

MODELO PREDICTIVO DEL CAMBIO DE COBERTURA FORESTAL EN EL ÁREA DE CONSERVACIÓN MUNICIPAL QUÍLAMO – CANTÓN MORONA

FOREST COVERAGE CHANGE PREDICTIVE MODEL IN THE QUÍLAMO MUNICIPAL CONSERVATION AREA –MORONA CANTON

Iván Fernando Palacios Orejuela^{1*}, Karol Dennise Arellano Pérez²

¹ Dirección de Planificación, Gobierno Autónomo Descentralizado Municipal del Cantón Morona. Calle 24 de Mayo y Bolívar. Macas, Ecuador, email: ifpalacios@espe.edu.ec

² Dirección de Planificación, Gobierno Autónomo Descentralizado Provincial de Morona Santiago. Calle 24 de Mayo y Bolívar. Macas, Ecuador, email: kdarellano@espe.edu.ec

* Autor de correspondencia: Calle 9 de Octubre y Sucre, Macas, Ecuador, ifpalacios@espe.edu.ec.

Recibido: 25 de marzo 2021

/

Aceptado: 26 de mayo 2021

RESUMEN

La pérdida de cobertura forestal es una problemática que en Ecuador depende de múltiples factores, especialmente de la intensificación del uso de suelo por actividades antrópicas. El cerro Quílamó ubicado en el cantón Morona, a pesar de haber sido declarado como área de conservación municipal (ACM) mediante ordenanza en el año 2016, aún refleja altas tasas de deforestación, consecuencia del control deficiente del avance de la frontera agrícola y cambios en el uso de suelo. El objetivo de estudio es generar un modelo predictivo del cambio de cobertura forestal en el ACM Quílamó, como un aporte a la toma de decisiones y a la generación de políticas enfocadas en reducir el impacto de deforestación en zonas protegidas de la región amazónica ecuatoriana. Mediante el uso de imágenes satelitales Landsat 5, Landsat 8 y Sentinel 2A de los años 2011, 2016 y 2020, se realizó una clasificación supervisada para identificar las coberturas del suelo, las cuales fueron reclasificadas en dos categorías: bosque y no bosque. Se aplica un modelo de simulación combinado entre autómatas celulares y cadenas de Markov, en cuya fase de calibración se utilizaron las coberturas de 2011 y 2016 para predecir la cobertura forestal al año 2020, y comparar su resultado con la cobertura real del 2020 en la fase de validación. Con el estadístico ROC y coeficiente Kappa se obtuvo un valor de 0.898 y 0.765 de precisión en la validación del modelo respectivamente, con el que se asegura una predicción robusta y confiable de la simulación. El modelo predictivo de cobertura forestal del ACM Quílamó para el año 2025, proyecta una deforestación anual de 31.76 ha/año y una tasa de deforestación de -0.016% para el periodo 2020-2025, además, de una elevada fragmentación del paisaje. El modelo generado se presenta como insumo dentro de los instrumentos de planificación del territorio, enfocados a la contribución del sector de mitigación en cambio climático.

Palabras clave: deforestación; clasificación supervisada; autómatas celulares; cadenas de Markov; ROC.

ABSTRACT

The loss of forest coverage is a problem that in Ecuador depends on multiple factors, especially the intensification of land use by anthropic activities. The Quílamó hill located in Morona canton, despite having been declared as a municipal conservation area (MCA) by ordinance in 2016, still reflects high

rates of deforestation, a consequence of deficient control in the advance of the agricultural frontier and changes in land use. The objective of the study is to generate a forest coverage predictive model in the MCA Quíllamo, as a contribution to decision-making and the generation of policies focused on reducing the impact of deforestation in protected areas of the Ecuadorian amazon region. Using Landsat 5, Landsat 8 and Sentinel 2A satellite images from the years 2011, 2016 and 2020, a supervised classification was carried out to identify land coverages, which were reclassified into two categories: forest and non-forest. A combined simulation model between cellular automata and Markov chains was applied, in whose calibration phase 2011 and 2016 coverages were used to predict the forest coverage to the year 2020, and compare its result with the 2020 real coverage in the validation phase. With the ROC statistic and Kappa coefficient, a precision value of 0.898 and 0.765 was obtained in the validation of the model respectively, with which a robust and reliable prediction of the simulation is ensured. The forest coverage predictive model of the MCA Quíllamo for the year 2025, projects an annual deforestation of 31.76 ha/year and a deforestation rate of - 0.016% for the period 2020-2025, also, a high fragmentation of the landscape. The generated model is presented as an input into the territorial planning instruments, focused on the contribution of the mitigation sector in climate change.

Keywords: deforestation; supervised classification; cellular automata; Markov chains; ROC.

INTRODUCCIÓN

La cobertura forestal o bosque constituye un ecosistema formado por árboles, arbustos y demás especies vegetales y animales, resultado de un proceso ecológico que interrelaciona otros recursos como el agua, la biodiversidad, el suelo, el aire, el paisaje, entre otros (Barrantes, Chaves, & Vinuesa, 2010). Además, ofrece una serie de servicios ambientales como: regulación del ciclo hídrico, belleza escénica, protección de la biodiversidad, mitigación de gases de efecto invernadero (Palacios & Rodríguez, 2021) por mencionar algunos.

Ecuador, a nivel de Latino América, es uno de los países con mayor porcentaje de su territorio destinado a la protección y conservación de sus ecosistemas naturales (cerca del 20%) (Elbers, 2011), sin embargo, eso no siempre es una garantía de que estos espacios naturales se mantenga sin amenazas a través del tiempo. A nivel nacional, entre los años 2014 – 2016, la tasa anual de deforestación bruta fue de -0,74% y neta de -0,48%, es decir 94,353 ha/año y 61,112 ha/año respectivamente (MAE, 2017). Ya en 2018, en la región amazónica, Morona Santiago fue la provincia con una mayor deforestación de sus bosques, siendo la segunda a nivel nacional por detrás de Manabí (El Mercurio, 2018), lo que denota una clara problemática en dicho territorio.

En Morona Santiago, uno de los principales factores causantes de la pérdida de cobertura forestal es la expansión de nuevas áreas agropecuarias, que, si bien contribuyen como fuente directa de ingresos económicos a corto plazo para pequeños productores, con el tiempo promueven el asentamiento de nuevas urbanizaciones o la construcción de infraestructura (carreteras, equipamientos, tendidos eléctricos, u otros) para su equipamiento, lo cual genera una deforestación paulatina del bosque, así como un deterioro del suelo que soporta estas actividades antrópicas (Merecí & Suqui, 2014; MAG, 2017). Esta problemática, refleja también la ausencia o incumplimiento de políticas de ordenamiento territorial que incorporen el manejo sustentable del bosque y que regulen actividades antrópicas considerando la capacidad y aptitud del suelo (Palacios, Ushiña, & Carrera, 2018; Palacios & Toulkeridis, 2020).

Las imágenes satelitales han sido ampliamente usadas para el monitoreo y análisis de las coberturas del suelo, y en especial los bosques (Abad *et al.*, 2020; Lechner, Foody, & Boyd, 2020), ya que permiten capturar información de la realidad del territorio y estudiar su comportamiento dinámico en el tiempo. En distintas aplicaciones de las geociencias, las imágenes multispectrales son fundamentales para su comprensión, como por ejemplo en el crecimiento urbano (Arellano & Castro, 2019; Palacios, 2020), cambio climático (Guo *et al.*, 2017), cálculo de temperaturas superficiales (Arellano, Padilla, & Molina, 2019; Arellano *et al.*, 2020), así como para la detección de cambios de cobertura forestal (Ávila *et al.*, 2020), con una amplio bagaje de estudios realizados en regiones amazónicas (Palacios, Castro, & Rodríguez, 2019; Barni *et al.*, 2020), lo que las convierte en una poderosa herramienta para en conjunto con modelos matemáticos y los sistemas de información geográfica (SIG), predecir los cambios futuros de la cobertura forestal.

Dentro de los SIG, los modelos espaciales de predicción son métodos que permiten la interacción de variables de la naturaleza (representadas en capas vectoriales o ráster) para la identificación de patrones o tendencias, y que generalmente son dinámicos en el tiempo (Palacios, 2019; Palacios, 2020). Estos patrones pueden ser modelados mediante algoritmos matemáticos, que basados en ciertas determinantes predicen el comportamiento de la variable objetivo en un lapso de tiempo dado (Palacios, Ushiña, & Carrera, 2020).

Existen varias técnicas usadas para el cálculo del potencial de transición de la variable, entre las más usadas se encuentran las Autómatas Celulares (AC) y Cadenas de Markov (CM) (Eastman & Toledano, 2018). La primera, consiste en una grilla simple – regular de píxeles en un número finito de estados posibles, y que dependen a su vez del anterior estado de los píxeles que se encuentran circunscritos en un vecindario (Mitsova, Shuster, & Wang, 2011), el cual se actualiza con cada paso discreto de tiempo en función de ciertas reglas para su transición. Por su parte, CM 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). Una variante a estos dos métodos, es la combinación de ambas AC y CM, que agrega un elemento de contigüidad espacial, sumado al conocimiento de la distribución espacial probable de las transiciones al análisis del proceso markoviano (Mas, Kolb, & Paegelow, 2014).

Son varias las investigaciones a nivel regional y mundial que han aplicado datos satelitales con métodos de predicción espacial de los SIG, en la deforestación (Mas *et al.*, 2004; Silva *et al.*, 2020) y el cambio de la cobertura del suelo (Ghosh *et al.*, 2017; MohanRajan, Loganathan, & Manoharan, 2020). Sumado a ello, existen autores como Syrbe y Walz (2012), o Duarte *et al.*, (2018), quienes sugieren el cálculo de índices espaciales para determinar el grado de fraccionamiento de un paisaje (índice de dimensión fractal, cohesión, entre otros), siendo indicadores de cuan afectado o conservado está un área natural (Hao *et al.*, 2017; Han *et al.*, 2019). Estas variables resultan de gran interés de la comunidad científica, lo cual refleja la importancia de desarrollar análisis relacionados en la temática, que coadyuven en la planeación del territorio, la lucha contra el cambio climático y la generación de políticas públicas desde los distintos niveles de gobierno.

Por ello, el presente estudio tiene por objetivo el generar un modelo espacial predictivo del cambio de cobertura vegetal del Área de Conservación Municipal Quíllamo – Cantón Morona, con el cual permita aplicar medidas de mitigación por parte de las autoridades competentes en cuanto a deforestación y fragmentación del paisaje en esta zona protegida de la región amazónica del Ecuador.

METODOLOGÍA

ÁREA DE ESTUDIO

El Área de Conservación Municipal (ACM) del Quílamo, se ubica en el cantón Morona, provincia de Morona Santiago, a $2^{\circ}17'54.94''$ de latitud Sur y $78^{\circ}09'59.03''$ de longitud Oeste. Su extensión comprende tres parroquias: Macas, Río Blanco, y General Proaño, donde la mayor superficie se encuentra en la primera de ellas. Posee 5158.373 hectáreas, y protege una parte del Bosque siempreverde piemontano del Sur de la Cordillera Oriental de los Andes, que se asienta sobre una prolongación de la Cordillera de la Andes, conocida como Cordillera del Abanico (ver Figura 1). La topografía de su territorio es variable, con alturas que van desde 2152.27 hasta 916.88, y una temperatura promedio de 25°C (GAD Morona, 2012).

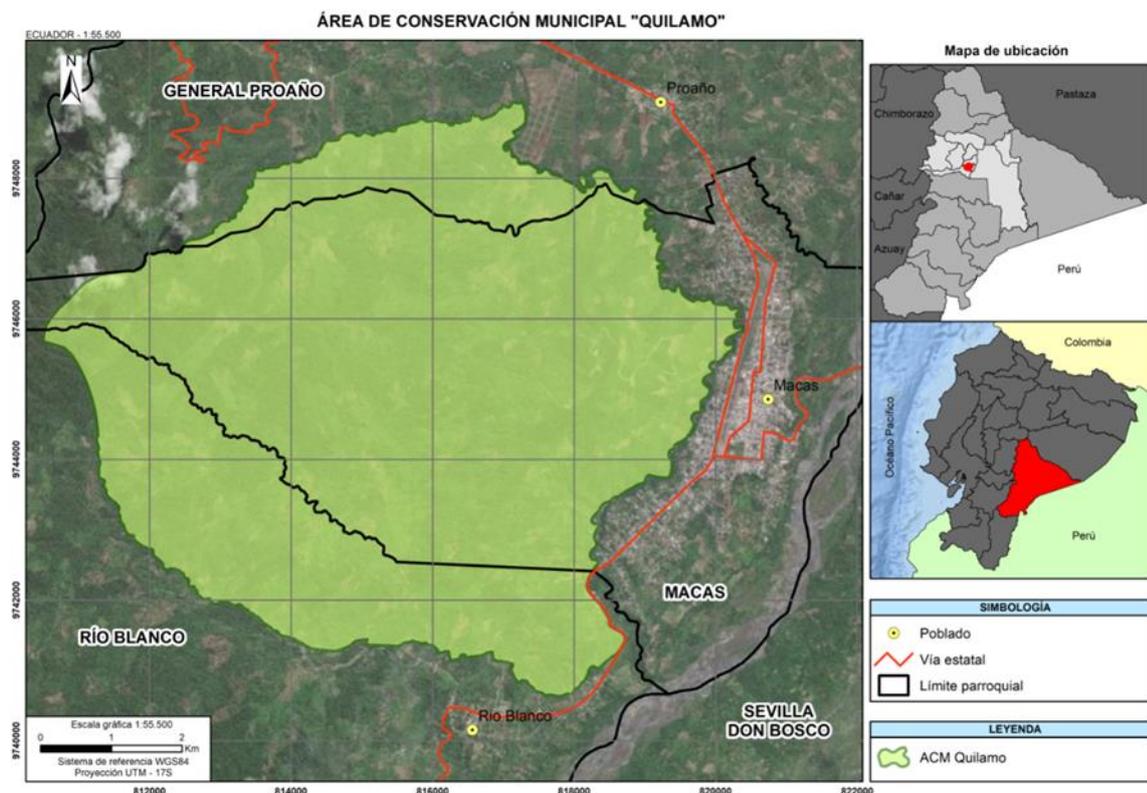


Figura 1. Mapa de ubicación del ACM Quílamo

Esta ACM fue declarada mediante ordenanza municipal el 05 de diciembre del 2016 (GAD Morona, 2016), y es una de las dos únicas áreas municipales protegidas en el cantón. El cerro Quílamo es un hito para la ciudad de Macas, no solo por su valor y riqueza inmaterial (lugar con tradición religiosa, ya que en su cima se encuentra una escultura dedicada a la Virgen Purísima de Macas), sino por ser uno de los principales atractivos turísticos de la urbe, donde se practica el turismo ecológico (Palacios, 2018), principalmente el avistamiento de aves en el mes de agosto. Además, en la parte colindante con el río Jurumbaino, se ha evidenciado que varias especies de animales (mamíferos menores, en especial) descienden al cuerpo de agua para beber, lo que destaca la importancia de la conservación del ACM, y otorga un valor agregado al presente estudio.

En la Figura 2, se resumen los pasos seguidos para la obtención del modelo predictivo de cobertura forestal con el uso de imágenes multiespectrales.

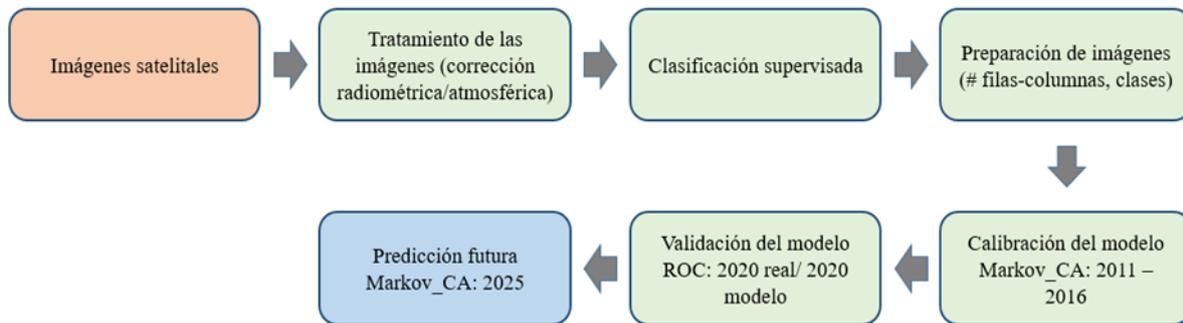


Figura 2. Flujograma de la metodología aplicada

TRATAMIENTO DE IMÁGENES SATELITALES

Las imágenes satelitales multiespectrales libres, como de la constelación Landsat o Sentinel, poseen ciertos errores que deben corregirse antes de ser usados (Hantson *et al.*, 2011). A menudo, presentan ya una corrección geométrica; sin embargo, es necesario una corrección radiométrica y atmosférica para solucionar distorsiones de la energía reflejada de los objetos sobre la superficie y su interacción con la atmósfera terrestre, entre otros errores (Cepeda *et al.*, 2018; Palacios & Cepeda, 2018).

En este estudio, se trabajó con imágenes Landsat 5, Landsat 8 y Sentinel 2A, del año 2011, 2016 y 2020 respectivamente. Las escenas del satélite Landsat 5 fueron consideradas en reemplazo de las imágenes del Landsat 7 para evitar errores debido al bandeo que presenta este satélite en sus datos ráster (Arellano *et al.*, 2020). El tratamiento de las bandas de cada escena fue realizado en el software libre QGIS, con el plugin de Clasificación Semi-automática (SCP, del inglés Semi-Automatic Classification Plugin), y posteriormente se compilaron sus bandas en un layer stack, cuyo resultado final fueron tres ráster corregidos. Vale señalar que la corrección atmosférica ejecutada con SCP es de tipo geométrico (método Chávez o DOS1), el cual elimina el efecto de la dispersión de la radiación electromagnética proveniente de partículas de la atmósfera; para esto, selecciona el número digital (ND) menor de cada banda, asumiendo que el error subyacente es debido a la dispersión atmosférica para calibrar la imagen, y que posteriormente los convierte a radiancia a través de fórmulas con parámetros extraídos del metadato de cada imagen guardado en un archivo MTL y MTD_MSI para Landsat y Sentinel, respectivamente (Chávez, 1988).

CLASIFICACIÓN DE LA IMAGEN Y DEFINICIÓN DE CATEGORÍAS

Se realizó una clasificación supervisada para la determinación de las distintas coberturas del suelo dentro del ACM Quílamo. Con la ayuda de combinaciones de bandas en color real y falso color, e índice de vegetación de diferencia normalizada (NDVI), se pudo tomar muestras de áreas de interés (ROI) para la conformación de cuatro librerías espectrales que representaron el número de coberturas identificadas. La separabilidad espectral mínima que se alcanzó en los ROI tomados fue de mínimo 1.87, lo que garantizó una correcta discriminación entre objetos.

Uno de los métodos más utilizados en clasificaciones orientadas a objetos es Máxima Verosimilitud, debido a su robustez y precisión en la determinación de coberturas en zonas heterogéneas (Hamdy *et al.*, 2017), por lo que fue usado para la clasificación en las tres imágenes multiespectrales.

Por motivos de simplificación del modelo, se reclasificó las imágenes resultantes de la clasificación supervisada en dos categorías que son: bosque y no bosque; de esta forma se facilita el manejo de los datos, puesto que estas dos categorías son las predominantes en el área de estudio, además de evitar posibles errores en la calibración y validación del modelo predictivo. Para esto, se trabajó con el software DINAMICA EGO, el cual tiene gran capacidad para elaborar modelos espaciales tanto simples y complejos (como en el caso del cambio de uso del suelo), mediante distintos métodos de predicción espacial (Soares, Coutinho, & Lopes, 2002). Dicho software libre permite trabajar además con varios formatos de ráster, así como el manejo de sus propiedades (Soares, Rodrigues, & Costa, 2009). En este caso, se definieron las características de los tres ráster para que sean homogéneos (número de filas y columnas, profundidad de pixel, nombres de las categorías, tamaño de pixel) mediante “functors” que contienen los operadores y fórmulas de configurar las propiedades de cada imagen. Este paso es fundamental para no tener errores al momento de la predicción espacial. En la Figura 3, se muestra el modelo construido en la definición de las categorías y propiedades de los ráster.

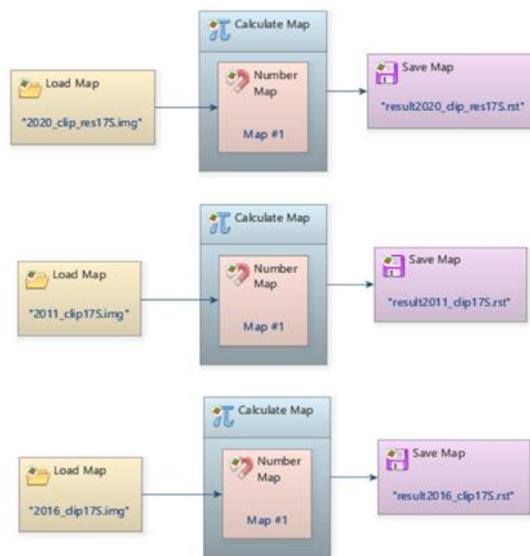


Figura 3. Reclasificación de categorías en DINAMICA EGO

MODELO MATEMÁTICO DE PREDICCIÓN

El modelo predictivo AC_CM fue ejecutado en el software IDRISI Selva, el cual utiliza la imagen booleana del segundo tiempo analizado (año 2016) como punto de partida para la simulación de los cambios futuros (al 2020); además, ingresa las áreas de transición resultantes del análisis entre los tiempos de calibración del modelo (2011 y 2016) mediante CM, las cuales reflejan la cantidad de cobertura de suelo que se espera cambie de una categoría a otra en la predicción. Otros inputs para AC_CM son: la probabilidad de transición de los pixeles a la clase de interés (bosque y no bosque) la cual es obtenida en el mismo módulo CM, así como el número de iteraciones (4) para el año en que se desea predecir (2020) y finalmente un filtro de contigüidad estándar de 5x5, valor recomendado según Eastman (2012), para el proceso de autómatas celulares, mismas que se encargan de reducir las probabilidades de las celdas más lejanas de las zonas existentes de cada categoría, y viceversa, cuyo resultado final es el ráster con las áreas de mayor probabilidad a ser ocupadas por las categorías de interés, que en este caso sería la cobertura boscosa (imagen al 2025).

La idea de trabajar con tres periodos de tiempo (2011, 2016 y 2020), responde a que las dos primeras imágenes sirven para el entrenamiento del modelo, mientras que la tercera imagen se usa para la validación del mismo, de esta forma se evalúa la precisión de la modelación y asegura que el resultado al periodo deseado (2025), sea confiable estadísticamente. En este estudio, se calculó el valor de ROC (Relative Operating Characteristic) y el coeficiente Kappa, para establecer el ajuste del ráster real (2020), con el ráster del modelo AC_CM (2020) (Eastman, 2012).

RESULTADOS Y DISCUSIONES

Como resultado de la reclasificación de las categorías de suelo, se obtuvieron los ráster de entrada para la fase de calibración y validación, las cuales se observan en la figura a continuación:

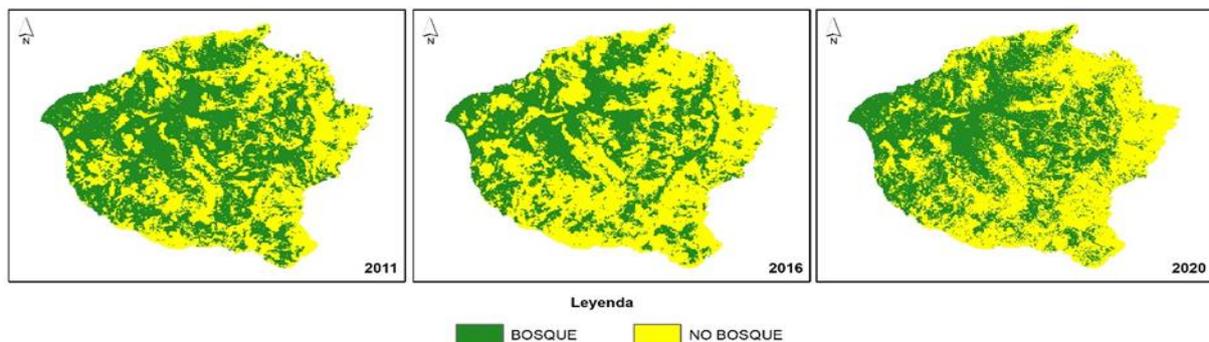


Figura 4. Reclasificación de categorías en DINAMICA EGO

Como se puede apreciar en la Figura 4, el cambio multitemporal sufrido en el área de conservación analizada es notorio, sobre todo en el primer rango de tiempo (2011 – 2016), lo que representa una agresiva antropización de la cobertura boscosa del Quílamo. En el año 2011, la cobertura forestal en el ACM representaba el 53.24% de su área total, mientras que en el 2016 fue del 41.83%, y ya para el 2020 el 40.62%; lo que representa una pérdida del bosque de 651.18 hectáreas en 9 años.

Además, para el periodo 2011 – 2016, se presenta una deforestación anual promedio de 117.77 ha/año, mientras que entre 2016 – 2020 es de 15,58 ha/año, y para el periodo 2020 – 2025 se proyectó un valor aproximado de 31.76 ha/año. Estos valores a su vez, se relacionan con tasas de deforestación de -0.047% , -0.007% y -0.016% para los rangos de tiempo 2011-2016, 2016 – 2020 y 2020 – 2025 respectivamente. Con estas cantidades, se refleja una tendencia negativa en la disminución de la cobertura boscosa en el área de conservación.

El análisis de precisión realizado mediante el estadístico ROC (estadística del área bajo la curva – AUC de ROC) el cual compara una imagen booleana real frente a una imagen de idoneidad calculada, cuyo resultado es una gráfica que refleja el rendimiento de un modelo de clasificación en distintos umbrales de tolerancia (Eastman, 2012). El AUC bajo la curva ROC proporciona una medición agregada del rendimiento en todos los umbrales de clasificación posibles, donde 1 corresponde al 100% de las predicciones realizadas son correctas, y el valor de 0 significa lo contrario a lo primero (Azmi, Amar, & Norelyaqine, 2020). Otro indicador de ajuste es el coeficiente Kappa, el cual representa la exactitud general del emparejamiento de cada píxel idéntico en los ráster analizados (Aneesha, Shashi, & Deva, 2020); éste último fue computado dentro del plugin MOLUSCE de QGIS. En este caso, se tuvo un valor AUC de 0.898 y un Kappa de 0.765, lo que representa una correcta validación del modelo construido con las imágenes de la fase de entrenamiento (2011 y 2016). Asegurar una buena precisión

entre el modelo generado y la imagen real, permite obtener un modelo futuro con la suficiente robustez estadística para que los resultados producidos sean confiables (Palacios, 2020).

El cambio temporal que ha sufrido la cobertura forestal en el ACM Quílamo se presenta en la Figura 5, en la que es evidente la reducción progresiva del bosque en las cuatro fechas analizadas. Por su parte, el producto del modelamiento espacial con autómatas celulares y cadenas de Markov para el año horizonte (2025) se muestra en la Figura 6, donde se denota que las zonas más afectadas se encuentran al costado Este del ACM, junto al área urbana de la ciudad de Macas, al igual que el costado Sur cerca del poblado de Río Blanco; mientras que al Oeste es la zona con mayor superficie de bosque que se mantiene constante en el tiempo.

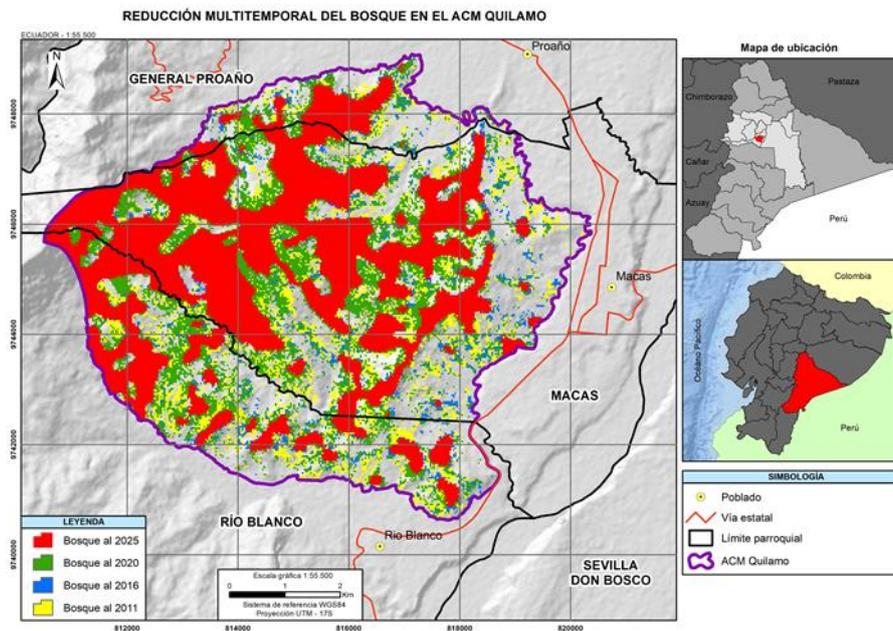


Figura 5. Mapa comparativo de la reducción multitemporal del bosque en el ACM Quílamo

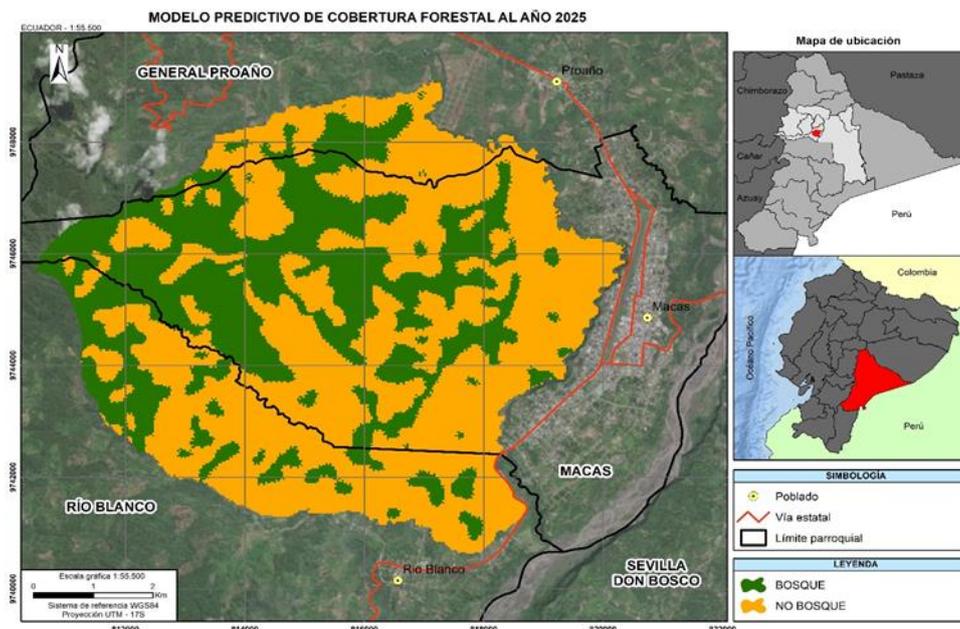


Figura 6. Modelo predictivo de cobertura boscosa en el ACM Quílamo al 2025

Una de las ventajas de combinar el proceso markoviano y autómatas celulares es que se reduce el nivel de sesgo en la probabilidad de cambio de cobertura, principalmente cuando se trabaja con productos de una clasificación del suelo, como el obtenido mediante Máxima Verosimilitud, en cuyo caso se recomienda asignar un error proporcional de 0.15, ya que el error típico en los mapas de cobertura del suelo están alrededor del 85% de precisión (Eastman, 2012); de esta forma el modelo resultante de AC_CM optimiza la tasa de transición generada con Markov, y el umbral adyacente de búsqueda que selecciona a los píxeles con mejor contigüidad espacial a través de las autómatas celulares.

En cuanto al fraccionamiento del paisaje, este se puede determinar a través del cálculo de estadísticos como el índice de dimensión fractal (para aproximar al valor de asimetría del parche), índice de cohesión del parche y distancia al vecino más cercano, los mismos que fueron calculados mediante el plugin LecoS de QGIS. En la Tabla 1, se resumen los resultados del análisis espacial del paisaje dentro del área de conservación Quílamo:

Tabla 1. Estadísticas de fragmentación del paisaje del ACM Quílamo

Período de tiempo	Variable	Cantidad
2011	Índice de dimensión fractal	1.046
	Índice de cohesión	9.901
	Distancia vecino cercano (m)	3946.656
2016	Índice de dimensión fractal	1.044
	Índice de cohesión	9.885
	Distancia vecino cercano (m)	3823.640
2020	Índice de dimensión fractal	1.037
	Índice de cohesión	9.895
	Distancia vecino cercano (m)	3742.028
2025	Índice de dimensión fractal	1.085
	Índice de cohesión	9.879
	Distancia vecino cercano (m)	3776.954

De los estadísticos del paisaje, se obtuvo que en el caso del índice de dimensión fractal, existió un descenso progresivo de los parches de bosque desde 2011 a 2020, con valores cercanos a la unidad, lo que representa una forma simple, y para el 2025 se tuvo un ligero incremento del valor de cohesión, pero permanece morfológicamente simple. En cuanto al índice de cohesión, se muestra un aumento gradual a través del periodo de tiempo analizado, incluyendo el año horizonte del estudio, sin embargo, los valores calculados son bajos que indicarían una alta fragmentación del paisaje, y que a su vez corresponden a la realidad que atraviesa el ACM Quílamo. Finalmente, los valores de distancia entre parches vecinos reflejarían una reducción en su distancia, pero con un pequeño incremento entre el periodo 2020 – 2025, lo cual permite inferir que los parches de bosque estarán más aislados. Con esto, se puede decir que el paisaje en el área natural se encuentra fragmentado, y por ende con repercusiones en la biota existente en ella; esta situación concuerda con el estado general proyectado al 2020 en que se halla el suelo en la región amazónica (Castro *et al.*, 2013), por lo que es una situación preocupante y con un panorama poco alentador si se mantienen las condiciones de los últimos 10 años.

Desde que el ACM Quíllamo fue creada mediante ordenanza en el 2016, al hacer una comparación de las hectáreas perdidas de bosque entre los periodos 2011 – 2016 y 2016 – 2020, se observa una disminución en la superficie de cambio, por lo que podría relacionarse con esta normativa cantonal se pudo reducir el impacto de la deforestación, sin embargo, aún persiste el cambio de cobertura en el área protegida. Esto denota la falta de un instrumento técnico/legal que produzca un mayor control del uso y cobertura del suelo, como por ejemplo el plan de manejo ambiental, con el cual hasta la fecha de estudio no cuenta el ACM Quíllamo.

Además, si se considera el PDOT vigente en el cantón (PDOT 2012 – 2020), el área protegida se emplaza dentro de la unidad ambiental con alto valor paisajístico y conservación, con una ponderación de méritos de conservación “alta” (GAD Morona, 2012), lo que refleja desde una mirada de ordenación del territorio, la importancia por conservar este espacio natural del cantón Morona. Sin embargo, al igual que lo indicado en la ordenanza de creación, el PDOT hasta la actualidad no ha coadyuvado en el control de cambio de suelo en el ACM. Una oportunidad para cambiar esta realidad, es a través de los instrumentos de gestión del suelo planteados en la legislación nacional vigente en materia de planificación del territorio, como el Plan de Uso y Gestión del Suelo (PUGS), el cual es vinculante no solo para el sector público, sino también el particular (art. 15 de la Ley Orgánica de Ordenamiento Territorial, Uso y Gestión del Suelo – LOOTUGS) (Asamblea Nacional, 2016), por lo que se brindaría una herramienta legal para efectivizar el control del uso del suelo o sus cambios sufridos, como en el área protegida analizada.

Trabajos como el desarrollado en el ACM Quíllamo, se presentan como un insumo técnico para la toma de decisiones, no solo desde la parte legal/política, sino también para ser considerados en planes sectoriales orientados al manejo y uso del suelo, puesto que permiten la generación de escenarios tendenciales para la zonificación y elaboración de propuestas de remediación en estas áreas.

CONCLUSIONES

El análisis multitemporal con tres periodos de tiempo (2011, 2016, 2020), permitió realizar la calibración del modelo y una posterior validación con la imagen real del último año (2020) con una precisión de ROC 0.898 y coeficiente Kappa 0.765, que garantizó un modelo predictivo a 2025 estadísticamente confiable.

Al año 2025, el modelo generado mediante la combinación de cadenas de Markov y autómatas celulares, proyectó una superficie de cobertura forestal del 37.54% aproximadamente, por lo que es urgente la intervención de las autoridades competentes para mitigar esta tendencia de pérdida de bosque en el ACM Quíllamo.

A través del cálculo de indicadores de fragmentación del paisaje, tales como el índice de cohesión, índice de dimensión fractal y distancia al vecino más cercano, se determinó que el paisaje dentro del área de conservación presenta una alta fragmentación, lo que propende a una degradación de su biodiversidad.

La generación de modelos predictivos de cambio de cobertura del suelo, como el elaborado en este estudio, se presentan como una herramienta fundamental para el apoyo a los tomadores de decisiones y como insumo dentro de los instrumentos de planificación del territorio, enfocados en la contribución al sector de mitigación USCUS (uso de suelo, cambio de uso de suelo y silvicultura) del cambio climático.

REFERENCIAS

- Abad, E., González, M., Vázquez, E., & López, E. (2020). Remote sensing applied in forest management to optimize ecosystem services: advances in research. *Forests*, *11*(9), 969. doi:10.3390/f11090969
- Aneasha, B., Shashi, M., & Deva, P. (2020). Future land use land cover scenario simulation using open source gis for the city of Warangal, Telangana, India. *Applied Geomatics*, *12*, 281–290. doi:10.1007/s12518-020-00298-4
- Arellano, K., & Castro, B. (2019). Modelamiento del crecimiento urbano en el cantón Ibarra al año 2025 para la planificación del uso y ocupación del suelo. Tesis de grado: Universidad de las Fuerzas Armadas ESPE, Sangolquí.
- Arellano, K., Padilla, P., & Molina, I. (2019). Determinación de zonas propensas al virus de la Mancha Blanca en piscinas camaroneras de la isla Puná mediante el cálculo de temperatura superficial con algoritmo Split-Window. *Revista Geoespacial*, *16*(1), 33-42. doi:10.24133/geoespacial.v16i1.1277
- Arellano, K., Padilla, P., Molina, I., Padilla, O., & Toulkeridis, T. (2020). Evaluation of the surface temperature applied in aquaculture based on satellite images in coastal Ecuador. *Conference On Information And Communication Technologies of Ecuador. TICEC 2020*. 1307, págs. 572-586. Quito. doi:10.1007/978-3-030-62833-8_42
- Asamblea Nacional. (2016). *Ley Orgánica de Ordenamiento Territorial, Uso y Gestión del Suelo*. Quito.
- Ávila, I., Ortiz, E., Soto, C., Vargas, Y., Aguilar, H., & Miller, C. (2020). Evaluación de cuatro algoritmos de clasificación de imágenes satelitales LANDSAT-8 y SENTINEL-2 para la identificación de cobertura boscosa en paisajes altamente fragmentados en Costa Rica. *Revista de teledetección*, *50*, 37-49. doi:10.4995/raet.2020.13340
- Azmi, R., Amar, H., & Norelyaqine, A. (2020). Generate knowledge base from very high spatial resolution satellite image using robust classification rules and genetic programming. *2020 IEEE International conference of Moroccan Geomatics (Morgeo)* (págs. 1-6). Casablanca: IEEE Xplore
- Barni, P., Barbosa, R., Manzi, A., & Fearnside, P. (2020). Simulated deforestation versus satellite data in Roraima, Northern Amazonia. *Sustainability in Debate*, *11*(2), 78-94.
- Barrantes, G., Chaves, H., & Vinuesa, M. (2010). El bosque en el Ecuador. Una visión transformada para el desarrollo y la conservación. COMAFORS.
- Castro, M., Sierra, R., Calva, O., Camacho, J., & López, F. (2013). Zonas de procesos homogéneos de deforestación del Ecuador. Factores promotores y tendencias al 2020. Quito: Programa GESOREN-GIZ y Ministerio de Ambiente del Ecuador.
- Cepeda, M., Palacios, I., Tierra, A., & 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
- Chávez, J. (1988). An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment*, *24*, 459-479.
- Duarte, G., Santos, P., Cornelissen, T., Ribeiro, M., & Paglia, A. (2018). The effects of landscape patterns on ecosystem services: meta-analyses of landscape services. *Landscape Ecology*, *33*, 1247–1257. doi:10.1007/s10980-018-0673-5
- Eastman, J. (2012). IDRISI Selva tutorial. Obtenido de http://uhulag.mendelu.cz/files/pagesdata/eng/gis/idrisi_selva_tutorial.pdf
- Eastman, J. (2012). IDRISI Selva. Guía para sig y procesamiento de imágenes. Obtenido de <http://clarklabs.org/wp-content/uploads/2016/10/IDRISI-Selva-Spanish-Manual.pdf>
- Eastman, J., & Toledano, J. (2018). A short presentation of the land change modeler (lcm). En M. Camacho, P. M., J. Mas, & F. Escobar, *Geomatic Approaches for Modeling Land Change Scenarios. Lecture Notes in Geoinformation and Cartography* (págs. 499-505). Cham: Springer. doi:10.1007/978-3-319-60801-3_36
- El Mercurio. (23 de Agosto de 2018). Morona Santiago con altos índices de deforestación. Recuperado el 28 de 02 de 2021, de <https://ww2.elmercurio.com.ec/2018/08/23/morona-santiago-con-altos-indices-de-deforestacion/#:~:text=El%20funcionario%20revel%C3%B3%20que%20Morona,la%20utilizaci%C3%B3n%20de%20las%20maderas>

- Elbers, J. (2011). Las áreas protegidas de América Latina: situación actual y perspectivas para el futuro. Quito: UICN.
- GAD Morona. (2012). Plan cantonal de desarrollo y ordenamiento territorial del cantón Morona 2012-2020. Macas.
- GAD Morona. (2016). Ordenanza que regula el uso y gestión del suelo en el cerro “Quilamo”, del cantón Morona. Macas.
- Ghosh, P., Mukhopadhyay, A., Chanda, A., Mondal, P., Akhand, A., Mukherjee, S., . . . Hazra, S. (2017). Application of cellular automata and markov-chain model in geospatial environmental modeling- a review. *Remote Sensing Applications: Society and Environment*, 5, 64-77. doi:10.1016/j.rsase.2017.01.005
- Guo, Q., Fu, B., Shi, P., Cudahy, T., Zhang, J., & Xu, H. (2017). Satellite monitoring the spatial-temporal dynamics of desertification in response to climate change and human activities across the ordos plateau, China. *Remote Sensing*, 9(6), 525. doi:10.3390/rs9060525
- Hamdy, O., Zhao, S., Salheen, M., & 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
- Han, Y., Kang, W., Thorne, J., & Song, Y. (2019). Modeling the effects of landscape patterns of current forests on the habitat quality of historical remnants in a highly urbanized area. *Urban Forestry & Urban Greening*, 41, 354-363. doi:10.1016/j.ufug.2019.04.015
- Hantson, S., Chuvieco, E., Pons, X., Domingo, C. C., Moré, G., Cristobal, J., . . . Tejeiro, J. (2011). Cadena de pre-procesamiento estándar para las imágenes Landsat del plan nacional de teledetección. *Revista de Teledetección*, 36, 51-61.
- Hao, R., Yu, D., Liu, Y., Liu, Y., Qiao, J., Wang, X., & Du, J. (2017). Impacts of changes in climate and landscape pattern on ecosystem services. *Science of The Total Environment*, 579(1), 718-728. doi:10.1016/j.scitotenv.2016.11.036
- Lechner, A., Foody, G., & Boyd, D. (2020). Applications in remote sensing to forest ecology and management. *One Earth*, 2(5), 405-412. doi:10.1016/j.oneear.2020.05.001
- MAE. (2017). Deforestación del Ecuador continental, periodo 2014-2016. Quito.
- MAG. (2017). Sistematización del taller de diagnóstico rural participativo del sector ganadero en las zonas de implementación del proyecto mgci en la provincia de Morona Santiago. Macas.
- Mas, J., Kolb, M., & Paegelow, M. (2014). Inductive pattern-based land use/cover change models: a comparison of four software packages. *Environmental Modelling & Software*, 51, 94-111. doi:10.1016/j.envsoft.2013.09.010
- Mas, J., Puig, H., Palacio, J., & Sosa, A. (2004). Modelling deforestation using GIS and artificial neural networks. *Environmental Modelling & Software*, 19(5), 461-471. doi:10.1016/S1364-8152(03)00161-0
- Mereci, J., & Suqui, A. (2014). Efecto de la deforestación sobre las propiedades físico-químicas de los suelos de la microcuenca del río Zhurucay. Tesis de grado: Universidad de Cuenca, Cuenca.
- Mitsova, D., Shuster, W., & 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
- MohanRajan, S., Loganathan, A., & Manoharan, P. (2020). Survey on land use/land cover (LU/LC) change analysis in remote sensing and GIS environment: techniques and challenges. *Environmental Science and Pollution Research volume*, 27, 29900-29926. doi:10.1007/s11356-020-09091-7
- 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, Sangolquí.

- Palacios, I. (2020). Generación de un modelo de crecimiento tendencial urbano de la ciudad de Macas (Ecuador) al año 2030, mediante técnicas de modelación espacial multivariable. Tesis de maestría: Universitat de Barcelona, Barcelona.
- Palacios, I. (2020). Susceptibilidad a deslizamientos en la vía Alóag – Santo Domingo, mediante Lógica Difusa. *Revista Geoespacial*, 17(2), 1-12. doi:10.24133/geoespacial.v17i2.1571
- Palacios, I., & Cepeda, M. (2018). Elimination of white noise from time series through the Wavelet Transform. *Modern Environmental Science and Engineering*, 4(7), 681-685.
- Palacios, I., & Rodríguez, F. (2021). Economic valuation of environmental goods and services of the Protector Forest Kutukú – Shaimi, SE Ecuador. *International Journal of Energy, Environment, and Economics*, 27(2), 117-132.
- Palacios, I., & Toulkeridis, T. (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)*, págs. 201-207. Buenos Aires. doi:10.1109/ICEDEG48599.2020.9096879
- Palacios, I., Castro, S., & Rodríguez, F. (2019). Almacenamiento de carbono como servicio ambiental en tres reservas naturales del Ecuador. *Revista Geoespacial*, 16(1), 1-14. doi:10.24133/geoespacial.v16i1.1275
- Palacios, I., Ushiña, D., & 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*, 13 (1), págs. 9-12. Sangolquí. doi:10.24133/ctespe.v13i1.649
- Palacios, I., Ushiña, D., & Carrera, D. (2020). Técnicas SIG para recuperación de suelos cangahuosos, con fines de agricultura comunitaria en el Ilaló. *Ciencia del Suelo*, 38(2), 295-309.
- Silva, A., Fonseca, L., Körting, T., & Escada, M. (2020). A spatio-temporal bayesian network approach for deforestation prediction in an Amazon rainforest expansion frontier. *Spatial Statistics*, 35, 100393. doi:10.1016/j.spasta.2019.100393
- Soares, B., Coutinho, G., & Lopes, C. (2002). Dinamica - a stochastic cellular automata model designed to simulate the landscape dynamics in an amazonian colocation frontier. *Ecological Modelling*, 154(3), 217-235.
- Soares, B., Rodrigues, H., & Costa, W. (2009). Modeling environmental dynamics with dinamica ego. Obtenido de <https://csr.ufmg.br/dinamica/>
- Syrbe, R., & Walz, U. (2012). Spatial indicators for the assessment of ecosystem services: providing, benefiting and connecting areas and landscape metrics. *Ecological Indicators*, 21, 80-88. doi:10.1016/j.ecolind.2012.02.013