d'Études Andines*, 28 (1), 53-89.
- Rostain, S. (2010). Cronología del valle del Upano (Alta Amazonía ecuatoriana). *Bulletin de l'Institut Français d'Études Andines*, 39 (3), 667-681. doi:10.4000/bifea.1825
- Rostain, S. (2012). Between Sierra and Selva: Landscape transformations in upper Ecuadorian Amazonia. *Quaternary International*, 249 (6), 31-42. doi:10.1016/j.quaint.2011.08.031

- Rueda, S. (2009). Las supermanzanas: reinventando el espacio público, reinventando la ciudad. *II Congreso Internacional Arte y Entorno. Ciudades globales, espacios locales* (pp. 123-132). Valencia: Universitat Politècnica de València.
- Ruiz, P., Cuevas, J., Bravo, R., Prieto, F., García, J., y Zavala, M. (2010). Land use change in a Mediterranean metropolitan region and its periphery: assessment of conservation policies through CORINE Land Cover data and Markov models. *Forest Systems*, 19 (3), 315-328. doi:10.5424/fs/2010193-8604
- Salazar, E. (1998). De vuelta al Sangay - Investigaciones arqueológicas en el Alto Upano, amazonía ecuatoriana. *Bulletin de l'Institut français d'études andines*, 27 (2), 213-240.
- Salazar, E. (2008). Pre-Columbian Mound Complexes in the Upano River Valley, Lowland Ecuador. En H. Silverman, y I. W. (eds.), *The Handbook of South American Archaeology* (pp. 263-278). New York: Springer.
- Sanabria, T., y Ramírez, J. (2017). Ciudad compacta vs. ciudad difusa. Ecos antiguos y recientes para las políticas de planeación territorial y espacial. *Cuaderno Urbano. Espacio, cultura, sociedad*, 22 (22), 29-52.
- Sangermano, F., Eastman, J., y Zhu, H. (2010). Similarity Weighted Instance-based Learning for the Generation of Transition Potentials in Land Use Change Modeling. *Transactions in GIS*, 14 (5), 569-580. doi:10.1111/j.1467-9671.2010.01226.x
- Silvestrini, R., Soares, B., Nepstad, D., Coe, M., Rodrigues, H., y Assunção, R. (2011). Simulating fire regimes in the Amazon in response to climate change and deforestation. *Ecological Applications*, 21 (5), 1573–1590. doi:10.1890/10-0827.1

- Soares, B., Assunção, R., y Pantuzo, A. (2001). Modeling the spatial transition probabilities of landscape changes in an Amazonian Colonization frontier. *Bioscience*, 51 (12), 1039-1046. doi:10.1641/0006-3568(2001)051[1059:MTSTPO]2.0.CO;2
- Soares, B., Coutinho, G., y Lopes, C. (2002). Dinamica—a stochastic cellular automata model designed to simulate the landscape dynamics in an Amazonian colonization frontier. *Ecological Modelling*, 154 (3), 217-235. doi:10.1016/S0304-3800(02)00059-5
- Soares, B., Filho, L., Cerqueira, G., y Araújo, W. (2003). Simulating the spatial patterns of change through the use of the DINAMICA model. *Anais XI SBSR* (pp. 721-728). Belo Horizonte.
- Soares, B., Rodrigues, H., y Costa, W. (2009). *Modeling environmental dynamics with Dinamica EGO*. Recuperado el 19 de mayo de 2020, de www.csr.ufmg.br/dinamica
- Soares, B., Rodrigues, H., y Follador, M. (2013). A hybrid analytical-heuristic method for calibrating land-use change models. *Environmental Modelling & Software*, 43, 80-87. doi:10.1016/j.envsoft.2013.01.010
- STPE. (2017). *Proyecciones y Estudios Demográficos: Proyecciones referenciales de población a nivel parroquial 2010-2020*. <https://sni.gob.ec/proyecciones-y-estudios-demograficos>
- Tahir, M., Bouridane, A., y Kurugollu, F. (2007). Simultaneous feature selection and feature weighting using Hybrid Tabu Search/K-nearest neighbor classifier. *Pattern Recognition Letters*, 28 (4), 438-446. doi:10.1016/j.patrec.2006.08.016
- Torrens, P., y O'Sullivan, D. (2001). Cellular Automata and Urban Simulation: Where Do We Go from Here? *Environment and Planning B: Planning and Design*, 28 (2), 163-168. doi:10.1068/b2802ed
- Troupin, D., y Carne, Y. (2018). Conservation planning under uncertainty in urban development and vegetation dynamics. *PLoS ONE*, 13 (4), e0195429.

- Urriza, G., y Garriz, E. (2014). ¿Expansión urbana o desarrollo compacto? Estado de situación en una ciudad intermedia: Bahía Blanca, Argentina. *Revista Universitaria de Geografía*, 23 (2), 97-123.
- Wilson, E., Hurd, J., Civco, D., Prisloe, M., y Arnold, C. (2003). Development of a geospatial model to quantify, describe and map urban growth. *Remote Sensing of Environment*, 86 (3), 275-285. doi:10.1016/s0034-4257(03)00074-9
- Yao, F., Hao, C., y Zhang, J. (2016). Simulating urban growth processes by integrating cellular automata model and artificial optimization in Binhai New Area of Tianjin, China. *Geocarto International*, 31 (6), 612-627. doi:10.1080/10106049.2015.1073365
- Yu, N., y Qingyun, D. (2011). Urban growth pattern modeling using logistic regression. *Journal Geo-spatial Information Science*, 14 (1), 62-67. doi:10.1007/s11806-011-0427-x
- Zhang, Q., Ban, Y., Liu, J., y Hu, Y. (2011). Simulation and analysis of urban growth scenarios for the Greater Shanghai Area, China. *Computers, Environment and Urban Systems*, 35 (2), 126-139. doi:10.1016/j.compenvurbsys.2010.12.002
- Ziaee, H., Hosseinm, M., y Forghani, Y. (2017). Land use change model based on bee colony optimization, Markov chain and a neighborhood decay cellular automata. *Natural Resource Modeling*, e12151. doi:10.1111/nrm.12151
- Zubair, O., Ji, W., y Weilert, T. (2017). Modeling the Impact of Urban Landscape Change on Urban Wetlands Using Similarity Weighted Instance-Based Machine Learning and Markov Model. *Sustainability*, 9 (12), 2223. doi:10.3390/su9122223