

Integración de información estadística y observaciones de la Tierra para el cálculo de indicadores ODS 11.3.1 y 11.7.1 en Colombia, aplicando técnicas de clasificación *Random Forest*

Miguel Ángel Ramírez Gutiérrez^o Juan Carlos Lasso Rodríguez^s Carlos Alberto Durán Gil^y 

Resumen

Este artículo presenta el cálculo de los indicadores ODS 11.3.1 y 11.7.1 en Colombia, integrando información estadística y geoespacial, como fuentes esenciales para lograr una medición robusta y desagregada territorialmente. Con base en los procesos definidos por ONU-Hábitat, se desarrolla una metodología con énfasis geoespacial, soportada en el procesamiento de imágenes satelitales a través del algoritmo de clasificación supervisada *Random Forest*, para obtener las métricas requeridas en el cálculo de los dos indicadores, como son las áreas construidas, el consumo del suelo urbano, y los espacios abiertos, en conjunto con análisis integrados de información estadística. El indicador ODS 11.3.1 durante el periodo 2015-2020 se calculó para 63 ciudades definidas, cuyo valor nacional de 0,43 destaca que en el país se hace uso eficiente del suelo, mientras que el ODS 11.7.1 para 2018, se calculó en una muestra representativa de nueve ciudades, derivando que a nivel nacional un 33,2 % de las áreas construidas se destinan a espacios abiertos de uso público. Estos resultados hacen del país un referente regional en el monitoreo de los ODS, resaltando la posibilidad de actualizar los resultados a futuro, gracias a los procesamientos automatizados en la nube empleando desarrollos por medio de *scripts*.

Palabras clave: algoritmo, bosques aleatorios, datos geoespaciales, desarrollo sostenible, estadística, imágenes de satélite.

Ideas destacadas: artículo de investigación que presenta las potencialidades de las técnicas analíticas enmarcadas en la clasificación supervisada de imágenes satelitales, cuyas aplicaciones para el cálculo de indicadores ODS, se consolidan como campo de acción relevante en un contexto de integración de la información estadística y geoespacial.



RECIBIDO: 30 DE AGOSTO DE 2021. | EVALUADO: 4 DE ENERO DE 2022. | ACEPTADO: 16 DE MAYO DE 2022.

CÓMO CITAR ESTE ARTÍCULO

Ramírez Gutiérrez, Miguel Ángel; Lasso Rodríguez, Juan Carlos; Durán Gil, Carlos Alberto. 2022. "Integración de información estadística y observaciones de la Tierra para el cálculo de indicadores ODS 11.3.1 y 11.7.1 en Colombia, aplicando técnicas de clasificación *Random Forest*." *Cuadernos de Geografía: Revista Colombiana de Geografía* 32 (1): 226-257. <https://doi.org/10.15446/rcdg.v32n1.98039>.

^o Universidad Nacional de Colombia – Bogotá D.C. – Colombia. miramirezg@unal.edu.co – ORCID: 0000-0002-9264-1491.

^s Departamento Administrativo Nacional de Estadística – DANE, Bogotá D.C. – Colombia. ✉ jclassor@dane.gov.co – ORCID: 0000-0002-9833-4038.

^y Departamento Administrativo Nacional de Estadística – DANE, Bogotá D.C. – Colombia. ✉ cadurang@dane.gov.co – ORCID: 0000-0002-5928-1113.

✉ Correspondencia: Miguel Ángel Ramírez, carrera 72 C Bis 6 32 Sur – Colombia.

Integration of statistical information and Earth observations for the calculation of SDG 11.3.1 and 11.7.1 indicators in Colombia, applying Random Forest classification techniques

Abstract

This article presents the calculation of the SDG 11.3.1 and 11.7.1 indicators in Colombia, integrating statistical and geospatial information, as essential sources to achieve a robust and territorially disaggregated measurement. Based on the processes defined by UN-Habitat, it develops a methodology with a geospatial emphasis, supported by the processing of satellite images through the Random Forest supervised classification algorithm, to obtain the metrics required in the calculation of the two indicators, such as built-up areas, urban land consumption, and open spaces, together with integrated analysis of statistical information. The SDG 11.3.1 indicator for the 2015-2020 period was calculated for 63 cities, whose national value of 0.43 highlights that efficient land use is made in the country, while SDG 11.7.1 for the year 2018 was calculated in a representative sample of nine cities, which indicates that at the national level 33.2 % of built areas are allocated to open spaces for public use. These results make the country a regional benchmark in the monitoring of the SDGs, highlighting the possibility of updating the results in the future, thanks to automated processing in the cloud using scripts developments.

Keywords: algorithm, random forest, geospatial data, sustainable development, statistics, satellite imagery.

Highlights: research article that presents the potential of analytical techniques framed in the supervised classification of satellite images. Its applications for the calculation of SDGs indicators are consolidated as a relevant field of action in a context of integration of statistical and geospatial information.

Integração de informações estatísticas e observações da Terra para o cálculo dos indicadores SDG 11.3.1 e 11.7.1 na Colômbia, aplicando técnicas de classificação de Florestas Aleatórias

Resumo

Este artigo apresenta o cálculo dos indicadores ODS 11.3.1 e 11.7.1 na Colômbia, integrando informações estatísticas e geoespaciais, como fontes essenciais para alcançar uma medição robusta e desagregada territorialmente. Com base nos processos definidos pela ONU-Habitat, é desenvolvida uma metodologia com ênfase geoespacial, apoiada no processamento de imagens de satélite por meio do algoritmo de classificação supervisionada *Random Forest*, para obter as métricas necessárias no cálculo dos dois indicadores, como são áreas construídas, consumo de solo urbano e espaços abertos, juntamente com análises integradas de informações estatísticas. O indicador ODS 11.3.1 para o período 2015-2020 foi calculado para 63 cidades definidas, cujo valor nacional de 0,43 destaca que o uso eficiente do solo é feito no país, enquanto o ODS 11.7.1 para o ano de 2018 foi calculado em uma amostra representativa de nove cidades, sendo que ao nível nacional 33,2 % das áreas construídas são destinadas a espaços livres de uso público. Estes resultados fazem do país uma referência regional no monitoramento dos ODS, destacando a possibilidade de atualização dos resultados no futuro, graças ao processamento automatizado na nuvem utilizando desenvolvimentos por meio de *scripts*.

Palavras-chave: algoritmo, florestas aleatórias, dados geográficos, desenvolvimento sustentável, estatística, imagens de satélite.

Ideias destacadas: artigo de pesquisa que apresenta o potencial de técnicas analíticas enquadradas na classificação supervisionada de imagens de satélite, cujas aplicações para o cálculo de indicadores ODS se consolidam como um campo de atuação relevante em um contexto de integração de informações estatísticas e geoespaciais.

Introducción

La Agenda 2030 para el desarrollo sostenible aprobada en 2015 por la Organización de las Naciones Unidas — en adelante, ONU—, aborda 17 objetivos principales y 169 metas definidas, como un macro plan que busca, a través de una alianza mundial y el compromiso de los diferentes Estados miembros, garantizar el desarrollo equitativo y armonizado con el medio ambiente, enfocado principalmente en superar las diferentes brechas sociales, económicas y ambientales, las cuales tienden a ser aún más pronunciadas en América Latina y el Caribe (CEPAL 2018).

El seguimiento de los Objetivos de Desarrollo Sostenible —en adelante, ODS— y sus metas propuestas se hace efectivo a través de la definición de un marco global de 241 indicadores, cuya medición y cálculo permite realizar diagnósticos y validar avances cuantificables en los diferentes contextos del desarrollo sostenible. Para lograr lo anterior, los lineamientos para el cálculo de indicadores son definidos por organismos custodios acorde a sus competencias, descritos en metadatos que presentan las metodologías y fórmulas a emplear, con el fin de lograr una medición estandarizada y comparable entre países. Ahora bien, no todos los indicadores planteados presentan el mismo grado de desarrollo metodológico y disponibilidad de datos, por lo que el Grupo Interagencial y de Expertos sobre Indicadores ODS (IAEG-SDGs, por sus siglas en inglés) ha establecido una clasificación por nivel o *tier*¹ (ONU 2021), con el fin de impulsar el cálculo masivo y reporte de los indicadores con metodologías definidas, y promover la participación multinacional para lograr la consolidación de procesos en aquellos indicadores con menor desarrollo.

En el contexto actual de los ODS, para lograr la aplicación plena de la Agenda 2030, se hace necesario invertir en datos para garantizar el cálculo de indicadores, ya que “la mayoría de los países no recopilan datos con regularidad para más de la mitad de los indicadores mundiales” (ONU 2019, 3). En este sentido, la Comisión Económica

para América Latina y el Caribe (CEPAL), ha definido una serie de prioridades para lograr la implementación y seguimiento de la Agenda Global, entre las cuales se destacan: potenciar los análisis a través del avance en las innovaciones tecnológicas; acceso e implementación de la sociedad de la información; integración de los ODS en los planes de desarrollo; creación de arquitecturas nacionales y fortalecimiento de capacidades; importancia de las oficinas nacionales de estadística —en adelante, ONE— en la recolección, procesamiento, desagregación, diseminación y análisis de datos y estadísticas (CEPAL 2018). De esta forma, los sistemas estadísticos nacionales se convierten en una de las áreas estratégicas para lograr acciones conducentes al desarrollo sostenible, involucrando el uso y aplicación de nuevas fuentes de datos y tecnologías, junto a la integración de datos geoespaciales en la producción de estadística (UN-GGIM: Europa 2019a). Esto ha permitido que las ONE capacitadas, para producir información, integren datos provenientes de fuentes alternativas y no tradicionales, como las imágenes satelitales, redes sociales, telefonía móvil, entre otros (Adams y Judd 2018).

El Comité de las Naciones Unidas sobre la Gestión Global de Información Geoespacial (UN-GGIM, por sus siglas en inglés) ha caracterizado un marco de trabajo, que destaca como fuentes nacionales de información para el seguimiento y reporte de los ODS a las Observaciones de la Tierra —en adelante EO, por sus siglas en inglés—, las infraestructuras de datos espaciales, los sistemas nacionales de estadísticas, y otras fuentes, incluido el *Big Data* (ESA 2018). Uno de los principales beneficios del uso de las EO en las ONE, radica en la posibilidad de derivar indicadores ODS que, de otra manera, serían técnica y financieramente difíciles de calcular, ya que se podría reducir la frecuencia de las encuestas y, por ende, sus costos asociados, proporcionando, adicionalmente, desagregación y granularidad a los indicadores (UN-GGIM: Europa 2019a), sumado a la posibilidad de monitorear los cambios durante el tiempo, para la oportuna toma de decisiones (Digital Globe s. f.). De esta forma, los datos estadísticos y geoespaciales son una de las fuentes de datos más prominentes para el monitoreo de indicadores ODS, siendo el objetivo 11 uno de los ejemplos de mayor efectividad en el uso y análisis de información geoespacial (Avtar et ál. 2019), donde las EO son una de las fuentes más relevantes para proveer datos de media y alta resolución requeridos en el cálculo de los indicadores asociados (Andries et ál. 2019), gracias a sus características más relevantes, entre las cuales se destacan:

1 TIER 1: indicador conceptualmente claro, con metodología internacional establecida, y producción regular de datos. TIER 2: indicador conceptualmente claro, con metodología internacional establecida, pero los datos no son producidos regularmente por los países. TIER 3: no existen metodologías o estándares internacionales establecidos para el indicador. Las metodologías están siendo desarrolladas o probadas.

acceso libre y abierto; escala y cobertura; consistencia y comparabilidad; continuidad temporal; complementariedad con métodos estadísticos tradicionales; diversidad de mediciones (ESA 2018).

El ODS 11 es uno de los objetivos con mayor seguimiento en tiempos recientes, ya que con sus diez metas definidas busca lograr que las ciudades y asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles, en un mundo donde la urbanización no es simplemente un fenómeno demográfico (ONU 2018), ya que la acelerada expansión urbana y sus complejidades acarrearán una serie de cuestiones ya conocidas, tales como: los asentamientos marginales, el acceso al transporte público, la disposición de residuos, contaminación del aire; y en otras que están tomando relevancia actual, como el acceso inclusivo y equitativo a espacios abiertos de uso público (ONU 2019). De esta forma, el monitoreo de avances en indicadores ODS asociados a contextos urbanos requiere de acceso y sistemas de datos desglosados especialmente abiertos y referenciados espacialmente, por el rol crucial que tienen las ciudades de cara a un futuro enmarcado en el desarrollo sostenible (Kanuri et al. s. f.). Ahora bien, la obtención de datos desagregados es costosa y requiere de capacidades adicionales, por lo que es indispensable conjugar esfuerzos entre los distintos niveles de gobierno, para trabajar en formas modernas de análisis y recolección de datos (ONU-Hábitat s. f.).

De acuerdo con lo anterior, ante el compromiso de Colombia para la implementación y monitoreo de la Agenda 2030, donde el Departamento Administrativo Nacional de Estadística —en adelante, DANE— participa activamente en el IAEG-SDGs (UNFPA, DANE, y FAO 2021), este trabajo se encamina a resaltar el uso de técnicas enmarcadas en el aprendizaje de máquinas, para el cálculo de los indicadores ODS 11.3.1, relación entre la tasa de consumo del suelo y la tasa de crecimiento de la población, y 11.7.1, proporción media de la superficie edificada de las ciudades que se dedica a espacios abiertos para uso público de todos, en un marco de procesos enfocados en la integración de la información estadística y geoespacial, a partir de los datos proporcionados por el DANE, en conjunción al acceso y procesamiento de imágenes de satélite. Otro aspecto relevante que se deriva de la realización de estos cálculos es lograr que Colombia escale posiciones en el índice ODS para América Latina y el Caribe, que para 2019 posicionaba al país en el puesto noveno del ranking regional (CODS 2020).

Estado del arte

El desarrollo sostenible es, actualmente, un término que se emplea de manera recurrente en diseño de políticas públicas, la planificación del territorio y, en general, con toda aquella relación dada entre el contexto socioeconómico y ambiental. En realidad, esta concepción se sustenta en la posibilidad de llegar al desarrollo sin comprometer los recursos, tanto presentes, como los de las próximas generaciones, entendiendo que la sostenibilidad es un fenómeno multidimensional en términos sociales, económicos y ambientales (Lorenzo 2020).

En el contexto global, ante los desafíos que se han presentado en los países para el monitoreo y avance de los ODS, las entidades productoras de información, especialmente las ONE, han visto la necesidad de emplear nuevas fuentes de información con mayores niveles de desagregación y dimensionalidad, así como grandes conjuntos de datos como el *Big Data*, con el fin de fortalecer los sistemas de medición de datos, y de esta forma lograr nuevas soluciones, no solo para el cálculo y monitoreo de indicadores ODS (Li 2021), sino para la propia producción estadística (Vaca y Vega 2019). Por esta razón, en la actualidad se plantea el concepto de infraestructura para el desarrollo sostenible, derivado de los recientes avances tecnológicos, el cual contempla categorías asociadas a la inteligencia artificial (AI, por sus siglas en inglés), junto a la integración con técnicas de *Machine Learning* y *Deep Learning*, sumado a las tecnologías de las EO, como los sensores remotos, LIDAR (*Light Detection and Ranging*) y vehículos aéreos no tripulados (drones) (Song y Wu 2021).

Aunque los dos indicadores abordados en este artículo están catalogados como *tier ii*, con su consecuente nivel de desagregación y disponibilidad de datos, ha permitido definir lineamientos metodológicos para el cálculo de sus diferentes indicadores. Tanto el ODS 11.3.1 como el 11.7.1 son indicadores que pueden ser soportados por *Big Data* y datos geoespaciales (Halderen et al. 2021).

Para el cálculo del indicador ODS 11.3.1 se adopta una métrica espacial como una de sus principales unidades de análisis, la tasa en que el suelo es consumido para crecimiento urbano (GUO 2020) y para ello, un conjunto de datos que sirve como línea base para su cálculo es la capa de asentamientos globales humanos —en adelante GHSL, por sus siglas en inglés— y sus componentes asociados a las áreas construidas, población residente y tipologías de asentamientos (Melchiorri et al. 2019). Asimismo, el análisis geoespacial combinando datos de población y coberturas del suelo derivan en métricas

relevantes para el desarrollo metodológico del indicador (UN-GGIM: Europa 2019b). De esta forma, el empleo de imágenes satelitales como Landsat-8, Sentinel-2 y MODIS, permite monitorear el crecimiento urbano y modelar la expansión de las ciudades, en conjunto al uso de técnicas *Machine Learning* para la detección de áreas construidas por medio de métodos de clasificación supervisada como las Máquinas de Soporte Vectorial (SVM, por sus siglas en inglés), *Random Forest* y árboles de decisión (O'Connor et ál. 2020), con las que se busca categorizar grandes números de observaciones, tales como, píxeles de las imágenes (Holloway, Mengersen, y Helmstedt 2018).

En el caso del indicador ODS 11.7.1, aunque se presentan limitaciones para disponer imágenes ópticas en la resolución espacial requerida para delinear los espacios abiertos, es posible emplear fuentes de datos globales como GHSL y CORINE *Land Cover*, que destaquen la huella urbana, en conjunto con datos de luces nocturnas y servicios comerciales de imágenes de alta resolución, como Copernicus (O'Connor et ál. 2020), que sumados a datos nacionales provenientes de catastros y coberturas de mayor desagregación territorial, garantizan la consistencia y estabilidad temporal necesarias para realizar mediciones a través del tiempo (UN-GGIM: Europa 2019b).

Justamente, se destacan algunos trabajos enfocados en los indicadores objeto de este estudio. Por ejemplo, para evaluar el indicador ODS 11.3.1 en cuatro ciudades de Sudáfrica se usaron imágenes satelitales Landsat 5 y SPOT 2&5, en adición a datos censales recolectados en 1996, 2001 y 2011, con la aplicación de técnicas de análisis de imágenes orientadas a objetos, y así obtener el consumo de suelo per cápita y el cambio urbano total para cada ciudad, derivando en la creación de una línea base para el seguimiento de este indicador (Mudau et ál. 2020). De otro lado, en China continental se emplearon datos de EO, cobertura y uso del suelo, luces nocturnas y censos, con el fin de extraer el porcentaje de área construida, que junto a la estimación de población, permitió obtener la heterogeneidad espacial y tendencia de la expansión urbana a nivel ciudad y nacional, desde 1990 hasta 2010, encontrando que más del 95 % de las ciudades experimentaron crecimientos en sus áreas construidas, con un valor del indicador que se incrementó de 1,69 en el periodo 1990-2000 a 1,78 en el periodo 2000-2010 (Wang et ál. 2020). El cálculo del indicador ODS 11.3.1 también ha sido llevado a cabo por países europeos como Suecia, Noruega y Portugal, los cuales emplearon fuentes de datos nacionales, GHSL, grillas de aglomeraciones urbanas,

y coberturas nacionales de uso del suelo (Dysterud y Engelién 2019), mientras que en la ciudad de Bari, Italia, se emplearon mapas dasimétricos a partir del uso del Mapa de Asentamientos Europeos de 2012, y la clasificación de imágenes Sentinel-2 de los años 2019 y 2020 (Aquilino et ál. 2021).

En el caso del ODS 11.7.1, para el monitoreo y modelado de accesibilidad a áreas verdes urbanas a través de datos de observaciones de la Tierra en cuatro ciudades europeas, se emplearon observaciones satelitales Sentinel-2 y de alta resolución derivadas de Copernicus, junto con información auxiliar de fuente catastral, para realizar procesos de clasificación supervisada de imágenes utilizando índices espectrales y máscaras de nubosidad en la plataforma *Google Earth Engine* (GEE), y así modelar y mapear la accesibilidad física de la población a su espacio verde público más cercano, en diferentes rangos de tiempo (Giuliani et ál. 2021). Otras fuentes empleadas por países europeos como Suecia, Noruega y Estonia son las coberturas de aglomeraciones urbanas, atlas, GHSL e información de vías (Dysterud y Engelién 2019). De otro lado, métodos más robustos para identificar y mapear los espacios verdes abiertos se emplearon en Monterrey, México, a través de tecnologías *Deep Learning* para la detección geométrica de patrones en imágenes de satélite (Huerta et ál. 2021).

Los casos anteriores demuestran que el uso de EO tiene el potencial para lograr el monitoreo oficial de los indicadores ODS (Wang et ál. 2020) y la facultad de complementar y mejorar los procesos estadísticos tradicionales, sumado a su alcance en el reporte de estos indicadores (Giuliani et ál. 2021).

Metodología

Desde los contextos investigativos y geográfico, este estudio cuantitativo tiene alcance correlacional (Hernández, Fernández y Baptista 2015), ya que se desarrollan procesos *Machine Learning* con árboles de predicción en técnicas espaciales referidas a la percepción remota (Bozzano et ál. 2016), con el fin de obtener clasificaciones sobre imágenes satelitales, fundamentales para el cálculo de los indicadores ODS 11.3.1 y 11.7.1.

Ahora bien, el organismo custodio para el desarrollo y cálculo de los indicadores mencionados, ONU-Hábitat ha elaborado metadatos asociados a cada uno de ellos, donde se describen, de forma general, el flujo de procesos y pasos a seguir y fórmulas a emplear. A continuación, se mencionan dichos pasos para cada indicador:

1. Indicador ODS 11.3.1 (ONU-Hábitat 2020a):
 - 1.1. Decisión del periodo/años de análisis;
 - 1.2. Delimitación del área urbana o ciudad de actuará como alcance geográfico del análisis;
 - 1.3. Análisis espacial y cálculo de la tasa de consumo del suelo;
 - 1.4. Análisis espacial y cálculo de la tasa de crecimiento de la población;
 - 1.5. Cálculo de la razón de la tasa de consumo del suelo respecto a la tasa de crecimiento de la población.;
2. Indicador ODS 11.7.1 (ONU-Hábitat 2020b):
 - 2.1. Análisis espacial para delimitar el área urbana o de ciudad que actuará como alcance geográfico para el cálculo del indicador;
 - 2.2. Análisis espacial para identificar espacios públicos abiertos, y cálculo del área total ocupada por los estos espacios;
 - 2.3. Estimación del área total asignada a vías;
 - 2.4. Estimación de la proporción de los grupos de población de interés con acceso a espacios abiertos públicos.

Área de estudio

La Comisión de Estadísticas de la ONU, en su sesión número 51, ha recomendado a los países emplear el método del grado de urbanización —en adelante DEGURBA, por sus siglas en inglés—, que permite delinear ciudades, áreas urbanas y rurales, para realizar comparaciones estadísticas internacionales (EU et ál. 2020), y puede ser usada para recopilar estadísticas acorde a los grados de urbanización definidos en un nivel principal, así (European Union-FAO-UN-Habitat-OECD-World Bank 2020): centro urbano o ciudad (área densamente poblada), aglomeración urbana o poblado (área de densidad intermedia) y área rural (baja densidad y población detallada).

A partir de la metodología DEGURBA se definió un universo de 68 ciudades en Colombia, de las cuales 63 contaban con insumos idóneos (imágenes ópticas sin alta nubosidad) para realizar el cálculo del indicador ODS 11.3.1, en el periodo 2015-2020. A su vez, ya que el indicador 11.7.1 requiere contar con insumos adicionales para determinar espacios abiertos de uso público, los cuales no están disponibles para todas las ciudades, se optó por aplicar el enfoque de una muestra nacional de ciudades del Observatorio Global Urbano —en adelante GUO, por sus siglas en inglés—, a partir de criterios definidos, como el número de ciudades y tamaño de la población, con el fin de usar una muestra estadísticamente representativa de los asentamientos urbanos del país, y así realizar la estimación nacional del indicador

(Ndugwa 2018). De acuerdo con lo anterior, se definió una muestra representativa de nueve ciudades para realizar el cálculo del indicador 11.7.1, año 2018, correspondiente a los datos disponibles del Censo Nacional y Población y Vivienda —en adelante, CNPV— de 2018. La Tabla 1 lista las ciudades empleadas para cada uno de los indicadores.

Tabla 1. Ciudades definidas para el cálculo de indicadores ODS 11.3.1 y 11.7.1

Ciudades	11.3.1	11.7.1
Medellín	x	x
Bello	x	
Caucasia	x	
Copacabana	x	
Envigado	x	
Itagüí	x	
La Estrella	x	
Rionegro	x	
Sabaneta	x	
Barranquilla	x	x
Malambo	x	
Sabanalarga	x	
Soledad	x	
Bogotá	x	x
Cartagena	x	x
Turbaco	x	x
Tunja	x	
Duitama	x	
Sogamoso	x	
Manizales	x	
Florencia	x	
Popayán	x	
Valledupar	x	
Aguachica	x	
Montería	x	
Cajicá	x	
Chía	x	
Facatativá	x	
Funza	x	
Fusagasugá	x	
Girardot	x	
Madrid	x	
Mosquera	x	
Soacha	x	x
Zipaquirá	x	
Neiva	x	

Ciudades	11.3.1	11.7.1
Riohacha	x	
Maicao	x	
Santa Marta	x	
Ciénaga	x	
Villavicencio	x	
Acacías	x	
Pasto	x	
Cúcuta	x	
Los Patios	x	
Ocaña	x	
Villa del Rosario	x	
Pereira	x	x
Dosquebradas	x	
Bucaramanga	x	x
Barrancabermeja	x	
Floridablanca	x	
Girón	x	
Piedecuesta	x	

Ciudades	11.3.1	11.7.1
Sincelejo	x	
Ibagué	x	
Cali	x	x
Buga	x	
Cartago	x	
Palmira	x	
Tuluá	x	
Yumbo	x	
Yopal	x	

Datos: metodologías DEGURBA y GUO aplicadas para seleccionar el área de estudio.

La Figura 1 presenta el mapa de contexto de la distribución de las ciudades definidas para el cálculo de los dos indicadores ODS, objeto de este estudio.

Datos

La Tabla 2 y la Tabla 3 describen los insumos y los datos empleados para el cálculo de los indicadores.

Tabla 2. Insumos empleados para el cálculo del indicador ODS 11.3.1

Dato	Insumo	Vigencia	Descripción	Fuente
Proyecciones de población	CG ² CNPV	2005 2018	Proyecciones de población para los años 2015 (desde 2005) y 2020 (desde 2018).	(DANE 2018c)
Delimitación de áreas urbanas	MGN	2018	Área delimitada por el perímetro censal.	(DANE 2018a)
Imágenes satelitales	Landsat 8	2015	Imágenes con resolución espacial de 30 m, disponibles para las 63 ciudades.	(NASA s.f.)
Imágenes satelitales	Sentinel-2	2018	Imágenes con resolución espacial de 10 m, disponibles para las 63 ciudades.	(ESA s.f.)

Datos: DANE (2005, 2018a, 2018c), NASA (2015), ESA (s.f.).

Tabla 3. Insumos empleados para el cálculo del indicador ODS 11.7.1

Dato	Insumo	Vigencia	Descripción	Fuente
Grupos de población de interés	CNPV	2018	Georreferenciación de viviendas con grupos de población de interés (mujeres, menores y limitaciones).	(ANDA 2021)
Manzanas censales	MGN	2018	Área de terreno edificada o sin edificar, delimitada por vías de tránsito vehicular o peatonal (DANE 2018b).	(DANE 2018a)
Topónimos	MGN	2018	Puntos con los nombres de sitios, lugares económicos y calles.	(DANE 2018a)
Información predial	Catastro	2017	Bases de predios consolidadas.	(IGAC 2017)
Imágenes satelitales	Sentinel-2	2018	Imágenes con resolución espacial de 10 m, disponibles para las nueve ciudades.	(ESA s.f.)

Datos: DANE (2018a), IGAC (2017), ESA (2018).




<p>Mapa de referencia</p> 	<p>Convenciones</p> <ul style="list-style-type: none"> ● Muestra de ciudades para el cálculo del indicador ODS 11.7.1 ● Ciudades definidas para el cálculo del indicador ODS 11.3.1 — Límite departamental — Límite municipal 	<p>Sistema de referencia</p> <p>GRS80</p> <p>Proyección Transversa de Mercator</p> <p>EPSG:4326</p>
--	--	--

Figura 1. Ciudades definidas para el cálculo de los indicadores ODS 11.3.1 y 11.7.1.
 Datos: Marco Geoestadístico Nacional (MGN) – DANE (2020).

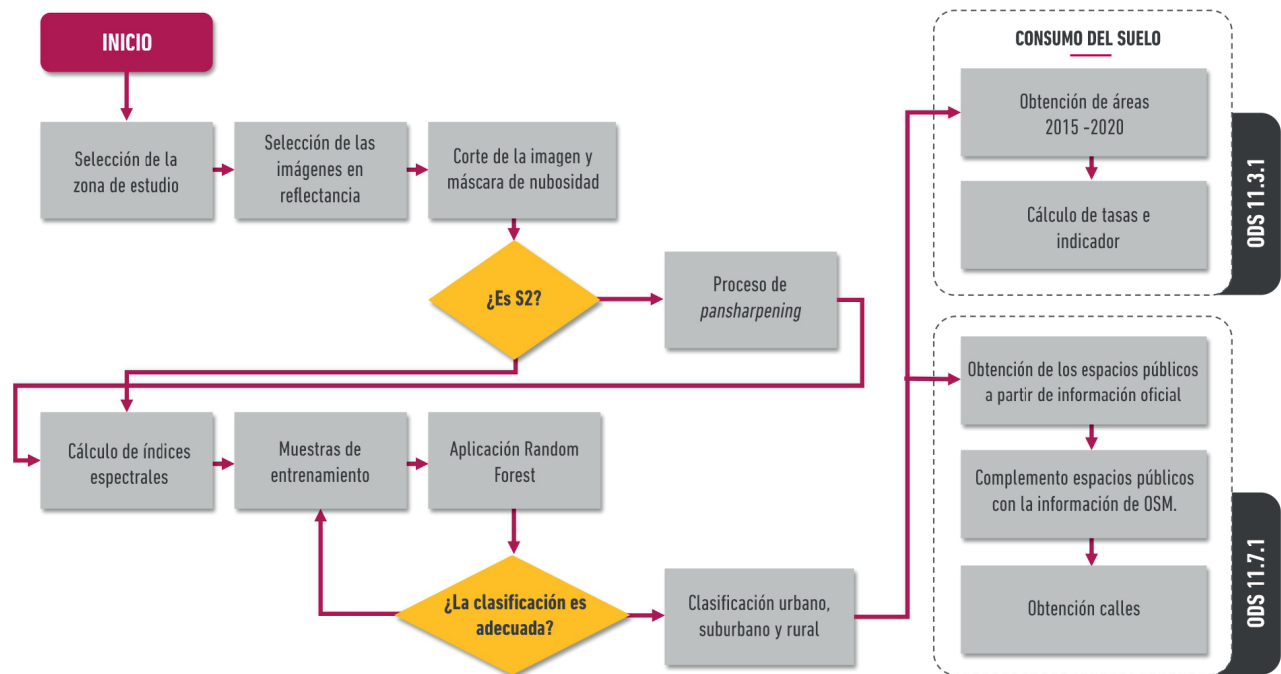


Figura 2. Diagrama general de procesos geospaciales para el cálculo de indicadores ODS 11.3.1 y 11.7.1. Datos: procesos geospaciales empleados para el desarrollo de los cálculos.

Procesos

El flujo de procesos geospaciales definido para el cálculo de los indicadores ODS 11.3.1 y 11.7.1 está plenamente soportado por técnicas analíticas espaciales, procesamiento de imágenes y algoritmos de *Machine Learning*, como se describe en la Figura 2.

Clasificación supervisada

De acuerdo con los lineamientos de los metadatos definidos para los indicadores ODS 11.3.1 y 11.7.1, se procedió a realizar el proceso de clasificación supervisada de las imágenes satelitales de media y alta resolución, en las siguientes categorías: áreas construidas, aquellas ocupadas por construcciones y superficies artificiales (ONU-Hábitat 2020a); áreas no construidas y agua.

Dos de las principales recomendaciones para la clasificación de imágenes conciernen a la creación de mosaicos y selección del algoritmo adecuado (Aguilar y Kuffer 2020; Giuliani et ál. 2021). De esta manera, a través de la plataforma de procesamiento en la nube, *Google Earth Engine* (GEE), fueron seleccionadas las imágenes satelitales de acceso libre, teniendo como criterios principales de selección los siguientes: (i) porcentaje de nubosidad por debajo del 40 %, a partir del metadato de la imagen, indicada por la concentración estimada que se encuentra presente en el total de la imagen; (ii) intervalo de fechas,

dependiendo de las vigencias requeridas para el cálculo del indicador; y (iii) selección por localización y corte al límite de las ciudades del área de estudio.

Las imágenes satelitales seleccionadas de las dos misiones poseen corrección geométrica y calibración radiométrica, con valores de píxel en reflectancia de superficie (TOA³, por sus siglas en inglés), ya que esto asegura la obtención de mejores resultados en procesamientos con las imágenes, más aún con la diferencia de temporalidad de los insumos para el caso del indicador ODS 11.3.1; en los años 2015 y 2020 los resultados pueden ser comparables entre sí (Nonni et ál. 2018).

Adicionalmente, se aplicó una máscara de nubosidad a cada imagen de la colección, de acuerdo con la banda de calidad de cada una de las misiones,⁴ donde se identifica la presencia de nubes y tipos particulares de estas, como cirrus (Traganos et ál. 2018) asociadas a algún bit. Esta acción disminuye la probabilidad de nubes en el mosaico utilizado para las distintas clasificaciones.

3 Las colecciones de imágenes de GEE de estas dos misiones ofrecen este tipo de procesamiento, en reflectancia de superficie, así: Sentinel-2: COPERNICUS/S2_SR; Landsat-8: LANDSAT/LC08/CO1/T1_TOA.

4 Sentinel-2: QA60; Landsat-8: "pixel_qa".

Como el propósito consistió en realizar la clasificación a partir de una sola imagen, se empleó una reducción de la colección de las imágenes para cada una de las misiones, generando un mosaico de medianas, que consiste en seleccionar el valor de la mediana de cada píxel, generando una imagen homogénea en el espacio y tiempo, con menor probabilidad de afectaciones por presencia de nubes y fuentes de contaminación, lo cual es una condición adecuada para la identificación de zonas construidas (Flood 2013).

Debido a las diferencias encontradas en la resolución espacial en las bandas espectrales RGB y NIR de las imágenes Landsat 8 con las bandas SWIR-1, SWIR-2 y Red Edge de las imágenes Sentinel-2, es necesario realizar sobre el mosaico de medianas el proceso *pansharpening*, que consiste en la fusión de imágenes con el fin mejorar la resolución espacial de las bandas, sin perder la resolución espectral que poseen (Li et ál. 2018). El algoritmo aplicado corresponde al filtro de paso alto (HPF, por sus siglas en inglés) (Chen 2019) a las bandas espectrales térmicas para obtener una resolución espacial final de 10 m en todas las bandas, y de esta forma realizar con mayor precisión la delimitación del área construida.

Para obtener una clasificación final mejorada, tanto en el mosaico de medianas como en la imagen de mejor resolución espacial extrapolada y re-muestreada, se calcularon los índices espectrales de la Tabla 4.

Tabla 4. Índices espectrales calculados como insumos en la clasificación

Nombre	Significado	Fórmula
NDVI	Índice de vegetación de diferencia normalizada.	$\frac{NIR - RED}{NIR + RED}$
NDBI	Índice de áreas construidas de diferencia normalizada.	
NDWI	Índice de agua de diferencia normalizada.	

Datos: índices calculados a partir de imagen satelital Landsat 8 y Sentinel-2 (2015 -2020).

El algoritmo que se utiliza para la clasificación supervisada basada en píxeles es *Random Forest*, siendo uno de los más usados y con mejores resultados dentro de las técnicas de *Machine Learning*, obteniendo la mejor exactitud temática para la detección de zonas urbanas (Belgiu y Drăgu 2016; Tavares et ál. 2019; C. Li, Cai, y Du 2021; Shafizadeh-Moghadam et ál. 2021). Respecto a los parámetros del algoritmo, el resultado de la clasificación

difiere solo si varía la muestra de entrenamiento, o esta es realizada en otra imagen (Ramírez et ál. 2020).

La clasificación se realizó a partir de los polígonos de entrenamiento trazados manualmente en los que se hizo distinción entre zonas construidas, verdes y cuerpos de agua. La muestra es dividida entre el 70 % de los polígonos de entrenamiento y el restante 30 % para validación (Millard y Richardson 2015). Para decidir si la clasificación es adecuada, se utilizaron los indicadores de exactitud temática más representativos, a saber: porcentaje de clasificación del mapa, calidad del productor, calidad del usuario y *kappa*, derivados de la matriz de confusión generada a partir de la información de entrenamiento y validación (Foody 2002; Liu, Frazier y Kumar 2007).

Con base en las imágenes clasificadas, se procede a realizar la evaluación para determinar el nivel de clasificación de las áreas construidas, a partir de las definiciones establecidas por la metodología DEGURBA (European Union-FAO-UN-Habitat-OECD-World Bank 2020):

1. Definir un círculo de 1 km² alrededor de cada píxel clasificado como construido, y calcular la proporción de píxeles en el círculo que también se clasifican como construidos.
2. Si el 50 % o más de los píxeles en el kernel son construidos, el píxel se clasifica como urbano.
3. Si entre el 25 % y menos del 50 % de los píxeles en el kernel son construidos, el píxel se clasifica como suburbano.
4. Si menos del 25 % de los píxeles en el kernel son construidos, el píxel se clasifica como Rural.

Cálculo del indicador ods 11.3.1, periodo 2015-2020

Con el resultado de la clasificación del área construida para cada ciudad, se procedió a realizar un ajuste a la clasificación, ya que se tiene una clasificación de todos los píxeles urbanos, y para realizar el cálculo del indicador se debe tener la delimitación por ciudad, por lo cual se realizó el corte con la cobertura de cabeceras municipales del MGN. Así mismo, se hizo el ajuste por la diferencia de resolución entre sensores (Landsat 8, 30 metros para 2015 y Sentinel-2, 10 metros para 2020), mediante Sistemas de Información Geográfica, generando los polígonos con el área construida a nivel ciudad, lo que permitió la comparabilidad visual entre las dos vigencias. Finalmente, se generaron los polígonos de consumo del suelo urbano entre los dos años.

Con el área del consumo de suelo para cada ciudad, se procede al cálculo de la correspondiente tasa que, junto

a la calculada a partir de las proyecciones para determinar el crecimiento de población, derivan en el cálculo del indicador. A continuación, se presentan las fórmulas establecidas para realizar los cálculos mencionados:

Ecuación 1. Tasa de consumo del suelo (TCS).

$$TCS = \frac{LN(Urb_{t+n}/Urb_t)}{(y)}$$

Donde:

Urb_{t+n} : Área construida en el año final (2020)

Urb_t : Área construida en el año (2015)

y: Número de años entre los dos momentos de medición (cinco)

Ecuación 2. Tasa de crecimiento de población (TCP).

$$TCP = \frac{LN(Pop_{t+n}/Pop_t)}{(y)}$$

Donde:

Pop_t : Población de la cabecera municipal en el año final (2020)

Pop_{t+n} : Población de la cabecera municipal en el año inicial (2015)

y: Número de años entre los dos momentos de medición (cinco)

Ecuación 3. Relación entre la tasa de consumo del suelo y la tasa de crecimiento de población.

$$Ind\ 11.3.1 = \left(\frac{TCS}{TCP}\right)$$

Cálculo del indicador ods 11.7.1 año 2018

Con el área urbana determinada por la clasificación de imágenes Sentinel-2 para 2018, se realizó la determinación de los espacios abiertos empleando técnicas de información geoespacial, tomando como base la información catastral disponible, el MGN y la toponimia. De los espacios públicos detectados, es necesario realizar un chequeo manual exhaustivo del resultado consolidado, a través de un mapa base actualizado o una imagen de muy alta resolución espacial de archivo. Esta actividad es necesaria ya que se pueden encontrar diferencias en forma y tamaño de estos espacios con la información catastral reportada como uso público, y por la temporalidad de la toponimia respecto a la fecha de toma de la imagen satelital clasificada (Giuliani et ál. 2021).

Como complemento a los espacios públicos detectados con la información oficial disponible, se utilizó la información de acceso abierto proveniente de la fuente *Open Street Map* (OSM), el cual es un insumo masivo útil con información confiable (Aguilar y Kuffer 2020; Giuliani et ál. 2021). No obstante, se realizó una verificación visual antes de su integración, y así construir un repositorio de espacios públicos más robusto para cada una de las ciudades analizadas.

Dentro del cálculo del indicador es indispensable determinar el área destinada a las calles, para lo cual se utilizaron los insumos base disponibles (manzanas censales y límites de cabeceras municipales) y la extensión urbana resultante del proceso de clasificación de imágenes. Se procedió a realizar una operación espacial de recorte, tomando el límite de cada cabecera, aplicando posteriormente la operación espacial de borrado, partiendo los cubrimientos resultantes con la cobertura de manzanas censales. El resultado obtenido es una malla, tipo polígono, de las vías de cada ciudad. Posteriormente, se realizó una revisión y depuración de estos cubrimientos, con el fin de detectar posibles inconsistencias, que afecten el cálculo del indicador, definido en la siguiente fórmula:

Ecuación 4. Proporción del área construida de la ciudad que es destinada a espacios abiertos de uso público.

$$Participación = \frac{Superficie\ total\ de\ espacio\ público\ abierto + Superficie\ total\ destinada\ a\ calles}{Superficie\ total\ de\ área\ construida\ de\ la\ ciudad} * 100$$

Dado que el indicador se debe desagregar por grupos de poblacionales de interés, a partir de las siguientes temáticas: sexo, edad y personas con condición de discapacidad, para realizar las estimaciones de población con acceso a espacios públicos abiertos, se adoptó el enfoque basado en el uso de datos de alta resolución provenientes de las ONE junto a la definición de áreas de servicio (ONU-Hábitat 2018). Por consiguiente, en cada una de las ciudades de la muestra se utilizaron las unidades censales (viviendas) georreferenciadas del CNPV 2018, en donde se logró identificar la participación de mujeres, menores de quince años y personas con discapacidad, cuya ubicación se superpuso con las áreas de servicio definidas para los espacios públicos, determinadas a una distancia de cuatrocientos metros caminando. La generación de estas áreas se realizó a través de procesos derivados del análisis de redes que ofrece la plataforma ArcGIS Pro. De esta manera, se estableció el indicador desagregado por medio del porcentaje de personas, pertenecientes a los tres grupos de población interés, que se encuentran

dentro del área de accesibilidad a los espacios abiertos definidos, aplicando la Ecuación 5.

Ecuación 5. Indicador desagregado por grupos poblacionales de interés.

$$\text{Indicador desagregado por grupo poblacional} = \frac{\text{Total de personas del grupo poblacional en las áreas de servicio}}{\text{Total de personas del grupo poblacional en el área urbana}} \cdot 100$$

Resultados

La sección de resultados se encuentra compuesta por los siguientes apartados: (i) procesamiento de imágenes satelitales, haciendo énfasis en los resultados obtenidos para las ciudades de Cali y Medellín; (ii) resultados relevantes del cálculo de indicadores ODS 11.3.1 y 11.7.1.

Procesamiento de imágenes

El primer producto corresponde al mosaico de composición de medianas para cada uno de los años de estudio (2015 y 2020 para el indicador ODS 11.3.1; 2018 para el indicador ODS 11.7.1), con el cual fue realizada cada una de las clasificaciones. La Figura 3 y la Figura 4 muestran los mosaicos generados para Cali y Medellín, respectivamente.

Los mosaicos se encuentran libres de nubosidad y radiométricamente son conformes, es decir, no se encuentran valores atípicos, situación que es característica general de una composición de medianas.

A partir de las muestras de entrenamiento recolectadas para cada una de las tres clases de interés, y luego de seleccionar aquella clasificación con mejores resultados tanto visuales como en los resultados de los indicadores de exactitud temática (Tabla 5) fueron escogidas las clasificaciones que se presentan en la Figura 5 para Cali y la Figura 6 para Medellín.

Los indicadores de exactitud temática obtenidos para las 63 ciudades definidas reflejan precisiones generales que oscilan 0,951 y 1, con índices Kappa entre 0,908 y 1 para cada uno de los años. Estos valores cercanos y superiores a 0,9, ratifican que los productos generados son adecuados⁵. En la Tabla 5 se observan los índices para las ciudades de Cali y Medellín.

A partir de las clasificaciones obtenidas, se aplica la metodología DEBURGA con el fin de identificar cuáles de estos píxeles se pueden clasificar como área construida, y así delimitar el consumo de suelo urbano. El resultado para las ciudades de Cali y Medellín se observa en la Figura 7 y en la Figura 8, respectivamente, enmascarando las demás coberturas.

Cabe recalcar que las áreas urbanas fueron obtenidas en función de la resolución espacial propia de las imágenes satelitales empleadas para cada vigencia. Es decir, las áreas urbanas del año 2015 se encuentran a una resolución espacial de treinta metros de las imágenes Landsat, y las del año 2018 y 2020 a una resolución de diez metros de las imágenes Sentinel-2.

Cálculo de los indicadores ODS 11.3.1 y 11.7.1

Indicador ODS 11.3.1 periodo 2015-2020

Después de obtener la clasificación de las áreas urbanas y la realización del ajuste a la clasificación debido a la diferencia en la resolución espacial de las imágenes de satélite, se pueden evidenciar las zonas y sus cambios sustanciales en el consumo del suelo entre 2015 y 2020, como se evidencia, a manera de ejemplo, en la ampliación realizada, a través de la plataforma *Google Earth*, en la ciudad de Cali (Figura 9).

Tabla 5. Valores de los índices de exactitud temática

Ciudad	2015		2018		2020	
	Precisión General	Kappa	Precisión General	Kappa	Precisión General	Kappa
Cali	0,941	0,917	0,925	0,895	0,902	0,879
Medellín	0,982	0,965	0,978	0,948	0,989	0,944

Datos: índices de evaluación temática resultado de la clasificación de las imágenes de satélite Landsat (2015) y Sentinel-2 (2018 y 2020).

5 En el proceso de revisión, se observó que algunas clasificaciones no distinguieron plenamente los cuerpos de agua y se asociaron a áreas no construidas. No obstante, esta situación no es relevante, ya que el foco de interés en la clasificación corresponde al consumo del suelo por áreas construidas.

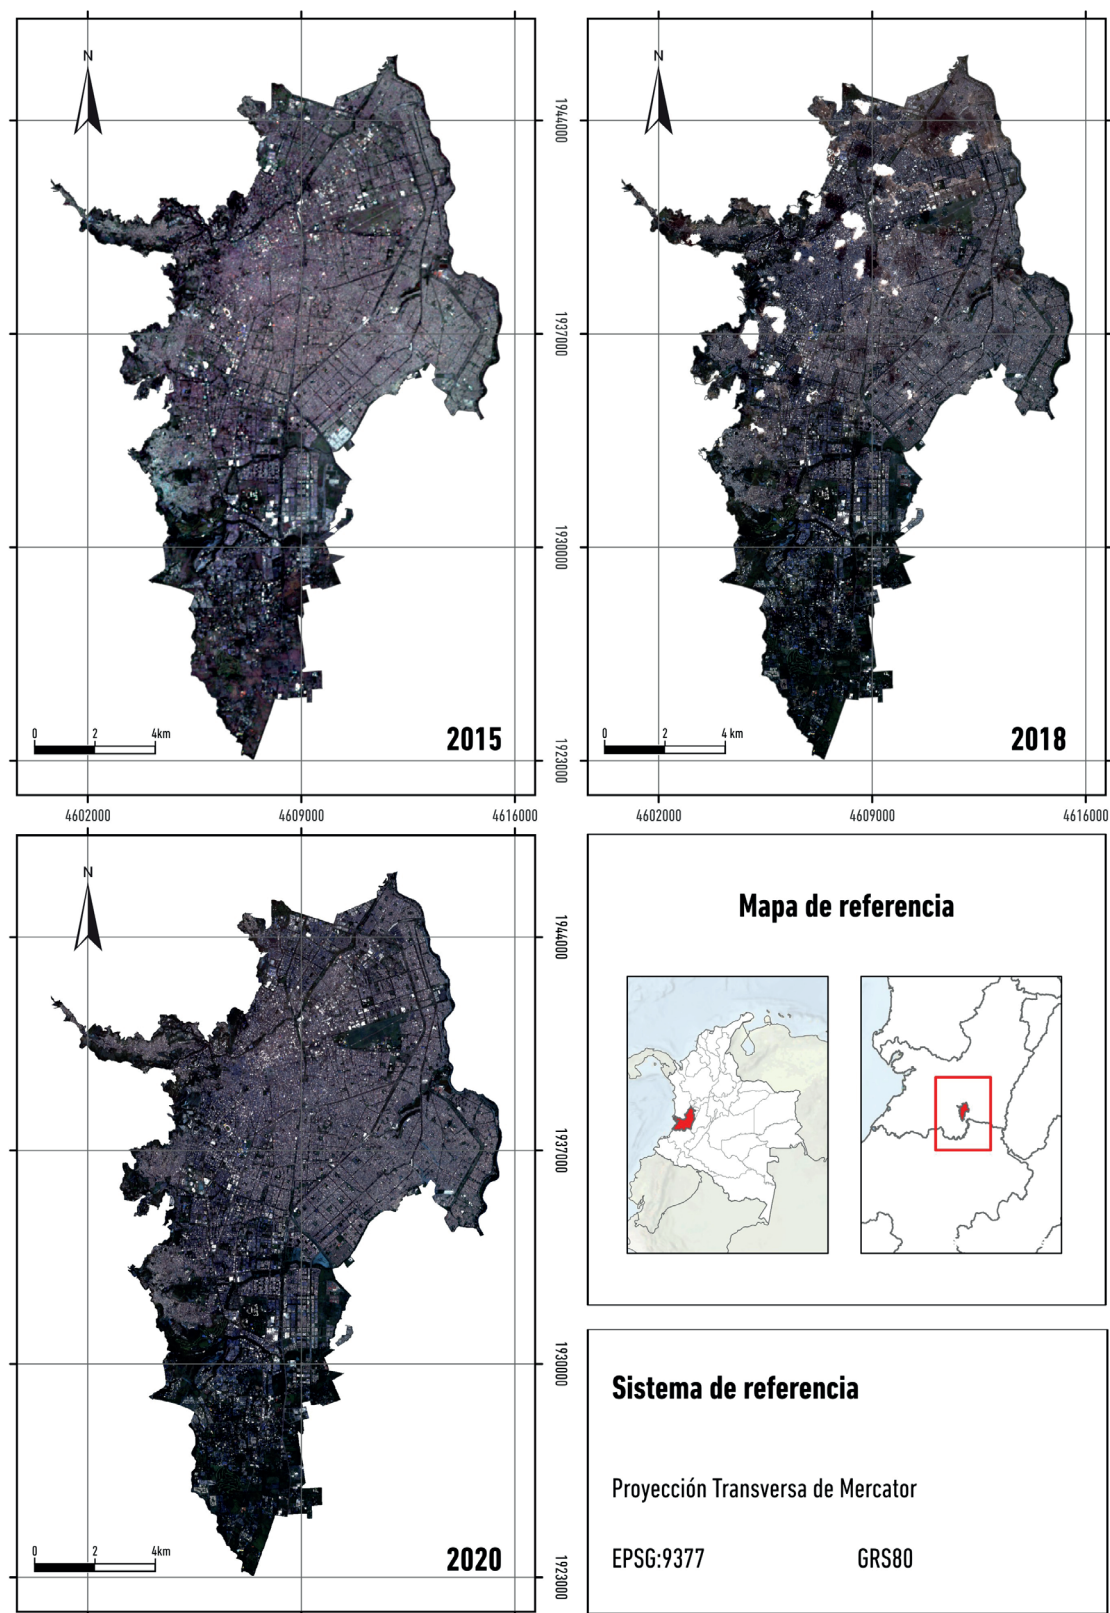


Figura 3. Composición de medianas utilizadas para cada una de las fechas de estudio en la ciudad de Cali. Datos: procesos geoespaciales elaborados a partir de imágenes satelitales Landsat 8 (2015) y Sentinel-2 (2018 y 2020).

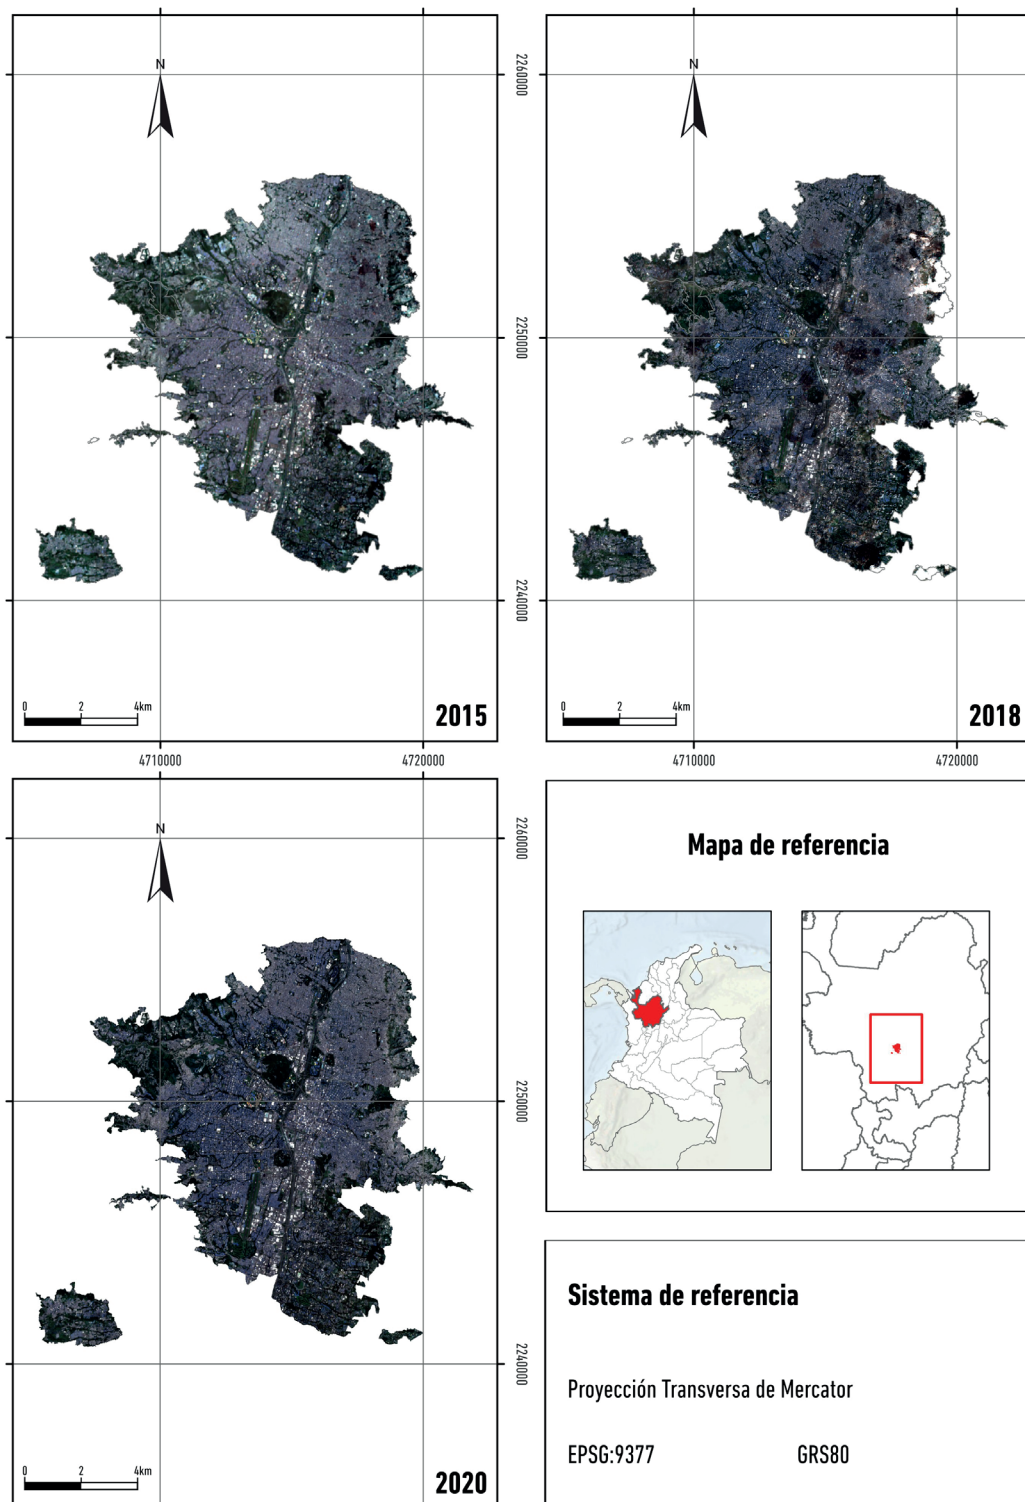


Figura 4. Composición de medianas utilizadas para cada una de las fechas de estudio en la ciudad de Medellín.
 Datos: procesos geoespaciales elaborados a partir de imágenes satelitales Landsat 8 (2015) y Sentinel-2 (2018 y 2020).

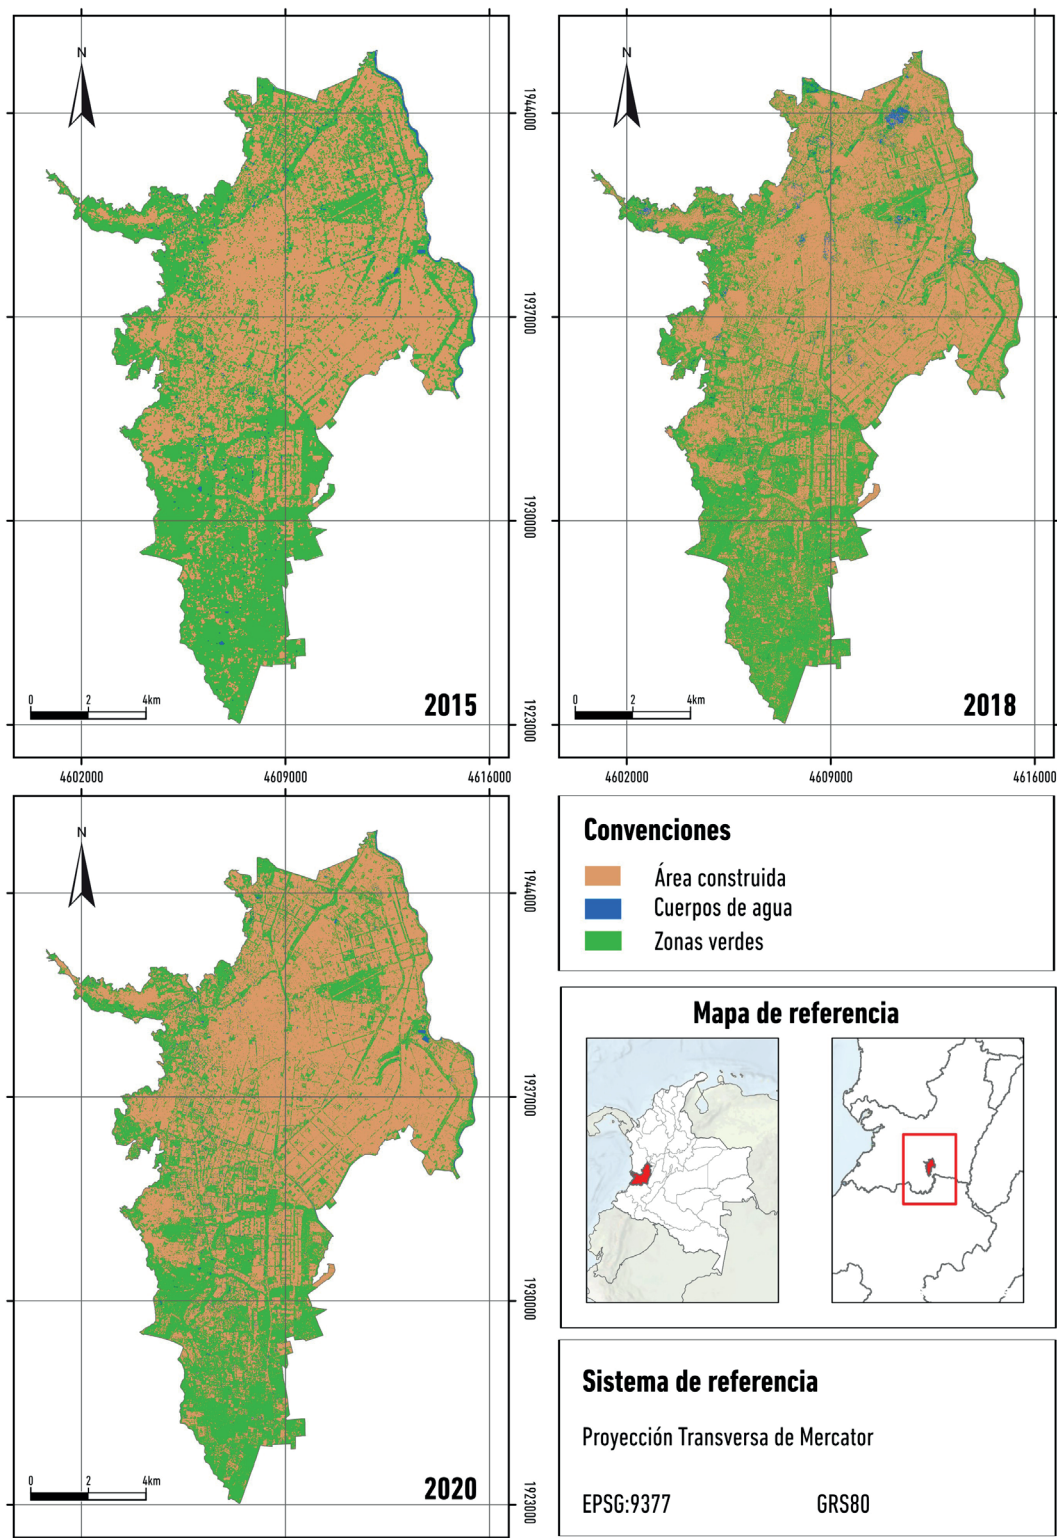


Figura 5. Clasificaciones seleccionadas para cada una de las fechas de estudio, en la ciudad de Cali.
 Datos: procesos geospaciales elaborados a partir de imágenes satelitales Landsat 8 (2015) y Sentinel-2 (2018 y 2020).

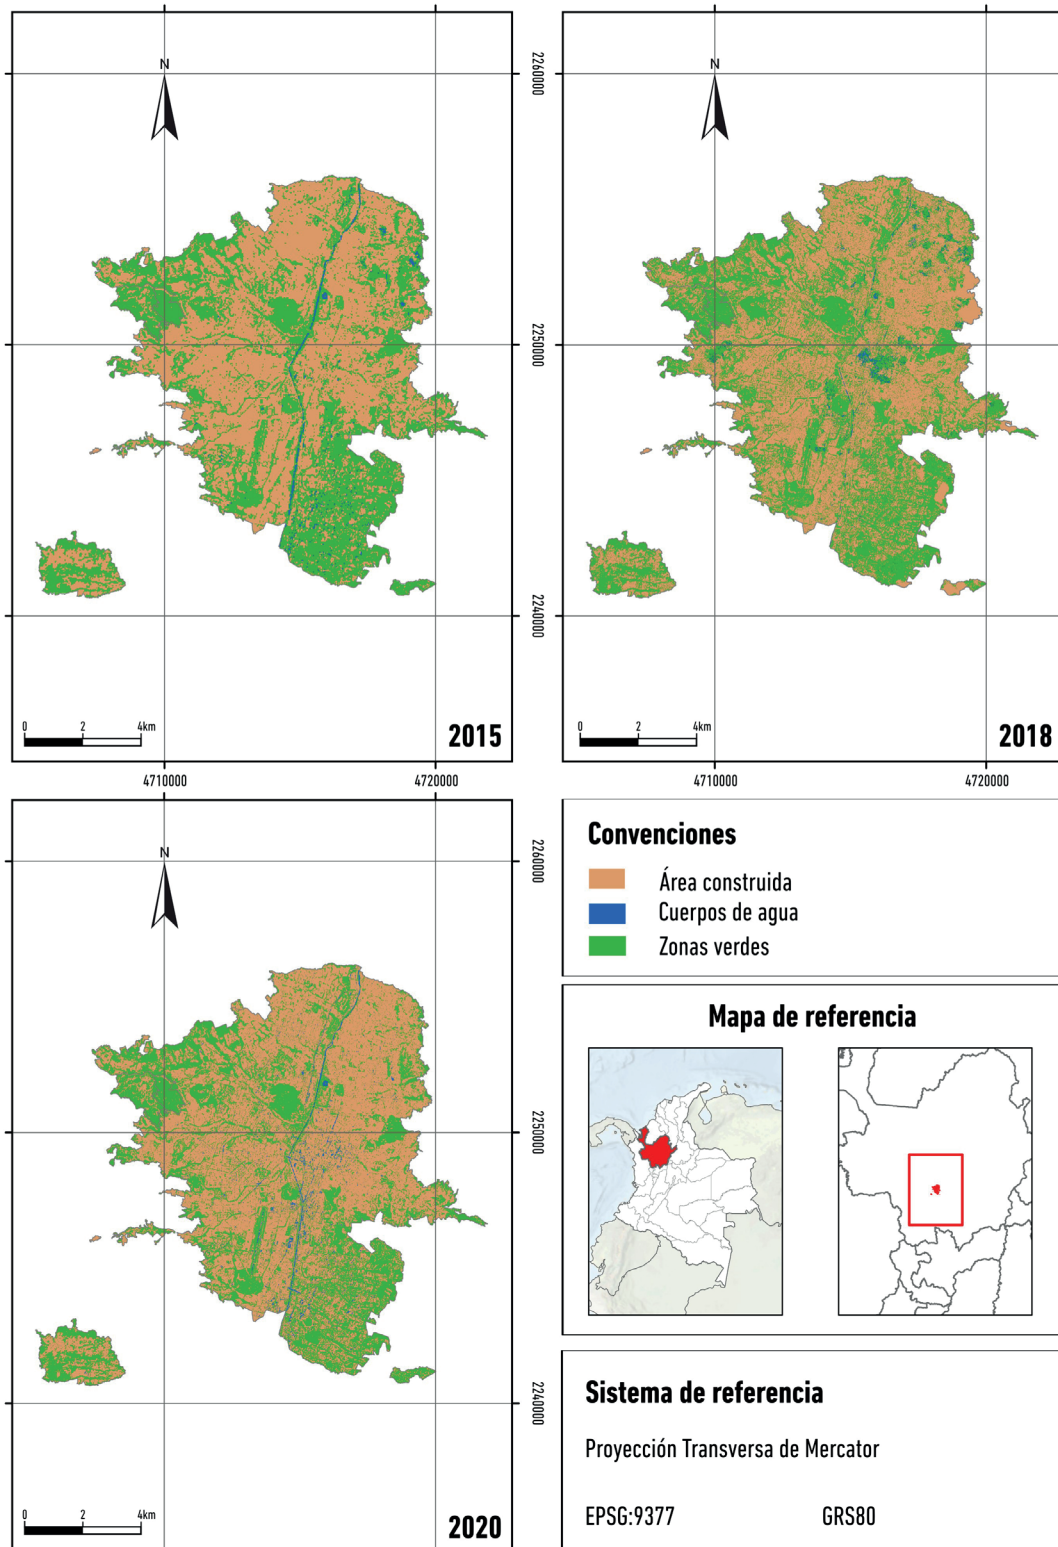


Figura 6. Clasificaciones seleccionadas para cada una de las fechas de estudio, en la ciudad de Medellín.
 Datos: procesos geoespaciales elaborados a partir de imágenes satelitales Landsat 8 (2015) y Sentinel-2 (2018 y 2020).

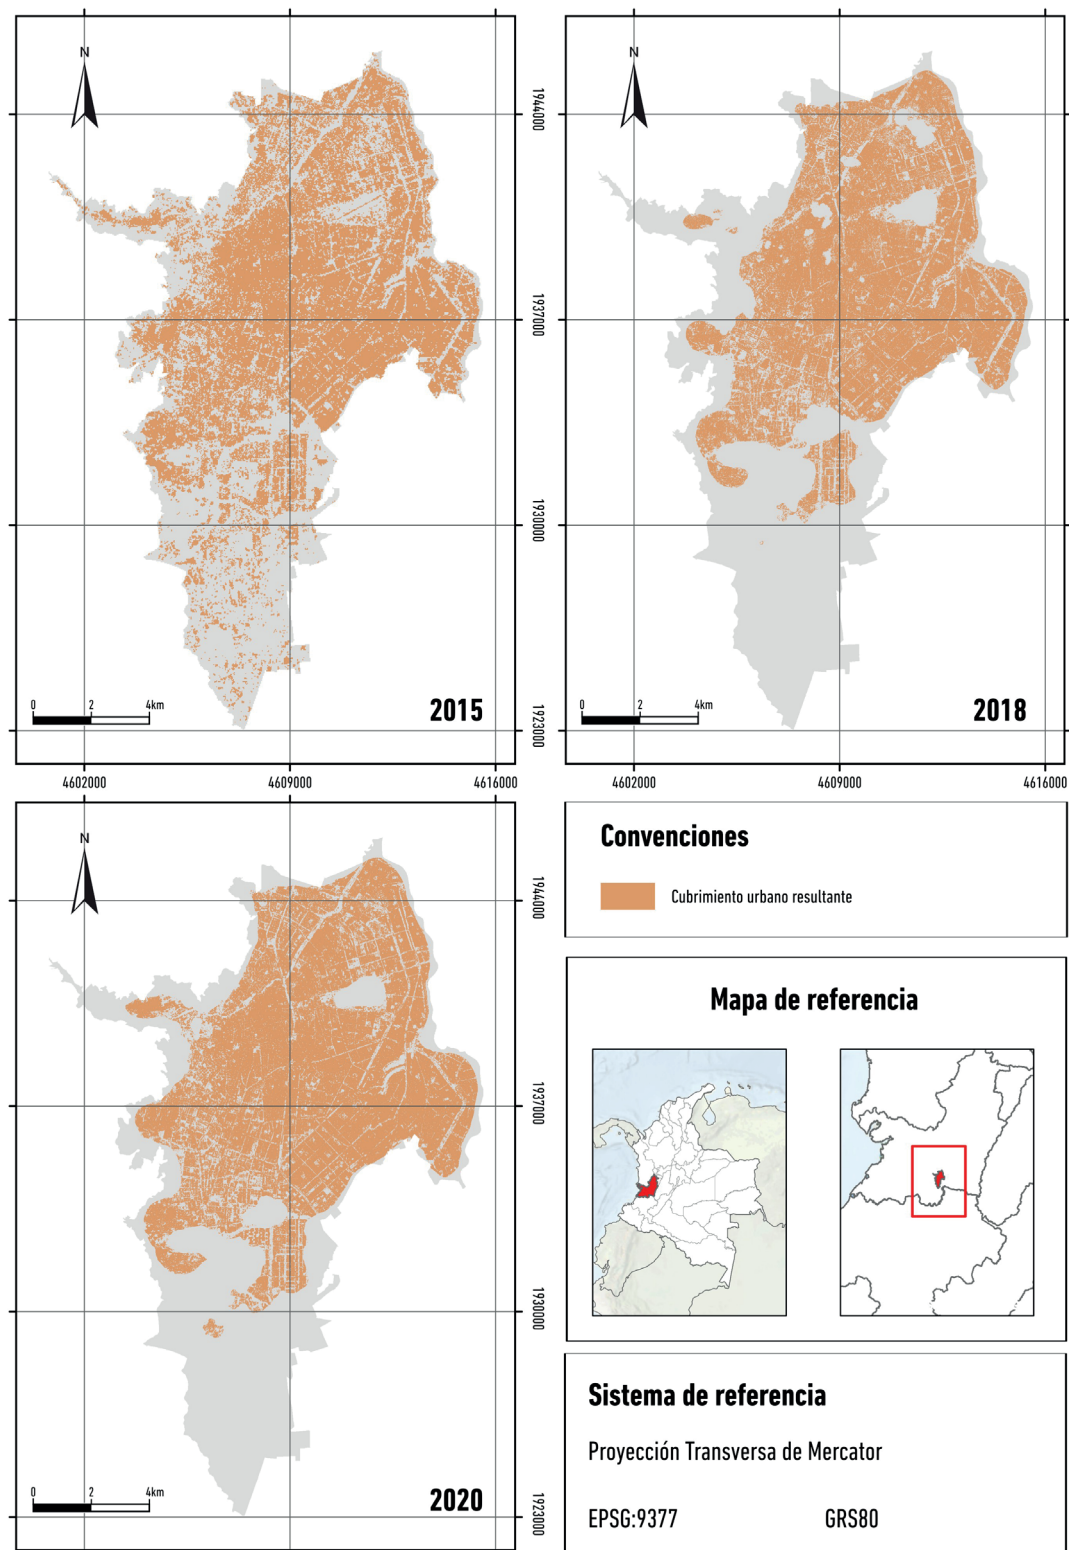


Figura 7. Área urbana obtenida para cada una de las fechas de estudio, en la ciudad de Cali.
 Datos: procesos geoespaciales elaborados a partir de imágenes satelitales Landsat 8 (2015) y Sentinel-2 (2018 y 2020).

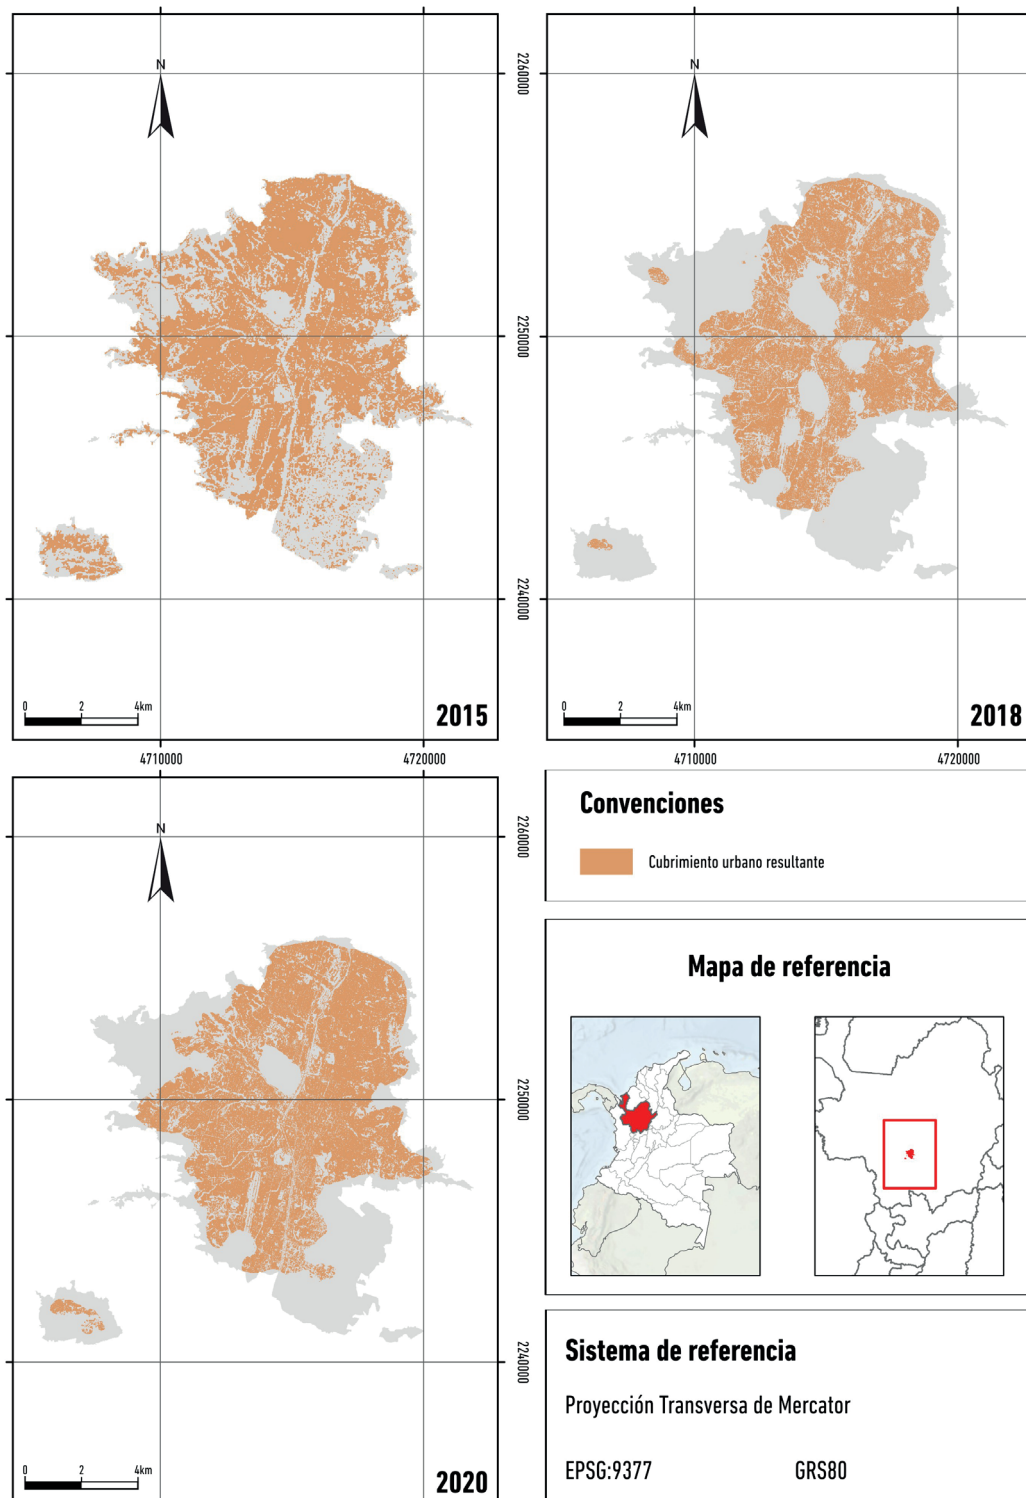


Figura 8. Área urbana obtenida para cada una de las fechas de estudio, en la ciudad de Medellín.
 Datos: procesos geoespaciales elaborados a partir de imágenes satelitales Landsat 8 (2015) y Sentinel-2 (2018 y 2020).



Figura 9. Cambios en el consumo del suelo entre 2015 (superior) y 2020 (inferior) en zona de la ciudad de Cali.
Fuente: Google Earth (2020).

Con los datos numéricos del área de consumo de suelo en las dos temporalidades y los datos de población proyectada en cabeceras municipales, se calculan las tasas de crecimiento de la población consumo del suelo.

De manera general, los incrementos del consumo de suelo urbano se encuentran localizados en las zonas periféricas de las ciudades de estudio, donde las mayores tasas se manifiestan en ciudades intermedias y pequeñas. Las dos ciudades con mayor tasa de consumo del suelo urbano son Madrid y Zipaquirá en el departamento de Cundinamarca, indicativo de sus procesos actuales de urbanización a partir de la alta demanda de espacios de vivienda derivada de la población de Bogotá D.C. A manera de ejemplo gráfico, como se ha hecho en las secciones anteriores de este artículo, se presentan los mapas que destacan las zonas de consumo del suelo urbano en las ciudades de Cali (Figura 10) y Medellín (Figura 11). De otro lado, las mayores tasas de crecimiento de la población se presentan en Sabaneta (Antioquia) y Cajicá (Cundinamarca), municipios cercanos a grandes ciudades como Medellín y Bogotá.

Los valores obtenidos para el indicador en las 63 ciudades reflejan que doce ciudades tienen un valor mayor a uno; 49 ciudades, un valor inferior a uno (positivo); y dos ciudades indicador con valor negativo. De acuerdo con la interpretación de resultados propuesta en el metadato del indicador (ONU-Hábitat 2020a), valores superiores a uno implican un posible uso ineficiente del suelo, caso contrario a los valores por debajo de uno, que representan efectos de estabilización, donde valores próximos a cero reflejarían procesos de densificación. En este caso, se destacan los valores altos significativos del indicador para las ciudades de: Barrancabermeja (5,41); Pereira (3,28); y Cartago (2,64). El valor negativo del indicador que se manifiesta en las ciudades de Buga y Pasto obedece a las tasas de crecimiento de población negativas entre los años 2015 y 2020. El valor derivado del indicador a nivel nacional es 0,503.

La Tabla 6 presenta, a manera de ejemplo y en concordancia con los anteriores, los valores de las tasas y el indicador para las ciudades de Cali y Medellín. En el anexo 1 se dispone la tabla completa de los resultados para las 63 ciudades definidas y a nivel nacional.

Tabla 6. Tasas e indicador ODS 11.3.1 para las ciudades de Cali y Medellín

Ciudad	Tasa crecimiento poblacional	Tasa consumo del suelo	ODS 11.3.1
Cali	0,0020	0,0017	0,8605
Medellín	0,0037	0,0009	0,2481

Datos: Cálculo del indicador ODS 11.3.1 para las ciudades del país.

Indicador ODS 11.7.1 año 2018

Tomando como base el área urbana estimada para el año 2018, se hizo una validación en cada una de las ciudades de la muestra, a partir de las unidades prediales del catastro y la toponimia del MGN, con el fin de determinar los espacios públicos abiertos. A su vez, con el fin de complementar la información, se integró a la información anterior los espacios públicos derivados de *Open Street Map*, y de esta forma obtener una cobertura completa para cada ciudad. El uso de esta fuente cartográfica colaborativa fue sumamente valioso, ya que diversos espacios públicos no podían ser determinados a través de la clasificación por el tamaño del píxel o por la ausencia nombres geográficos actualizados, en especial en las zonas de urbanizaciones nuevas.

Cabe anotar que para el cálculo de este indicador, el espacio público abierto está compuesto por las zonas verdes y el área destinada a vías, la cual también fue estimada en cada ciudad. Adicionalmente, para la desagregación del indicador por los grupos de población de interés, se generaron las áreas de servicio requeridas para calcular la población con acceso a los espacios abiertos de uso público. La Figura 12 presenta los mapas correspondientes a dichos espacios (zonas verdes y área destinada a vías), así como las áreas de servicio definidas para la ciudad de Cali; la Figura 13, para la ciudad de Medellín.

Con los valores definidos de área urbana y del área de espacios abiertos de uso público, se realizó el cálculo del indicador global, aplicando la Ecuación 4. La Tabla 7 presenta los resultados obtenidos para las nueve ciudades de la muestra definida.

Tabla 7. Resultados indicador ODS 11.7.1: área urbana; área de espacios abiertos de uso público; proporción del área construida de la ciudad que es destinada a espacios abiertos de uso público.

Ciudad	Área urbana (m ²)	Área espacios abiertos de uso público (m ²)	Indicador global ODS 11.7.1
Pereira	8.677.835,3	3.919.722,9	45,2 %
Cali	74.264.818,8	31.913.933,2	43 %
Medellín	53.542.076,6	22.517.661,7	42,1 %
Bogotá D.C.	245.293.914,9	94.153.746,9	38,4 %
Soacha	11.728.165,1	4.173.642,1	35,6 %
Bucaramanga	15.436.523,2	5.392.587,4	34,9 %
Turbaco	3.136.856,3	915.097,3	29,2 %
Barranquilla	68.871.089,1	19.617.412	28,5 %
Cartagena	41.848.557,5	22.517.661,7	23,7 %

Datos: cálculo del indicador ODS 11.7.1 para las ciudades del país.

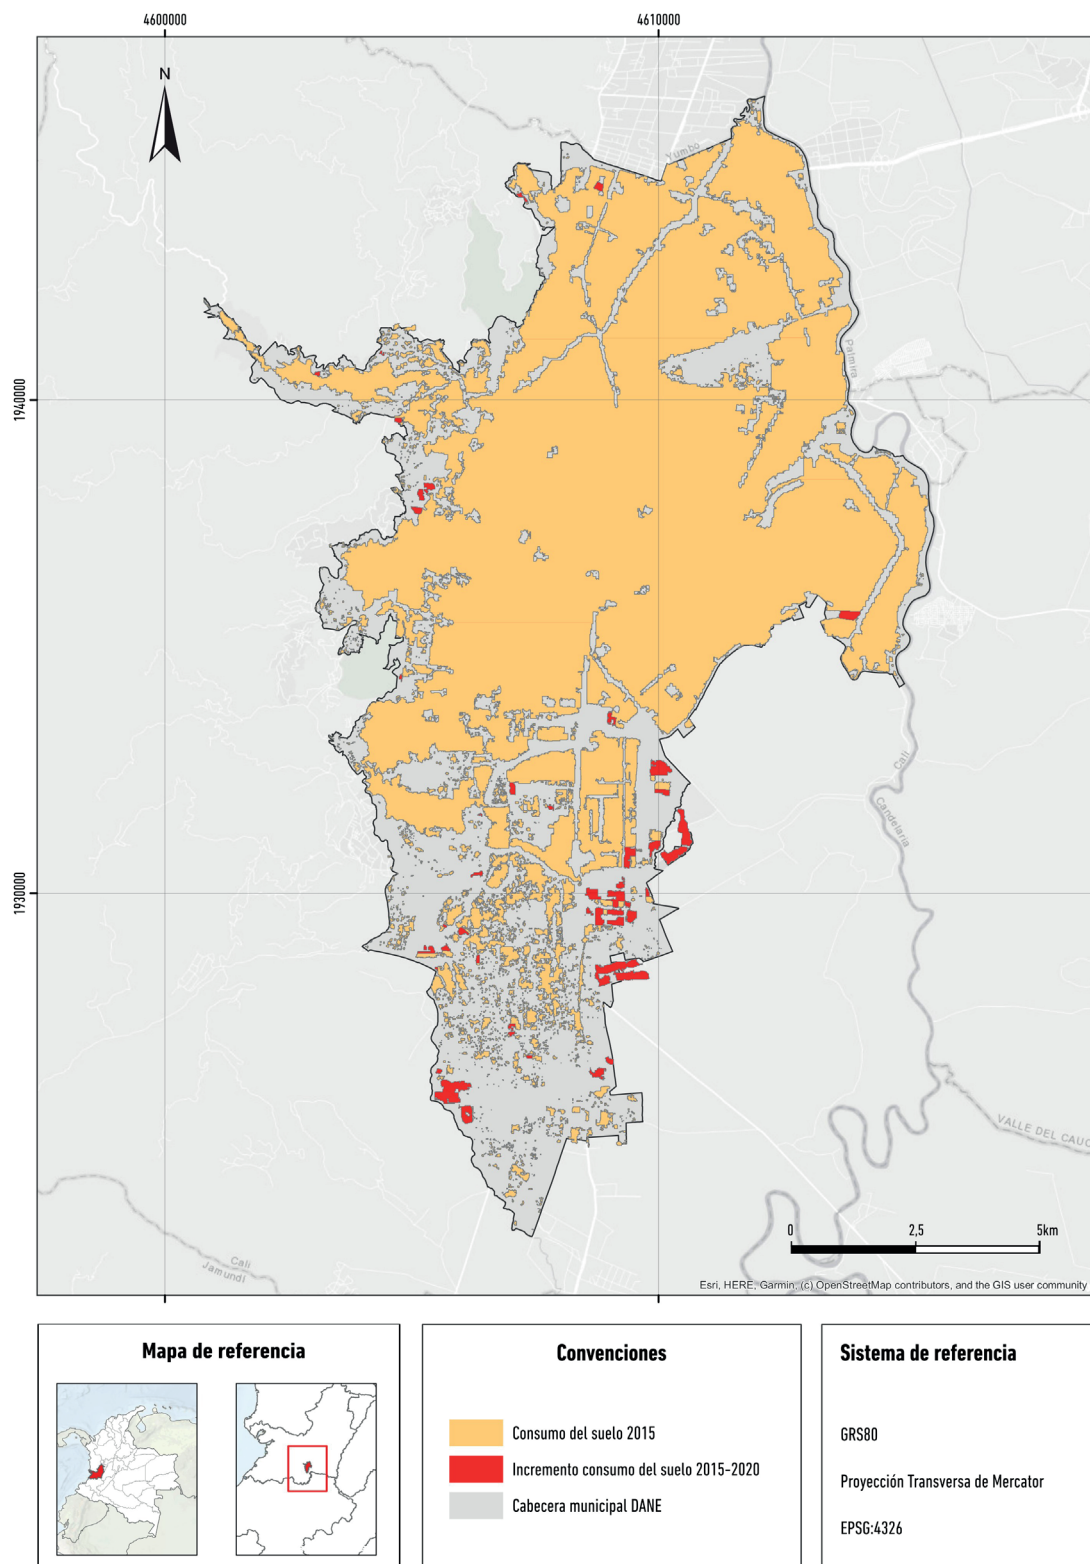


Figura 10. Consumo del suelo urbano entre 2015 y 2020 en la ciudad de Cali.
Datos: procesos geoespaciales elaborados para el cálculo del indicador ODS 11.3.1.

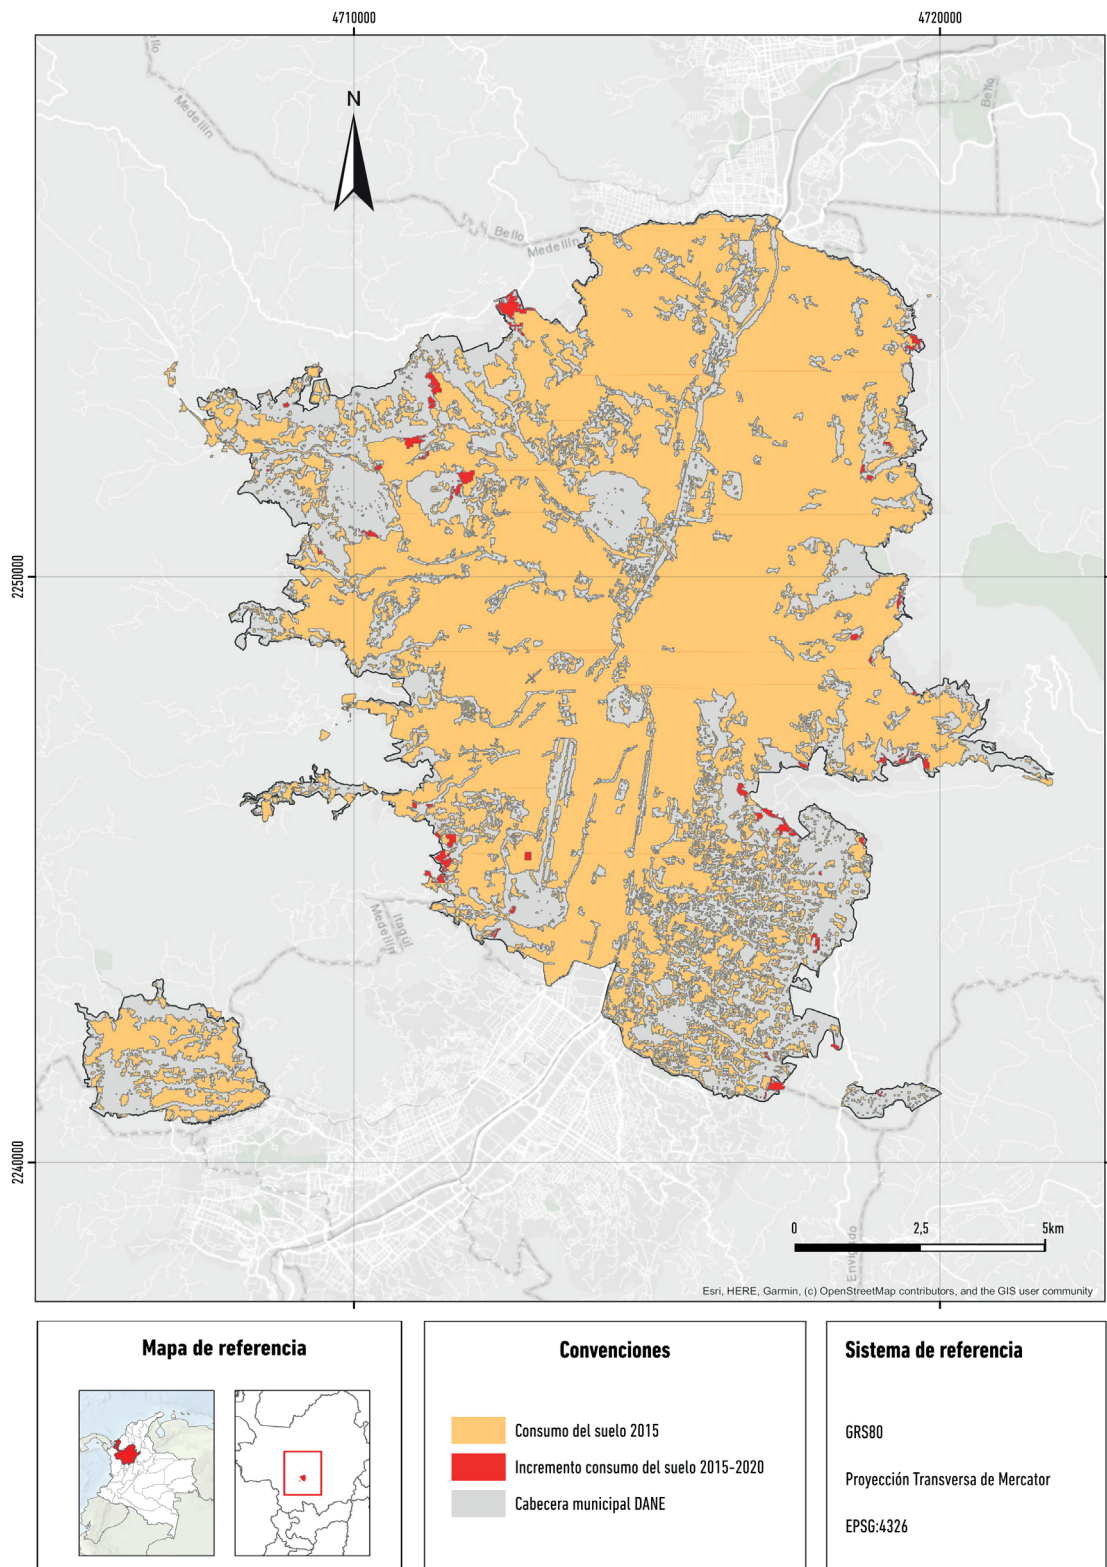


Figura 11. Consumo del suelo urbano entre 2015 y 2020 en la ciudad de Medellín.
 Datos: procesos geospaciales elaborados para el cálculo del indicador ODS 11.3.1.

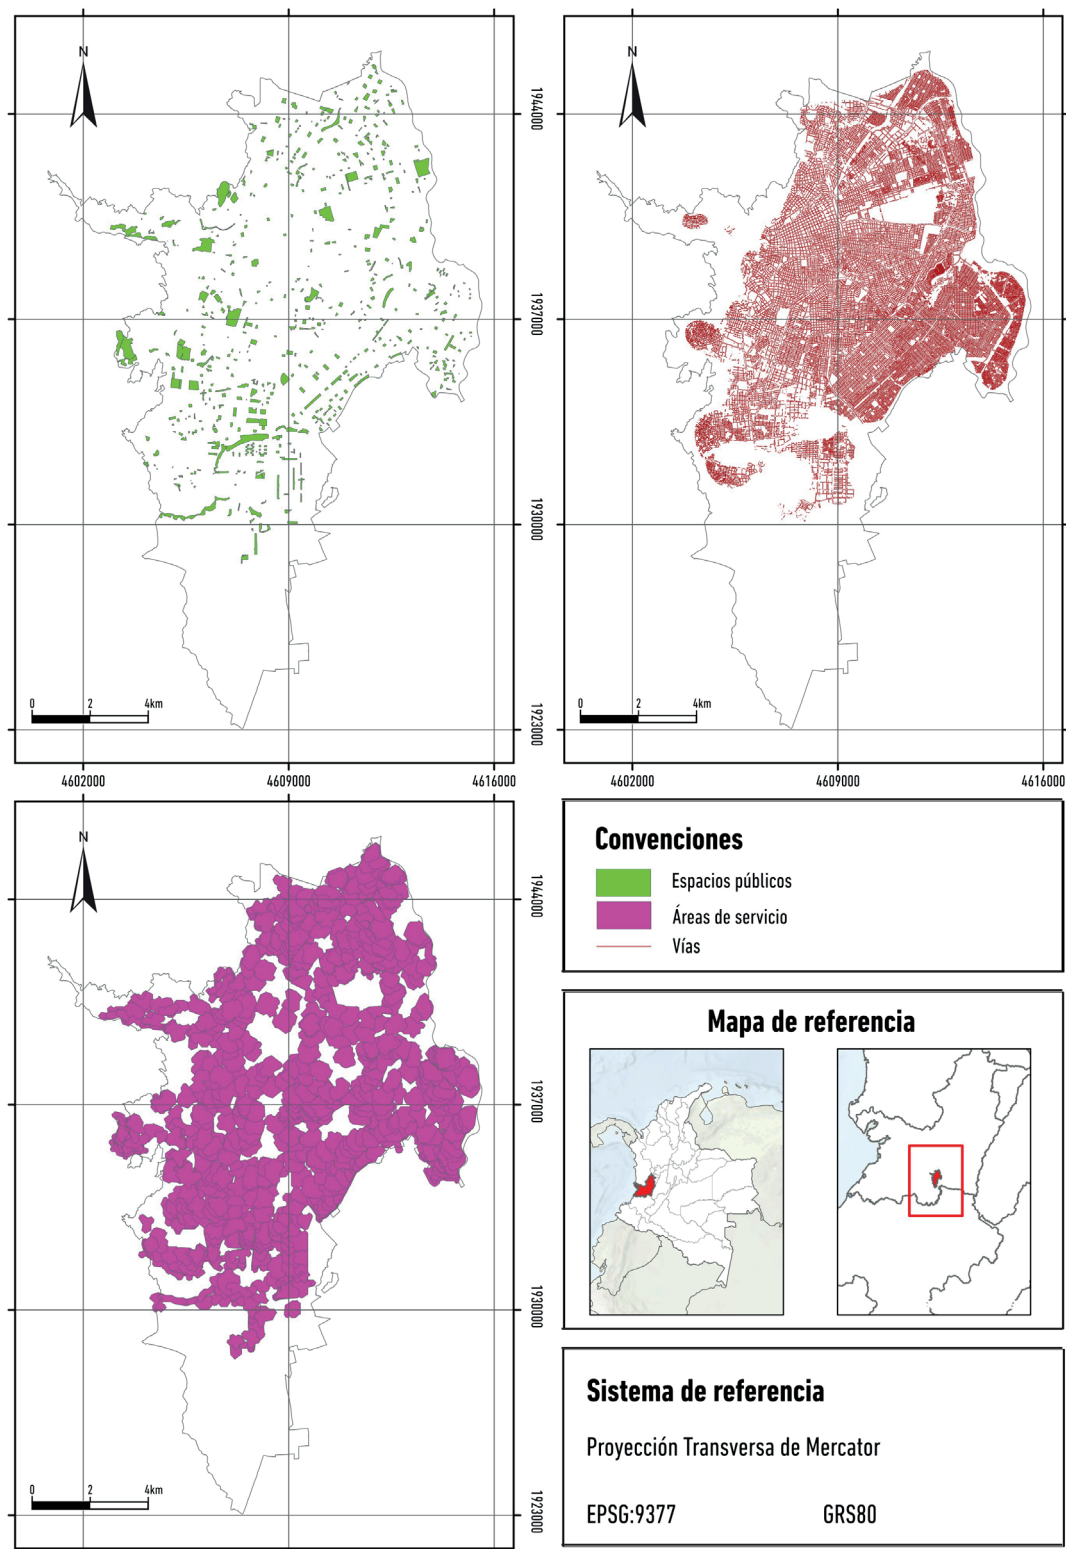


Figura 12. Espacios abiertos de uso público (zonas verdes y vías), en la ciudad de Cali.
 Datos: procesos geoespaciales elaborados a partir de imágenes satelitales Sentinel-2 (2018) y técnicas SIG.

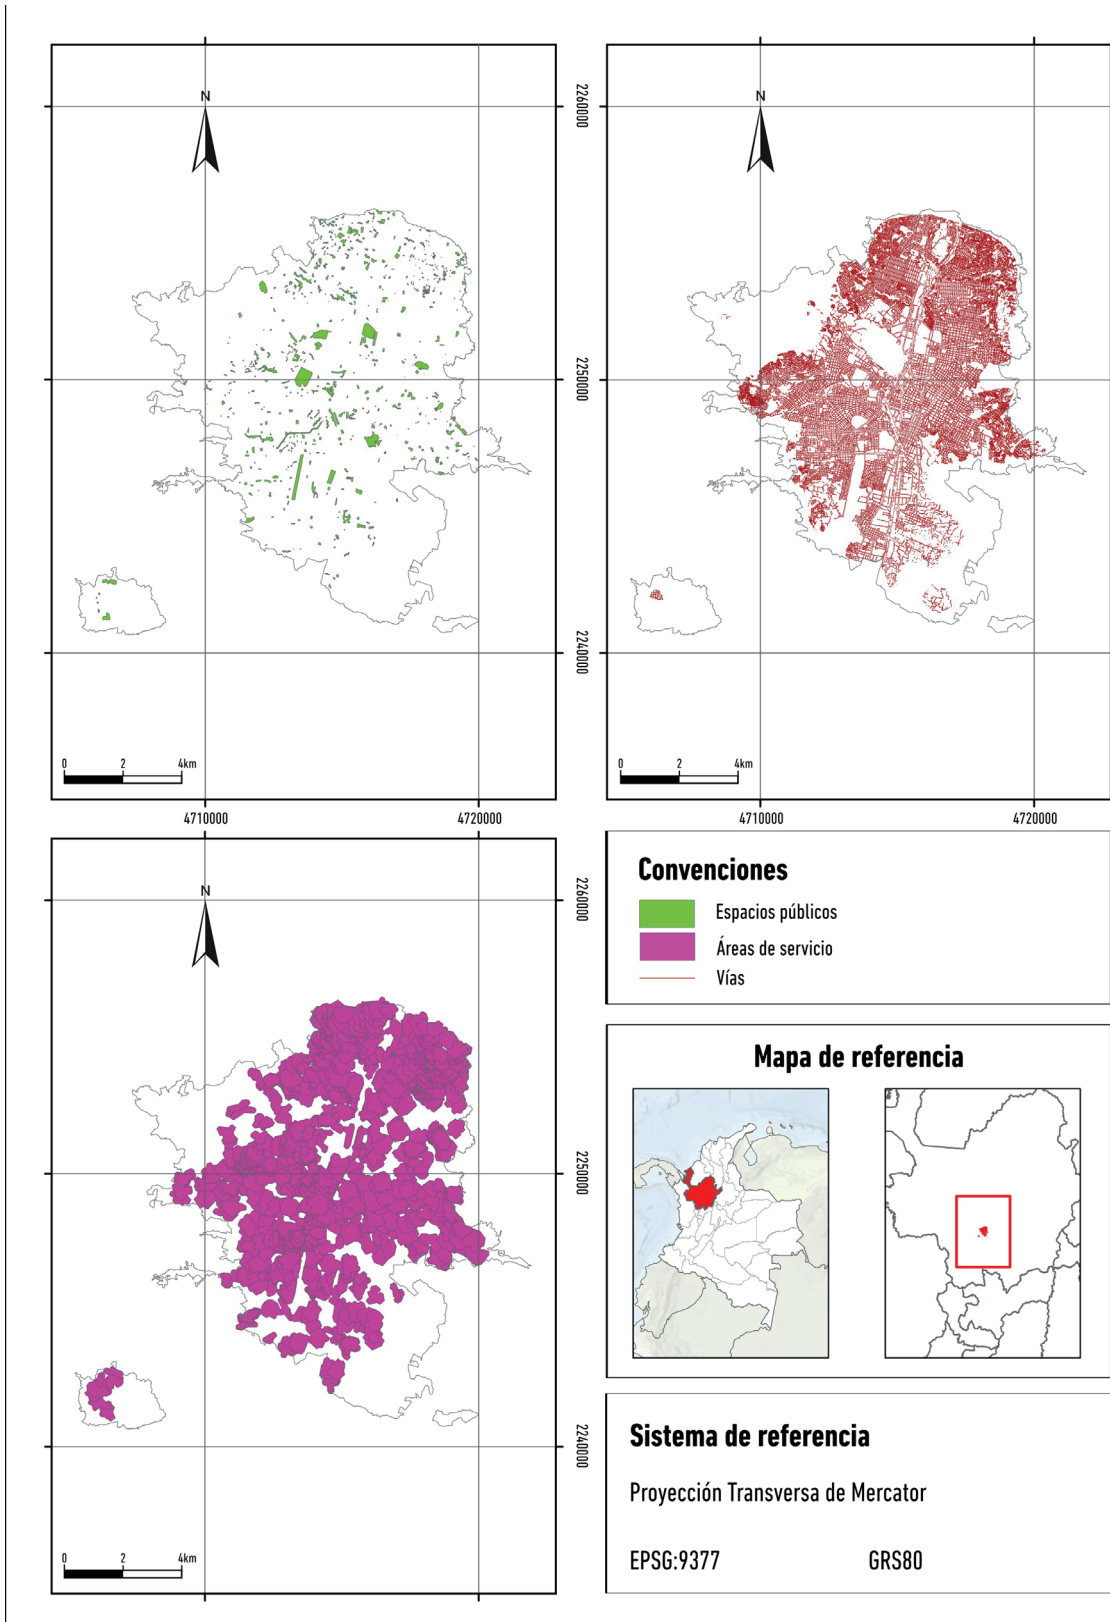


Figura 13. Espacios abiertos de uso público (zonas verdes y vías), en la ciudad de Medellín.
 Datos: procesos geospaciales elaborados a partir de imágenes satelitales Sentinel-2 (2018) y técnicas SIG.

De los resultados del indicador se destaca que las ciudades de Pereira, Cali y Medellín poseen los porcentajes más altos de área construida destinada a espacios abiertos de uso público, superiores al 40 %, caso contrario a ciudades de la muestra ubicadas en la región Caribe, Turbaco, Barranquilla y Cartagena, con porcentajes inferiores al 30 %. El valor estimado del indicador a nivel nacional es igual a 33,2 %.

La desagregación del indicador se efectúa determinando la proporción de los grupos de población de interés con acceso a los espacios públicos abiertos a través de la superposición de la información censal georreferenciada en las áreas de servicio. De esta manera se obtuvo el total de población para cada uno de los grupos poblacionales de interés, contenida en las áreas de servicio, para así aplicar la Ecuación 5, obteniendo el indicador desagregado como se observa en la Tabla 8.

Tabla 8. Resultados desagregados del indicador ODS 11.7.1: proporción de los grupos de población de interés, con acceso a espacios abiertos de uso público

Ciudad	Mujeres	Menores de 14 años	Personas con limitaciones
Bogotá D.C.	97,1 %	97,1 %	97,5 %
Pereira	91,1 %	90,9 %	91,6 %
Soacha	88,7 %	87,2 %	89,4 %
Medellín	88,2 %	88,4 %	88,8 %
Bucaramanga	88,2 %	86,6 %	88,1 %
Cali	86,8 %	86,6 %	87,0 %
Turbaco	67,2 %	65,6 %	73,9 %
Barranquilla	67,1 %	63,8 %	71,1 %
Cartagena	60,5 %	57,4 %	64,1 %

Datos: Cálculo del indicador ODS 11.7.1 para las ciudades del país.

De acuerdo con la Tabla 9, las ciudades con mayor porcentaje de población perteneciente a los grupos de interés, con acceso a espacios abiertos de uso público, son Bogotá D.C. y Pereira, con valores superiores al 90 %. Caso contrario se presenta la ciudad de Cartagena con valores próximos al 60 %. Se destaca, adicionalmente, que las personas del grupo poblacional de personas con limitaciones presentan mayores porcentajes de acceso respecto a los otros dos grupos poblacionales. Ahora bien, los valores estimados del indicador desagregado para el nivel nacional son los siguientes: mujeres, 80,0 %; menores de 14 años, 77,8 %; personas con limitaciones, 84,8 %.

Conclusiones y discusión

Con este trabajo, se presenta la propuesta metodológica desarrollada para el cálculo de los indicadores ODS 11.3.1 y 11.7.1 en Colombia, soportado por la integración de información estadística y geoespacial, sumado de procesamiento de imágenes satelitales en la nube, aprovechando las potencialidades de los métodos de clasificación enmarcadas en *Machine Learning*.

En cuanto a la definición de ciudades y la clasificación de las áreas urbanas, la metodología recomendada del grado de urbanización DEGURBA, es adecuada y óptima para la medición de indicadores asociados al ODS 11, enfocado en las ciudades.

Respecto al uso y procesamiento de imágenes satelitales, como información geoespacial clave y fuente masiva de datos para el monitoreo del desarrollo sostenible, actualmente se cuenta con una gran variedad de imágenes de acceso libre, lo que permite realizar clasificaciones en distintas fechas, aventajando el empleo de otras fuentes como son GHSL, disponibles para años específicos y con una resolución espacial menos detallada, respecto a las imágenes Sentinel-2 o Landsat-8 (Melchiorri et ál. 2019).

El procesamiento de imágenes en la nube garantiza, además del acceso, realizar procesos más rápidos, con automatización de tareas, desde la búsqueda de las imágenes disponibles hasta obtener la clasificación final de las áreas y/o coberturas que se requieran. Esto evita requerir equipos de cómputo de gran capacidad de cómputo junto a licencias de software especializado en el procesamiento de imágenes. Justamente, una de las ventajas principales en este ambiente es el desarrollo de algoritmos o *scripts* que pueden ser replicables en otras zonas o adaptables para otros estudios similares, gracias a la aplicación de técnicas de clasificación o predicción sobre grandes volúmenes de datos, derivadas del *Machine Learning*, como los árboles de decisión aleatorios o *Random Forest*.

En cuanto a la información estadística, la importancia de levantar, disseminar y disponer datos georreferenciados y desagregados por parte de las ONE, en este caso el DANE, se convierten en insumos fundamentales para el monitoreo de indicadores con énfasis sociodemográfico. Es así que los datos empleados en Colombia para el cálculo de los indicadores incluyó fuentes estadísticas convencionales como las proyecciones de población para determinar la tasa de crecimiento de la población en el indicador ODS 11.3.1, y las unidades censales georreferenciadas para determinar la desagregación por grupos poblacionales en el indicador ODS 11.7.1, las cuales son

consideradas datos de alta resolución, en comparación a otras fuentes de datos, como las grillas de población o la información agregada a niveles superiores.

Los resultados obtenidos en el indicador ODS 11.3.1 destacan casos especiales en ciudades con un alto consumo del suelo urbano entre 2015 y 2020, y dos ciudades con tasas de crecimiento poblacional negativas. No obstante, el valor derivado nacional indica un comportamiento estable de acuerdo la interpretación del indicador. Respecto al indicador ODS 11.7.1, se destacan los valores inferiores en las ciudades de la muestra pertenecientes a la Región Caribe, los cuales se pueden inferir, en términos de morfología urbana, por el entramado vial predominantemente irregular de las ciudades de Cartagena y Turbaco, sumado a la fundación histórica de estos asentamientos, así como en vocación portuaria e industrial del distrito de Barranquilla. De otro lado, Medellín, Cali y Pereira son ciudades en donde más del 40 % de su superficie edificada está destinada a espacios abiertos de uso público, porcentaje superior al valor estimado nacional, correspondiente al 33 %.

El desarrollo metodológico expuesto en este artículo sigue los lineamientos generales del organismo custodio de los dos indicadores, ONU-Hábitat, realizando procesos de clasificación de imágenes satelitales y análisis de información geoespacial. No obstante, es probable que la identificación obtenida de espacios abiertos de uso público podría diferir respecto a un inventario detallado de este tipo de espacios, ya que los resultados finales del indicador en cada ciudad están condicionados a los insumos empleados. En este sentido, para trabajos futuros se sería recomendable disponer y utilizar o información oficial o registros administrativos de espacio público, y continuar explotando fuentes alternativas de información, como las plataformas de mapeo colectivo, entre ellas, OSM, la cual ha sido empleada en otros trabajos (Aguilar y Kuffer 2020; Giuliani et ál. 2021) y que por su actualización constante garantiza no solo el cálculo del indicador sino su actualización en el tiempo, sumado a que es información de acceso libre.

Mientras que la actualización en la medición del indicador ODS 11.3.1 puede estar garantizada gracias a la disponibilidad de imágenes satelitales en diferentes vigencias y a las fuentes de datos de población, como las proyecciones censales o iniciativas globales tales como *WorldPop* y *Facebook*, el cálculo actualizado del indicador ODS 11.7.1 estaría afectado por la desactualización de la información catastral en algunas ciudades, creando una brecha de información con las ciudades que si mantienen

procesos catastrales continuos. Con el fin de solucionar lo anterior, sumado a garantizar una estructura de información que permita la interoperabilidad con otras fuentes, se espera que el desarrollo del catastro multipropósito en Colombia procure mecanismos para disponer de información predial actualizada, de gran utilidad para el cálculo del indicador.

La aplicación de técnicas de análisis espacial en SIG permite explorar diversas posibilidades en estudios de accesibilidad urbana, ya sea a través de áreas de servicio o la definición de métricas de acceso a los espacios abiertos de uso público. Cabe destacar que el cálculo desagregado del indicador ODS 11.7.1 por grupos poblacionales, a la fecha no se ha documentado en publicaciones y artículos relacionados, ya que el enfoque se ha plasmado sustancialmente en la determinación de los espacios abiertos.

Los indicadores calculados no solo tienen como fin cumplir con el seguimiento a la Agenda Global del Desarrollo Sostenible, sino que se afirman como resultados idóneos y necesarios para alcaldes y gobiernos municipales, ya que la desagregación espacial y focalización de estos indicadores serían un soporte para la toma de decisiones informada, en pro de llegar a la planificación y ordenamiento de ciudades sostenibles. En este sentido, se insta a los mandatarios y gabinetes a emplear estos recursos, con el fin de plantear políticas, programas y proyectos que busquen la inclusión y acceso de los diferentes grupos poblacionales a los espacios públicos y su aprovechamiento, así como el desarrollo de estrategias para lograr un equilibrio sostenible y sustentable entre el crecimiento de la población y los procesos de urbanización.

Agradecimientos

Los autores de este artículo agradecen a la Dirección Técnica de Geoestadística del DANE, en cabeza de la Ingeniera Sandra Moreno, por su apoyo constante a los procesos de investigación para el cálculo de indicadores ODS, sumado a su participación en las primeras exploraciones metodológicas del ODS 11.3.1. Agradecimiento especial a los Ingenieros Yineth Acosta y David González, y a los estadísticos Aníbal Montero y Lisethe Castellanos, por todo el trabajo y aportes realizados en fases preliminares, cálculos previos y estimaciones nacionales, así como al Grupo Interno de Trabajo de los Objetivos de Desarrollo Sostenible del DANE, por los contactos establecidos con la iniciativa de cooperación alemana GIZ, y sus aportes en el uso de fuentes colaborativas. Finalmente,

agradecemos al Ingeniero Juan Camilo Aros por la realización de los mapas expuestos en este trabajo.

Referencias

- Adams, Barbara, y Karen Judd. 2018. "Los altibajos de los indicadores: midiendo el progreso de los ODS." Nueva York: Global Policy Watch. Consultado el 14 de septiembre de 2021. https://www.globalpolicywatch.org/esp/wp-content/uploads/2018/05/GPW22_2018_05_09-esp.pdf
- Aguilar, Rosa, y Monika Kuffer. 2020. "Cloud Computation Using High-Resolution Images for Improving the SDG Indicator on Open Spaces." *Remote Sensing* 12 (7): 1144. <https://doi.org/10.3390/rs12071144>
- ANDA (Archivo Nacional de Datos). 2021. "Censo Nacional de Población y Vivienda - CNPV - 2018." *Microdatos* 2021. Consultado del 7 de enero de 2022. <http://microdatos.dane.gov.co/index.php/catalog/643>
- Andries, Ana, Stephen Morse, Richard Murphy, Jim Lynch, y Emma Woolliams. 2019. "Seeing Sustainability from Space: Using Earth Observation Data to Populate the UN Sustainable Development Goal Indicators." *Sustainability* 11 (18): 5062. <https://doi.org/doi:10.3390/su11185062>
- Aquilino, Mariella, María Adamo, Palma Blonda, Angela Barbanente, y Cristina Tarantino. 2021. "Improvement of a Dasymeric Method for Implementing Sustainable Development Goal 11 Indicators at an Intra-Urban Scale." *Remote Sensing* 13 (14): 2835. <https://doi.org/10.3390/rs13142835>
- Avtar, Ram, Ridhika Aggarwal, Ali Kharrazi, Pankaj Kumar, y Tonni Agustiono Kurniawan. 2019. "Utilizing Geospatial Information to Implement SDGs and Monitor Their Progress." *Environmental Monitoring and Assessment*, no. 35. <https://doi.org/10.1007/s10661-019-7996-9>
- Belgiu, Mariana, y Lucian Drăgu. 2016. "Random Forest in Remote Sensing: A Review of Applications and Future Directions." *ISPRS Journal of Photogrammetry and Remote Sensing* 114: 24-31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Bozzano, Horacio, Julieta Frediani, Gastón Cirio, y Cintia Barrionuevo. 2016. *Metodología de la Investigación en Geografía*. Primera. La Plata, Argentina: Editorial de la Universidad de La Plata.
- CEPAL (Comisión Económica para América Latina y el Caribe). 2018. *La Agenda 2030 y Los Objetivos de Desarrollo Sostenible: Una Oportunidad Para América Latina y El Caribe*. Santiago: Naciones Unidas. Consultado el 2 de enero de 2022. https://repositorio.cepal.org/bitstream/handle/11362/40155/24/S1801141_es.pdf
- Chen, Teo. 2019. "Pansharpening Sentinel-2 Imagery in Google Earth Engine." *The Landscape Ecology and Conservation Laboratory*. 17 de julio.
- CODS (Centro de los Objetivos de Desarrollo Sostenible para América Latina). 2020. "Índice ODS 2019 para América Latina y el Caribe." Bogotá: Centro de los Objetivos de Desarrollo Sostenible para América Latina y el Caribe. <https://cods.uniandes.edu.co/wp-content/uploads/2020/06/Índice-ODS-2019-para-América-Latina-y-el-Caribe-2.pdf>
- DANE (Departamento Administrativo Nacional de Estadística). 2005. "Información general." *Censo general* 2005. <https://www.dane.gov.co/index.php/estadisticas-por-tema/demografia-y-poblacion/censo-general-2005-1>
- DANE (Departamento Administrativo Nacional de Estadística). 2018a. "Descarga del Marco Geoestadístico Nacional (MGN)." Geoportal del DANE. 2018. <https://geoportal.dane.gov.co/servicios/descarga-y-metadatos/descarga-mgn-marco-geoestadistico-nacional/>
- DANE (Departamento Administrativo Nacional de Estadística). 2018b. "Manual de conceptos - Censo Nacional de Población y Vivienda 2018." Bogotá D.C. <https://www.dane.gov.co/files/censo2018/informacion-tecnica/cnpv-2018-glosario.pdf>
- DANE (Departamento Administrativo Nacional de Estadística). 2018c. "Proyecciones de Población." *Censo Nacional de Población y Vivienda*. 2018. <https://www.dane.gov.co/index.php/estadisticas-por-tema/demografia-y-poblacion/proyecciones-de-poblacion>
- DANE (Departamento Administrativo Nacional de Estadística). 2020. "Descarga del Marco Geoestadístico Nacional (MGN)." Geoportal del DANE. 2020. <https://geoportal.dane.gov.co/servicios/descarga-y-metadatos/descarga-mgn-marco-geoestadistico-nacional/>
- Digital Globe. s.f. "Transforming Our World - Geospatial Information Key to Achieving the 2030 Agenda for Sustainable Development." Consultado el 10 de enero de 2022. <https://sdgs.un.org/2030agenda>
- Dysterud, Marianne, y Erik Engelién. 2019. *Testing the Global Statistical Geospatial Framework (GSGF Europe) by Calculating a Selection of sdg Indicators - A Study by the geostat 3 Project*. EFGS and Eurostat. https://www.efgs.info/wp-content/uploads/geostat/3/GEOSTAT3_WP2_SDG_findings_report_v1.0.pdf
- ESA (European Space Agency). s. f. "Sentinel-2." *Sentinel Online*. Consultado el 20 de julio de 2022. <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>
- ESA (European Space Agency). 2018. *Satellite Earth Observations in Support of the Sustainable Development Goals*, editado por Marc Paganini, Ivan Petiteville, Stephen Ward,

- George Dyke, Matthew Steventon, Jennifer Harry y Flora Kerblat. París: European Space Agency. http://eohandbook.com/sdg/files/CEOS_EOHB_2018_SDG.pdf
- EU, FAO, ILO, OCDE, UN-Habitat, y WB (The European Union, The Food and Agriculture Organization of the United Nations, the International Labour Office, the Organization for Economic Co-operation and Development, United Nations Human Settlements Programme y the World Bank). 2020. *A Recommendation on the Method to Delineate Cities, Urban and Rural Areas for International Statistical Comparisons*. Bruselas: UN Statistical Commission. <https://ec.europa.eu/eurostat/cros/system/files/bg-item3j-recommendation-e.pdf>
- European Union-FAO-UN-Habitat-OECD-World Bank. 2020. *Applying the Degree of Urbanisation: A Methodological Manual to Define Cities, Towns and Rural Areas for International Comparisons*, editado por Lewis Dijkstra, Teodora Brandmüller, Thomas Kemper, Arbab Asfandiyar y Paolo Veneri. Bruselas: European Union. Consultado 7 de enero de 2022. <https://ec.europa.eu/eurostat/documents/10186/11395216/DEGUR-BA-manual.pdf/3a6bab6a-3fb1-4261-ad5b-e604cb67dcod>
- Flood, Neil. 2013. "Seasonal Composite Landsat TM/ETM+ Images Using the Medoid (a Multi-Dimensional Median)." *Remote Sensing* 5 (12): 6481-6500. <https://doi.org/10.3390/rs5126481>
- Foody, Giles M. 2002. "Status of Land Cover Classification Accuracy Assessment." *Remote Sensing of Environment* 80 (1): 185-201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- Giuliani, Gregory, Ekkehard Petri, Eduard Interwies, Veronika Vysna, Yaniss Guigoz, Nicolas Ray, y Ian Dickie. 2021. "Modelling Accessibility to Urban Green Areas Using Open Earth Observations Data: A Novel Approach to Support the Urban SDG in Four European Cities." *Remote Sensing* 13 (3): 422. <https://doi.org/10.3390/rs13030422>
- GUO (Global Urban Observatory). 2020. *Status of Human Settlements Statistics*. Nairobi: UN-Habitat. Consultado el 6 de enero de 2022. https://unhabitat.org/sites/default/files/2020/06/status_of_human_settlement_statistics.pdf
- Halderen, Gemma Van, Irina Bernal, Tanja Sejerssen, Ronald Jansen, Niels Ploug, y Maciej Truszczyński. 2021. "Big Data for the SDGs - Country Examples in Compiling SDG Indicators Using Non-Traditional Data Sources." SD/WP/12/January. Bangkok, Tailandia: Statistics Division Economic and Social Commission for Asia and the Pacific (ESCAP) United Nations. https://www.unescap.org/sites/default/d8files/knowledge-products/SD_Working_Paper_no12_Jan2021_Big_data_for_SDG_indicators.pdf
- Hernández Sampieri, Roberto, Carlos Fernández Collado, y Pilar Baptista Lucio. 2015. *Metodología de la Investigación*. Quinta Edición. México D.F.: McGraw-Hill.
- Holloway, Jacinta, Kerrie Mengersen, y Kate Helmstedt. 2018. "Spatial and Machine Learning Methods of Satellite Imagery Analysis for Sustainable Development Goals." En *16th Conference of IAOS*, del 19 al 21 de septiembre, París, Francia. Consultado 10 de octubre de 2021. https://www.oecd.org/iaos2018/programme/IAOS-OECD2018_Holloway-Mengersen-Helmstedt.pdf
- Huerta, Roberto, Fabiola Yépez, Diego Lozano-García, Víctor Guerra, Adrián Ferriño, Héctor de León, Ricardo Cavazos, y Adriana Vargas-Martínez. 2021. "Mapping Urban Green Spaces at the Metropolitan Level Using Very High Resolution Satellite Imagery and Deep Learning Techniques for Semantic Segmentation." *Remote Sensing* 13 (11): 2031. <https://doi.org/10.3390/rs13112031>
- IGAC (Instituto Geográfico Agustín Codazzi). 2017. "Datos abiertos catastro." Geportal. Consultado el 10 de enero de 2022. <https://geportal.igac.gov.co/contenido/datos-abiertos-catastro>
- Kanuri, Chaitanya, Aromar Revi, Jessica Espey, y Holger Kuhl. s.f. *Cómo implementar los ODS en las ciudades. Un manual introductorio para quienes trabajan en el ámbito del desarrollo urbano sostenible*. Sustainable Development Solutions Network y German Cooperation Agency. https://reds-sdsn.es/wp-content/uploads/2018/12/SDG-Cities-Guide-Spanish_edited_Final-version.pdf
- Li, Chaopeng, Guoyin Cai, y Mingyi Du. 2021. "Big Data Supported the Identification of Urban Land Efficiency in Eurasia by Indicator SDG 11.3.1." *ISPRS International Journal of Geo-Information* 10 (2): 64. <https://doi.org/10.3390/ijgi10020064>
- Li, Yunsong, Jiahui Qu, Wenqian Dong, y Yuxuan Zheng. 2018. "Hyperspectral Pansharpening via Improved PCA Approach and Optimal Weighted Fusion Strategy." *Neurocomputing* 315: 371-80. <https://doi.org/10.1016/j.neucom.2018.07.030>
- Liu, Canran, Paul Frazier, y Lalit Kumar. 2007. "Comparative Assessment of the Measures of Thematic Classification Accuracy." *Remote Sensing of Environment* 107 (4): 606-616. <https://doi.org/10.1016/j.rse.2006.10.010>
- Lorenzo, Claudia. 2020. "Medición de los Objetivos de Desarrollo Sostenible en la Unión Europea a través de indicadores compuestos." Documentos de Trabajo n° especial (2ª época), Madrid, Fundación Carolina.
- Melchiorri, Michele, Martino Pesaresi, Aneta Florczyk, Christina Corbane, y Thomas Kemper. 2019. "Principles and Applications of the Global Human Settlement Layer as Baseline for the Land Use Efficiency Indicator—SDG 11.3.1." *International Journal of Geo-Information* 8 (2): 96. <https://doi.org/doi:10.3390/ijgi8020096>
- Millard, Koreen, y Murray Richardson. 2015. "On the Importance of Training Data Sample Selection in Random Forest

- Image Classification: A Case Study in Peatland Ecosystem Mapping." *Remote Sensing* 7 (7): 8489-8515. <https://doi.org/10.3390/rs70708489>
- Mudau, Naledzani, Dennis Mwaniki, Lesiba Tsoeleng, Morwapa Mashalane, Donatien Beguy, y Robert Ndugwa. 2020. "Assessment of SDG Indicator 11.3.1 and Urban Growth Trends of Major and Small Cities in South Africa." *Sustainability* 12 (17): 7063. <https://doi.org/doi:10.3390/su12177063>
- NASA (Administración Nacional de Aeronáutica y el Espacio). s. f. "Landsat 8." *Landsat Science*. <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>
- Ndugwa, Robert. 2018. "Urban SDG and GeoSpatial Information Needs and Challenges." Deqing: UN-Habitat. Consultado de lo de enero de 2022. https://ggim.un.org/unwgic/presentations/7.1_Robert_Ndugwa.pdf
- Nonni, Frederica, Diego Malacarne, Salvatore Eugenio Pappalardo, Daniele Codato, Franco Meggio, y Massimo De Marchi. 2018. "Sentinel-2 Data Analysis and Comparison with UAV Multispectral Images for Precision Viticulture." *GI Forum* 6 (1): 105-16. https://doi.org/10.1553/giscience2018_01_s105
- O'Connor, Brian, Katherine Moul, Barbara Pollini, Xavier de Lamo, y Will Simonson. 2020. *Earth Observation for SDG: Compendium of Earth Observation Contributions to the SDG Targets and Indicators*. European Spatial Agency. Consultado el 20 de julio de 2021. https://eo4society.esa.int/wp-content/uploads/2021/01/EO_Compendium-for-SDGs.pdf
- ONU (Organización de las Naciones Unidas). 2018. *Tracking Progress Towards Inclusive, Safe, Resilient and Sustainable Cities and Human Settlements. SDG 11 Synthesis Report. High Level Political Forum 2018*. Nairobi: Naciones Unidas. Consultado 2 de enero de 2022. <http://uis.unesco.org/sites/default/files/documents/sdg11-synthesis-report-2018-en.pdf>
- ONU (Organización de las Naciones Unidas). 2019. *Informe de los Objetivos de Desarrollo Sostenible 2019*. Nueva York: Naciones Unidas. Consultado 2 de enero de 2022. https://unstats.un.org/sdgs/report/2019/The-Sustainable-Development-Goals-Report-2019_Spanish.pdf
- ONU (Organización de las Naciones Unidas). 2021. "IAEG-SDGs Tier Classification for Global SDG Indicators." *United Nations Statistics Division Development Data and Outreach Branch*. Consultado el 6 de enero de 2022. <https://unstats.un.org/sdgs/iaeg-sdgs/tier-classification/>
- ONU-Hábitat (Programa de Naciones Unidas para los Asentamientos Humanos). s. f. *Sustainable Development Goal 11: Make Cities and Human Settlements Inclusive, Safe, Resilient and Sustainable - A Guide to Assist National and Local Governments to Monitor and Report on SDG Goal 11+ Indicators*. Nairobi: ONU-Hábitat. Consultado del 6 de enero de 2022. <https://www.local2030.org/library/60/SDG-Goal-11-Monitoring-Framework-A-guide-to-assist-national-and-local-governments-to-monitor-and-report-on-SDG-goal-11-indicators.pdf>
- ONU-Hábitat (Programa de Naciones Unidas para los Asentamientos Humanos). 2018. *SDG Indicator 11.7.1 Training Module: Public Space*. Nairobi: Programa de Naciones Unidas para los Asentamientos Humanos. Consultado el 7 de enero de 2022. https://unhabitat.org/sites/default/files/2020/07/indicator_11.7.1_training_module_public_space.pdf
- ONU-Hábitat (Programa de Naciones Unidas para los Asentamientos Humanos). 2020a. *Metadata on SDGs Indicator 11.3.1 Indicator Category: Tier II*. Nairobi: Programa de Naciones Unidas para los Asentamientos Humanos. Consultado el 7 de enero de 2022. https://unhabitat.org/sites/default/files/2020/11/metadata_on_sdg_indicator_11.3.1_07-2020_1.pdf
- ONU-Hábitat (Programa de Naciones Unidas para los Asentamientos Humanos). 2020b. *Metadata on SDGs Indicator 11.7.1 Indicator Category: Tier II*. Nairobi: Programa de Naciones Unidas para los Asentamientos Humanos. Consultado el 7 de enero de 2022. https://unhabitat.org/sites/default/files/2020/11/metadata_on_sdg_indicator_11.7.1_02-2020_1.pdf
- Ramírez, Miguel, Laura Martínez, Maryury Montilla, Óscar Sarmiento, Juan Lasso, y Sebastián Díaz. 2020. "Obtaining Agricultural Land Cover in Sentinel-2 Satellite Images with Drone Image Injection Using Random Forest in Google Earth Engine." *Revista de Teledetección*, no. 56, 49-68. <https://doi.org/10.4995/raet.2020.14102>
- Shafizadeh-Moghadam, Hossein, Masoud Minaei, Robert Gilmore Pontius, Ali Asghari, y Hashem Dadashpoor. 2021. "Integrating a Forward Feature Selection Algorithm, Random Forest, and Cellular Automata to Extrapolate Urban Growth in the Tehran-Karaj Region of Iran." *Computers, Environment and Urban Systems* 87: 101595. <https://doi.org/10.1016/j.compenvurbsys.2021.101595>
- Song, Yongze, y Peng Wu. 2021. "Earth Observation for Sustainable Infrastructure: A Review." *Remote Sensing* 13 (8): 1528. <https://doi.org/10.3390/rs13081528>
- Tavares, Paulo Amador, Norma Ely Santos Beltrão, Ulisses Silva Guimarães, y Ana Cláudia Teodoro. 2019. "Integration of Sentinel-1 and Sentinel-2 for Classification and LULC Mapping in the Urban Area of Belém, Eastern Brazilian Amazon." *Sensors* 19 (5): 1140. <https://doi.org/10.3390/s19051140>
- Traganos, Dimosthenis, Bharat Aggarwal, Dimitris Poursanidis, Konstantinos Topouzelis, Nektarios Chrysoulakis, y Peter Reinartz. 2018. "Towards Global-Scale Seagrass Mapping and Monitoring Using Sentinel-2 on Google Earth Engine: The Case Study of the Aegean and Ionian Seas." *Remote Sensing* 10 (8): 1227. <https://doi.org/10.3390/rs10081227>

- UN-GGIM: Europa (United Nations Global Geospatial Information Management). 2019a. *The Integration of Geospatial Data and Statistics to Compute SDG Indicators – Requirements and Practices: Scoping Paper*. Versión 1.0. Ginebra: United Nations. https://un-ggim-europe.org/wp-content/uploads/2020/06/UNGGIM-Europe_WG_DataIntegration_Subgroup-I_ScopingPaper_v1.0.pdf
- UN-GGIM: Europa (United Nations Global Geospatial Information Management). 2019b. *The Territorial Dimension in SDG Indicators: Geospatial Data Analysis and Its Integration with Statistical Data*. Lisboa: Instituto Nacional de Estatística de Portugal. https://un-ggim-europe.org/wp-content/uploads/2019/05/UN_GGIM_08_05_2019-The-territorial-dimension-in-SDG-indicators-Final.pdf
- UNFPA, DANE, y FAO (Fondo de Población de las Naciones Unidas, Departamento Administrativo Nacional de Estadística, y Organización de las Naciones Unidas para la Alimentación y la Agricultura). 2021. *Guía para la medición y reporte de los indicadores globales en el marco de cooperación de las Naciones Unidas para el Desarrollo Sostenible*. Bogotá, Colombia: UNFPA Colombia. https://colombia.unfpa.org/sites/default/files/pub-pdf/guia_xra_de_cooperacion_ajustes_060521.pdf
- Vaca, Margarita, y Juan Camilo Vega. 2019. *Generalidades del big data para el desarrollo sostenible en Colombia*. Bogotá: Big Data for Development - Cepei. <https://cepei.org/wp-content/uploads/2019/09/Generalidades-Big-Data.pdf>
- Wang, Yunchen, Chunlin Huang, Yaya Feng, Minyan Zhao, y Juan Gu. 2020. "Using Earth Observation for Monitoring SDG 11.3.1-Ratio of Land Consumption Rate to Population Growth Rate in Mainland China." *Remote Sensing* 12 (3): 357. <https://doi.org/doi:10.3390/rs12030357>

Miguel Ángel Ramírez Gutiérrez

Candidato a doctor en Geografía de la Universidad Nacional de Colombia, sede Bogotá, perteneciente a la red SDG Nexus Network, magíster en Geomática de la Universidad Nacional de Colombia e ingeniero Catastral y Geodesta de la Universidad Distrital Francisco José de Caldas. Líneas de investigación principales: teledetección, fotogrametría digital y cartografía.

Juan Carlos Lasso Rodríguez

Profesional investigador del Grupo Interno de Trabajo de Investigación y Desarrollo de la Dirección Técnica de Geoestadística, en el Departamento Administrativo Nacional de Estadística (DANE). Estudiante de la maestría en Teledetección de la Universidad Católica de Manizales e ingeniero Topográfico de la Universidad Distrital Francisco José de Caldas. Líneas de investigación principales: análisis espacial y teledetección.

Carlos Alberto Durán Gil

Coordinador del Grupo Interno de Trabajo de Investigación y Desarrollo de la Dirección Técnica de Geoestadística en el Departamento Administrativo Nacional de Estadística (DANE). Ingeniero Catastral y geodesta de la Universidad Distrital Francisco José de Caldas, especialista en Análisis Espacial de la Universidad Nacional. Estudiante de la maestría en Estadística Aplicada de la Universidad Santo Tomás. Docente Ocasional del Departamento de Geografía de la Facultad de Ciencias Humanas en la Universidad Nacional. Líneas de investigación principales: análisis y modelado espacial, estadística espacial, geoestadística y geovisualización.

Anexos

Anexo 1. Resultados del indicador ODS 11.3.1

Municipio	Tasa de crecimiento de la población	Tasa del consumo del suelo	Relación tasa consumo del suelo -tasa crecimiento de la población
Bogotá, D.C.	0,0056	0,0005	0,0946
Medellín	0,0037	0,0009	0,2481
Bello	0,0193	0,0052	0,2719
Caucasia	0,0105	0,0134	1,2786
Copacabana	0,0097	0,0030	0,3109
Envigado	0,0167	0,0018	0,1054
Itagüí	0,0088	0,0019	0,2210
La Estrella	0,0321	0,0055	0,1723
Rionegro	0,0133	0,0130	0,9763
Sabaneta	0,0425	0,0077	0,1802
Barranquilla	0,0037	0,0027	0,7215
Malambo	0,0165	0,0128	0,7710
Sabanalarga	0,0117	0,0063	0,5368
Soledad	0,0205	0,0057	0,2771
Cartagena de Indias	0,0058	0,0019	0,3270
Turbaco	0,0160	0,0119	0,7425
Tunja	0,0065	0,0111	1,6988
Duitama	0,0064	0,0082	1,2805
Sogamoso	0,0059	0,0029	0,4876
Manizales	0,0060	0,0045	0,7414
Florencia	0,0076	0,0022	0,2866
Popayán	0,0043	0,0045	1,0535
Valledupar	0,0170	0,0028	0,1645
Aguachica	0,0150	0,0093	0,6204
Montería	0,0073	0,0061	0,8375
Cajicá	0,0404	0,0048	0,1176
Chía	0,0244	0,0032	0,1325
Facatativá	0,0220	0,0085	0,3887
Funza	0,0214	0,0018	0,0855
Fusagasugá	0,0224	0,0114	0,5098
Girardot	0,0111	0,0070	0,6287
Madrid	0,0387	0,0270	0,6962
Mosquera	0,0231	0,0126	0,5436
Soacha	0,0217	0,0082	0,3780
Zipaquirá	0,0206	0,0161	0,7826
Neiva	0,0034	0,0062	1,8510
Riohacha	0,0230	0,0039	0,1676

Municipio	Tasa de crecimiento de la población	Tasa del consumo del suelo	Relación tasa consumo del suelo -tasa crecimiento de la población
Maicao	0,0217	0,0017	0,0794
Santa Marta	0,0100	0,0035	0,3456
Ciénaga	0,0090	0,0032	0,3491
Villavicencio	0,0056	0,0058	1,0185
Acacías	0,0102	0,0072	0,7062
Pasto	-0,0024	0,0020	-0,8409
San José de Cúcuta	0,0135	0,0033	0,2438
Los Patios	0,0176	0,0043	0,2468
Ocaña	0,0157	0,0098	0,6238
Villa del Rosario	0,0140	0,0059	0,4218
Pereira	0,0021	0,0068	3,2867
Dosquebradas	0,0084	0,0077	0,9171
Bucaramanga	0,0055	0,0012	0,2216
Barrancabermeja	0,0006	0,0031	5,4114
Floridablanca	0,0068	0,0030	0,4443
Girón	0,0107	0,0050	0,4658
Piedecuesta	0,0248	0,0078	0,3129
Sincelejo	0,0066	0,0019	0,2842
Ibagué	0,0035	0,0035	1,0093
Cali	0,0020	0,0017	0,8605
Buga	0,0000	0,0097	-236,6984
Cartago	0,0015	0,0040	2,6426
Palmira	0,0026	0,0046	1,7944
Tuluá	0,0029	0,0032	1,1054
Yumbo	0,0076	0,0026	0,3392
Yopal	0,0152	0,0067	0,4398
Nacional	0,0078	0,0034	0,4362