

Clasificación de cobertura vegetal con resolución espacial de 10 metros en bosques del Caribe colombiano basado en misiones Sentinel 1 y 2

Jesús A. Anaya¹^{*}, Susana Rodríguez-Buriticá², María C. Londoño²

¹ Facultad de ingeniería, Universidad de Medellín, Cra. 87 #30-65, Medellín, Colombia.

² Instituto de Investigaciones de Recursos Biológicos Alexander von Humboldt, Calle 28A # 15-09, Bogotá, Colombia.

Resumen: Se generó un mapa de cobertura terrestre del Caribe colombiano con datos de las misiones Sentinel-1 y Sentinel-2 para el año 2020. El objetivo principal fue evaluar el uso de imágenes Sentinel 1 y 2 para la generación de una clasificación de bosques del Caribe. Las imágenes fueron procesadas con *Google Earth Engine* (GEE) y luego clasificadas con *Random Forest*. Se calculó la exactitud global, la disminución media en exactitud y la disminución media en Gini para las bandas ópticas y radar. Esto permitió evaluar la importancia de las diferentes regiones del espectro electromagnético en la clasificación de la cobertura vegetal y la importancia relativa de cada banda. La exactitud del mapa de cobertura terrestre fue del 76% utilizando exclusivamente las bandas de Sentinel-2, con un ligero aumento cuando se incorporaron los datos de Sentinel-1. La región SWIR fue la más importante de ambos programas Sentinel para aumentar la exactitud. Destacamos la importancia de la banda 1 de aerosoles costeros (442,7 nm) en la clasificación a pesar de su baja resolución espacial. La exactitud global alcanzó el 83% al agregar los datos de elevación de la misión de topografía de radar del transbordador (SRTM) como variable auxiliar. Estos resultados indican un gran potencial para la generación de mapas de cobertura vegetal a nivel regional manteniendo un tamaño de píxel de 10 m. Este artículo destaca la importancia relativa de las diferentes bandas y su aporte a la clasificación en términos de exactitud.

Palabras clave: Sentinel, selección de bandas, *Google Earth Engine*, exactitud de la clasificación, bosque seco, Colombia.

Land cover classification with spatial resolution of 10 meters in forests of the Colombian Caribbean based on Sentinel 1 and 2 missions

Abstract: A Land cover map of the Colombian Caribbean were generated with data from the Sentinel-1 and Sentinel-2 missions for the year 2020. The main objective was to evaluate Sentinel 1 and 2 images to generate a classification for Caribbean forests. The images were processed using *Google Earth Engine* (GEE) and then classified using *Random Forest*. The Overall Accuracy, the Mean Decrease Accuracy and the Mean Decrease in Gini were calculated for the optical and radar bands, this allowed evaluating the importance of different regions of the electromagnetic spectrum in the classification of vegetation cover and the relative importance of the spectral bands. The accuracy of the land cover map was 76% using exclusively Sentinel-2 bands, with a slight increase when Sentinel-1 data was incorporated. The SWIR region was the most important of both Sentinel programs for

To cite this article: Anaya, J.A., Rodríguez-Buriticá, S., Londoño, M.C. 2023. Land cover classification with spatial resolution of 10 meters in forests of the Colombian Caribbean based on Sentinel 1 and 2 missions. *Revista de Teledetección*, 61, 29-41. <https://doi.org/10.4995/raet.2023.17655>

* Corresponding author: janaya@udemedellin.edu.co

increasing accuracy. We highlight the importance of coastal aerosol band 1 (442.7 nm) in the classification despite its low spatial resolution. The overall accuracy reached 83% when adding the Elevation data from the Shuttle Radar Topography Mission (SRTM) as auxiliary variable. These results indicate great potential for the generation of vegetation cover maps at the regional level while maintaining a pixel size of 10 m. This article highlights the relative importance of the different bands and its contribution to improve accuracy.

Key words: Sentinel, bands selection, Google Earth Engine, classification accuracy, dry forest, Colombia.

1. Introducción

La deforestación ha sido asociada a problemas de escala global como la pérdida de la biodiversidad y el cambio climático (Barlow et al., 2016). Siendo los bosques secos uno de los ecosistemas más amenazados a nivel mundial (Miles et al., 2006), con el agravante de ser también poco estudiados (Portillo-Quintero et al., 2015; Bastin et al., 2017). En América los bosques secos se encuentran principalmente en Brasil y se extienden desde México hasta Bolivia, pasando por Colombia y Ecuador (Pizano y García, 2014). La red de observación de biodiversidad (GEO BON) ha promovido el uso de información de la teledetección para estimar variables esenciales de biodiversidad. Determinar la ubicación y extensión de bosques secos tropicales es el primer paso para estimar algunas de estas variables y para proponer estrategias de restauración. A escala global existe un mapa de la extensión del bosque seco y de sus posibilidades de su restauración (Bastin et al., 2017) que incluye gran parte del norte de Colombia y Venezuela. Sin embargo, Fagan (2020) encontró errores en la discriminación del bosque seco, especialmente por la discontinuidad del dosel que es común en este tipo de bosques.

En Colombia el bosque seco se extiende por los valles de los ríos Cauca y Magdalena, la costa Caribe y los Llanos Orientales. Los trabajos más recientes sobre la extensión de este tipo de ecosistema incluyen el mapa del Instituto Humboldt de Investigaciones en recursos biológicos Alexander von Humboldt (IAvH y MADS, 2014) y el mapa de bosques del Instituto de Hidrología Meteorología y Estudios Ambientales (IDEAM, 2016). Definir qué es y qué no es un bosque no es un asunto menor, especialmente porque algunas aproximaciones no diferencian áreas naturales o regeneradas lo que limita su utilidad para establecer estrategias de

manejo que preserven la biodiversidad (Chazdon et al., 2016). Para grandes extensiones, un factor determinante en la adecuada identificación de bosques es la resolución espacial y espectral de los sensores satelitales.

La fusión de datos de nuevos sensores con mayor resolución espacial y espectral representan una gran oportunidad para mejorar la clasificación de coberturas (H. Zhang et al., 2018; Hong et al., 2021; Jin y Mountrakis, 2022). El aumento de bandas espectrales permite la interpretación diferentes aspectos de la vegetación (Lapini et al., 2020) como la fotosíntesis, la estructura de las hojas, la humedad y el estado del dosel, entre otros. Ante un mayor número de variables explicativas también se hace necesario determinar su importancia relativa en términos de eficiencia computacional (F. Zhang y Yang, 2020) especialmente en el ámbito de la inteligencia artificial AI (Himeur et al., 2022). Sin embargo, gran parte de la literatura disponible en teledetección se centra en los algoritmos de clasificación, las técnicas de muestreo o las series de tiempo, con poco énfasis en la importancia relativa e interpretación de las diferentes bandas/regiones del espectro electromagnético.

El programa Copernicus, de la agencia espacial europea (ESA), a través de las misiones Sentinel-1 y Sentinel-2, ofrece datos de reflectividad a 10 m, 20 m y a 60 m de resolución espacial en diferentes longitudes de onda, como también datos de retrodispersión en polarizaciones VV y VH. En este artículo se presenta la exactitud de la clasificación de coberturas vegetales que se genera al incluir diferentes regiones del espectro electromagnético haciendo énfasis en la resolución espacial de 10 m. El propósito de este artículo es evaluar la exactitud de la clasificación utilizando diversas regiones del espectro electromagnético, evaluar la importancia relativa de las bandas utilizadas

y discutir la exactitud de los resultados haciendo énfasis en los bosques secos.

2. Métodos

2.1. Área de estudio

El área de estudio se encuentra al norte de Colombia, en la región caribe; una región dominada por ecosistemas secos y semi-secos (Figura 1). Es una de las regiones de mayor transformación antrópica en Colombia (Correa Ayram et al., 2020) que incluye 12 municipios priorizados por el programa de Riqueza Natural USAID. El paisaje está compuesto por una matriz de pastos en un ambiente seco característico de estos bosques del Caribe,

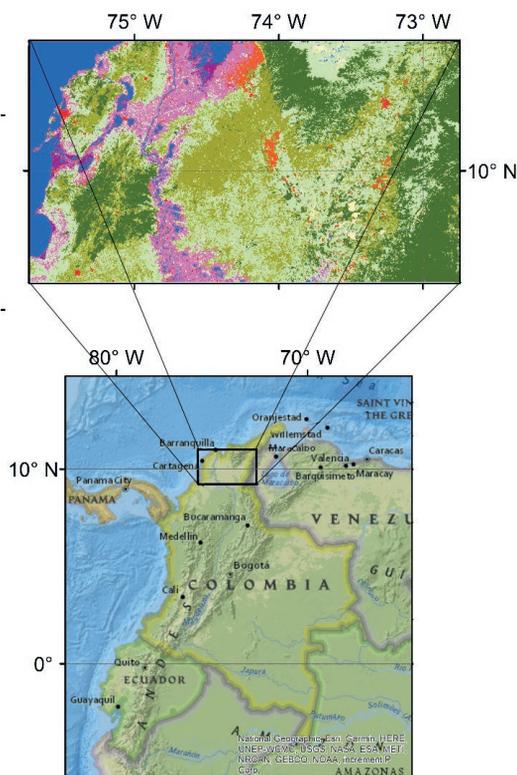


Figura 1. El área incluye parte de la cuenca del Río César y la parte baja del Río Magdalena hasta su desembocadura, se incluyen áreas de captación de la cordillera oriental, la Sierra Nevada de Santa Marta y los Montes de María. En tonos verdes se presenta la vegetación de tierra firme, desde pastos hasta bosques, en morado la vegetación sujeta a inundaciones, en naranja los cultivos arbóreos y en rojo el tejido urbano.

pero con gran presencia de humedales asociados a ciénagas. Los remanentes de bosques se encuentran en zonas montañosas de alta pendiente. Las coordenadas mínimas y máximas de la extensión geográfica son: 75,73W 9,24N y 72,78W 11,00N, con algo más de 67000 km², 6% del área continental del país y varía desde el nivel del mar hasta los 5700 m s.n.m. en la Sierra Nevada de Santa Marta. El preproceso se realizó en *Google Earth Engine* (GEE) cubriendo 12 cuadrantes de la zona UTM-18: PVT, VPS, PVR, PWR, PWS, PWT, PXR, PXS, PXT, PYR, PYS y PYT.

El régimen de precipitación tiene una época seca fuertemente marcada que inicia en diciembre y termina durante el mes de marzo, como se observa en la figura 2 de precipitación mensual basado en *Climate Hazard group Infrared Precipitation with Station data* (CHIRPS) para 2020 (Palomino-Ángel et al., 2019; Cavalcante et al., 2020).

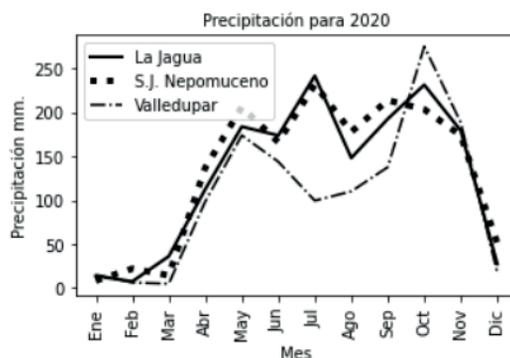


Figura 2. Precipitación mensual estimada por CHIRPS en tres sitios representativos de la zona de estudio. La jagua en el piedemonte de la cordillera de los Andes, S.J. Nepomuceno en los montes de María y Valledupar en la parte baja de la Sierra Nevada de Santa Marta.

2.2. Descripción de imágenes, adquisición y preprocesado

Para generar la cartografía de coberturas vegetales se integró información de las misiones Sentinel 1 y 2 para todo el año 2020, lo que incluye el pico de la época seca y la transición al primer pico de precipitación.

Tanto los sensores activos como pasivos trabajan en tándem A y B, desfasados 180°, juntos alcanzan una resolución temporal de 6 días. Los datos

ópticos multispectrales (Tabla 1) se identifican como S2 A y S2 B, nivel 2 de reflectividad en superficie *Multispectral Instrument MSIL2A* (Chastain et al., 2019). En Sentinel-2, de las 13 bandas 4 tienen resolución espacial de 10 m. Con el fin de mantener este tamaño de píxel, las bandas de 20 y 60 m se remuestrearon a 10 m. Se generaron mosaicos y compuestos temporales de Sentinel-2 para controlar la calidad de los píxeles en áreas geográficas con alta presencia de nubes y cirros (Anaya et al., 2015; Hansen et al., 2016), se procesaron 475 imágenes Sentinel 2. Es importante notar que los compuestos ópticos fueron obtenidos para todo 2020, sin embargo, enero, febrero y marzo corresponden a la época del año seca y con menor contenido de nubosidad, con lo cual hay una tendencia a seleccionar las observaciones durante estos meses (Figura 2). Después de filtrar los píxeles de baja calidad, principalmente por contenido de nubes, se hizo un cálculo de mediana de las observaciones seleccionadas (Anaya et al., 2020). Se crearon tres bases de datos con Sentinel 2 con el fin de determinar la exactitud global en cada una: la primera, solo con las bandas de resolución espacial de 10 m; la segunda, las bandas visibles y las bandas del NIR; y en la tercera se adicionaron las cuatro bandas del SWIR. La región visible es reconocida por su importancia en los procesos fotosintéticos de las plantas; la región del NIR por su capacidad de indicar el estado de la estructura de las hojas; y el SWIR por su relación con la humedad.

Los datos de microondas utilizados para complementar las observaciones ópticas se conocen como Sentinel-1 A y Sentinel-1 B, banda-C SAR GRD (*Synthetic Aperture Radar Ground Range*

Detected), en modo *Interferometric Wide swath* (IW) con polarizaciones VV y VH. Los datos obtenidos por SAR han sido utilizados con éxito en bosques tropicales (Chen et al., 2016) y en la clasificación de zonas agrícolas (Lapini et al., 2020). La base de datos fue obtenida en *Google Earth Engine* (GEE) con un tamaño de píxel de 10 m, en total se procesaron 368 imágenes Sentinel 1. La documentación de GEE indica que cada escena radar fue preprocesada con el software de Sentinel-1 *Toolbox* incluyendo los siguientes pasos: actualización de la órbita, eliminación de ruido y datos inválidos en los bordes de la imagen, eliminación de ruido termal, calibración radiométrica, orto-rectificación, y conversión a decibeles con escala logarítmica ($10 \times \log_{10}(x)$). Es de notar que los datos Sentinel-1 disponibles en GEE se encuentran ortorrectificados, pero no cuentan con normalización topográfica y por tanto fue necesario hacer una corrección radiométrica basada en ángulos (Vollrath et al., 2020).

Se seleccionaron datos Sentinel-1 en ambas direcciones siguiendo el método propuesto para la generación de datos listos para el análisis (Vollrath et al., 2020; Mullissa et al., 2021) y se aplicó un filtro de media focal de 3×3 con el fin de disminuir el efecto *speckle* (Lillesand y Kiefer, 2000). La retrodispersión observada con polarización VV y VH facilita la separación de coberturas del suelo (Achard y Hansen, 2013; Whelen y Siqueira, 2018; Arias et al., 2020). Los bosques y el tejido urbano continuo tienen alta retrodispersión mientras que los pastos y los cuerpos de agua tienen baja retrodispersión. La banda C es particularmente sensible a la presencia de hojas en el dosel en bosques deciduos (Soudani et al., 2021).

Tabla 1. Resolución espacial y espectral de reflectividad en superficie de Sentinel-2 con cuatro bandas con resolución espacial de 10 m.

Banda	Nombre	Bandas espectrales (nanómetros)	Resolución espacial
B1	Violeta	443	60m
B2	Azul	490	10m
B3	Verde	560	10m
B4	Rojo	665	10m
B5	Límite rojo 1	705	20m
B6	Límite rojo 2	740	20m
B7	Límite rojo 3	783	20m
B8	NIR	842	10m
B8A	NIR banda estrecha	865	20m
B9	Vapor de agua	940	60m
B11	SWIR 1	1610	20m
B12	SWIR 2	2190	20m

2.3. Clasificación y validación

Los clasificadores no paramétricos son utilizados de forma generalizada para obtener coberturas vegetales a partir de los valores de mediana obtenidos por el cálculo de mediana explicados en la sección 2.2, en este caso se utilizó el método de *Random Forest* (Breiman, 2001) en R para Windows. El modelo fue parametrizado siguiendo las recomendaciones de Vuolo et al. (2018), para correr 500 árboles usando una selección aleatoria de variables en cada uno igual a la raíz cuadrada del número total de predictores. Se calcularon dos parámetros asociados a la utilidad de las variables explicativas: el valor Disminución Media en Gini, *Mean Decrease Gini* en adelante (MDGini), fue utilizado para determinar la importancia que cada variable. Si la variable es importante MDGini tiende a separar nodos mixtos en nodos más puros, un valor alto indica una mayor importancia de la variable para minimizar la impureza en cada nodo. También se calculó el parámetro *Mean Decrease Accuracy* en adelante (MDAccuracy), el cual indica la disminución en la exactitud al eliminar determinada variable. Finalmente se calculó una matriz de correlación para evaluar la similitud entre las capas utilizadas.

Se interpretaron visualmente 3586 puntos con imágenes de alta resolución, los sitios de validación y entrenamiento fueron obtenidos a partir de un muestreo aleatorio estratificado (Olofsson et al., 2013, 2014) y ponderando según la proporción de cada cobertura (Tabla 2). La estratificación se realizó con la capa de coberturas vegetales obtenida con imágenes MODIS para Colombia (Anaya et al., 2015).

Tabla 2. Puntos de referencia y proporción de cada clase para realizar el muestreo aleatorio estratificado.

Clase	Puntos de Referencia	Clase (%)
1. Aguas continentales	390	13.1
2. Arbustal	390	14.3
3. Bosque denso alto	894	34.6
5. Cultivos permanentes arbóreos	261	1.7
6. Humedal	433	5.7
7. Tejido urbano continuo	217	1.1
8. Pastos limpios	737	27.6
9. Zona de extracción minera/Suelo	264	1.8

Para lograr la equivalencia con la leyenda utilizada en Colombia (IDEAM, 2010) fue necesario fusionar la clase sabana con la clase pastos, la clase páramo con la clase arbustal, la clase de bosque secundario con la clase bosque denso tierra firme y separar las clases herbazal inundable de la clase bosque denso inundable. Posteriormente, los puntos para cada clase fueron separados de forma aleatoria en dos grupos, 70% para entrenar el clasificador y 30% para validar el modelo de coberturas resultante (Tabla 3).

Tabla 3. Leyenda para la clasificación del mapa de coberturas de la tierra y número de puntos utilizados para entrenamiento y validación.

Clase	CLC	Entrenamiento	Validación
1. Aguas continentales	51	90	300
2. Arbustal	322	90	300
3. Bosque denso alto inundable	31122	50	167
4. Bosque denso alto tierra firme	31111	228	666
5. Cultivos permanentes arbóreos	223	61	200
6. Herbazal denso inundable	32112	50	167
7. Tejido urbano continuo	111	50	167
8. Pastos limpios	231	170	567
9. Zona de extracción minera/Suelo	131	64	200

Se generaron 5 modelos de coberturas vegetales basados en diferentes bandas del espectro electromagnético. El primer modelo de coberturas vegetales se obtuvo a partir de bandas de 10 m de visible y NIR (B2, B3, B4, B8); en el segundo modelo se adicionaron las bandas de 20 m B8A y límite del rojo (B5, B6, B7, B8A); en el tercer modelo se adicionan las dos bandas del infrarrojo de onda corta SWIR (B11, B12); en el cuarto modelo se adicionaron las dos polarizaciones VV y VH, y finalmente para el último modelo se adicionaron las capas de altura (SRTM) (NASA JPL, 2020) y pendiente, esto último con el fin de mejorar la clasificación por distribución altitudinal y restricción de uso del suelo por pendiente (Kellndorfer et al., 2004; Cartus et al., 2014; Anaya et al., 2015). Con las muestras de validación se calculó la exactitud global del mapa de coberturas vegetales, para ello se construyó la matriz de confusión. La figura 3

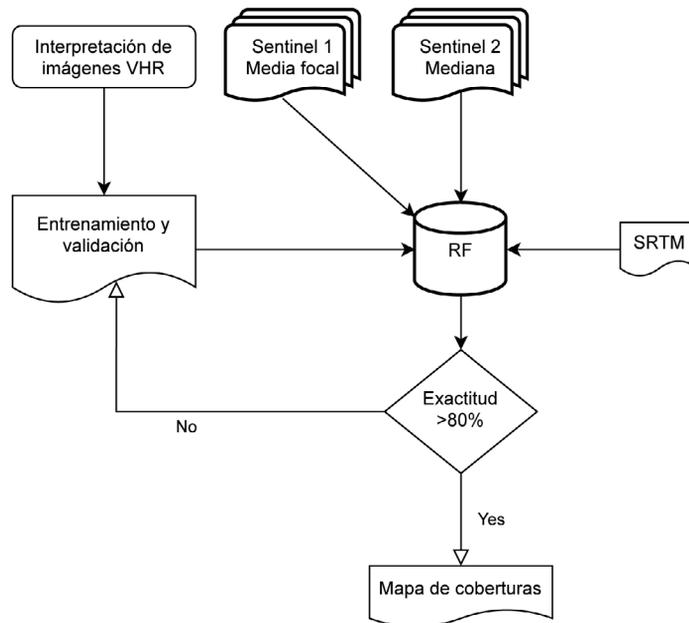


Figura 3. En este diagrama de flujo los símbolos indican cuando un proceso involucra múltiples capas o una sola capa. Con las imágenes de satélite se forma un cubo de datos y se realiza una clasificación supervisada utilizando *Random Forest* (RF). Se genera un circuito donde se calcula la exactitud global con la matriz de confusión (Congalton y Green, 2009) hasta superar la exactitud del 80%.

muestra los datos incluidos, el flujo de los procesos y los circuitos seguidos para evaluar la calidad.

La interpretación para el entrenamiento y la validación se realizó con trabajo de campo en la época seca y con el apoyo de imágenes de muy alta resolución espacial de *Google Earth* y del programa Sepal (<https://sepal.io>) disponibles de forma abierta, donde se pueden identificar la copa de cada árbol y la densidad de los arbustos. En el caso de los cultivos arbóreos se puede observar el patrón de siembra y la preparación de los potreros. Así mismo, se hizo un análisis de la existencia de bosques en zonas inundables con el fin de separarlos de la vegetación herbácea de zonas inundables. Una vez clasificado el mapa se utilizó un filtro de mayoría para disminuir el efecto sal y pimienta creando segmentos más homogéneos.

2.4. Catálogo de coberturas vegetales (Leyenda)

Con el fin de promover la estandarización de los métodos de clasificación de coberturas vegetales se utilizó la leyenda oficial para Colombia definida por el Instituto de Hidrología Meteorología

y Estudios Ambientales (IDEAM, 2010). Esta leyenda se basa en el estándar europeo *Corine Land Cover -CLC-* y fue adaptada para Colombia en el 2010. El catálogo está estructurado de forma jerárquica y permite la inclusión de nuevos niveles según el detalle requerido en la clasificación de coberturas (Tabla 3). El primer nivel consta de cinco unidades: territorios artificializados, territorios agrícolas, bosques y áreas seminaturales, áreas húmedas y superficies de agua. Las clases se definieron de forma tal que se pudieran separar los cultivos permanentes arbóreos, especialmente de palma que tienen gran predominio en la región Caribe, los bosques naturales, los humedales asociados a la zona costera y los cuerpos de agua continentales. Los arbustales son una clase de especial importancia en procesos de regeneración dado que se tratan de plantas ramificadas a poca altura y su tallo leñoso es muy inferior al de un árbol maduro. A diferencia de los bosques densos los arbustales pueden presentar un dosel discontinuo. La leyenda separa los bosques de tierra firme de tierra inundable, lo cual está altamente asociado a la disponibilidad de humedad de las clases de bosque. Este mismo criterio fue de utilidad para

separar las clases herbazal inundable y pastos, estas dos clases no tienen contenido de plantas leñosas.

3. Resultados

Se analizó la exactitud de la cobertura del suelo en un ecosistema de bosque seco tropical al utilizar distintas regiones del espectro electromagnético. Para ello se definieron cuatro regiones: Visible y NIR de 10 m; bandas Visibles y NIR de 10, 20 y 60 m; todas las bandas ópticas incluyendo SWIR; y finalmente ambas regiones: óptico y microondas. La exactitud global de la clasificación varió entre el 62 y el 83%. La clasificación con menor exactitud fue 62% y se obtuvo utilizando exclusivamente las bandas de resolución espacial de 10 m (B2, B3, B4, B8).

Los parámetros MDGini y MDAccuracy para el análisis relativo de las bandas tienen un comportamiento muy similar (R^2 95%). La importancia relativa de cada banda varía al incluir nuevas bandas. La banda de 10 m con mayor valor MDGini fue la banda del infrarrojo cercano (B8). La exactitud aumentó levemente hasta el 64% al incluir las bandas de menor resolución espacial en el visible y en el NIR (B1, B5, B6, B7 y B8A). En este caso los mayores valores MDGini fueron para las bandas B8A y B1. Al adicionar el resto de bandas ópticas la clasificación alcanzó una exactitud de 76%, mostrando la importancia del SWIR en mejorar la exactitud de la clasificación. En este caso las bandas con mayores valores de MDGini fueron B1 y B11. Al adicionar S1-VV y S1-VH la exactitud aumentó tan solo 1%, con lo cual se puede lograr una exactitud de 77% adicionando bandas radar. Sin embargo, es de notar que los valores MDGini se mantienen altos para las bandas del SWIR y B1 seguidas por ambas polarizaciones radar. Con las variables auxiliares SRTM el aumento fue de 8% alcanzando una exactitud de 83% (Tabla 4). Según el valor Disminución Media en Gini (MDGini), las bandas más importantes fueron en su orden: Elevación, SWIR1, SWIR2, B1, VV, VH, B9, B3, Pendiente, B8A, B2, B5, B7, B4, B8 y B6.

Existe una alta correlación entre las bandas visibles, entre ambas bandas radar y entre las bandas del SWIR. Se encontraron cuatro bandas con altísimos valores de correlación (>97%): límite del

rojo 2 (B6), límite del rojo 3 (B7), NIR (B8) y NIR de banda estrecha (B8A), además, el aumento en exactitud general incluyendo las tres bandas del límite del rojo fue marginal. Las correlaciones de las bandas de microondas con las bandas ópticas son bajas en general, excepto con las bandas B6, B7, B8, B8A y B9 donde la correlación es próxima al 70%.

La clase agua, identificada por el número 1 según la tabla 3, debido a su baja reflectividad en el SWIR (sin sedimentos) y a su baja retrodispersión suele tener bajos errores de clasificación con aciertos de 94% (Tabla 4) donde de 90 muestras de validación 82 fueron clasificadas correctamente. En general, se encuentra que al aumentar regiones del espectro electromagnético también aumentan los valores en la diagonal, la exactitud mínima fue de 66% y la máxima de 84%.

Se obtuvo un aumento de exactitud global del 9% (del 65% al 74%) al adicionar SWIR1 y SWIR2, impulsado especialmente por las clases bosque y bosque inundable. Si bien el aumento de exactitud al adicionar las bandas de radar es marginal, la clase herbazal denso inundable fue la más favorecida con su inclusión aumentando la exactitud del productor del 56% al 71%.

Clases con comportamiento espectral similar tienden a confundirse, por ejemplo, arbustal con bosques y arbustal con pastos. Solo aquellos potreros sin arbustos o con muy bajo contenido de arbustos fueron clasificados como pastos. También se presentan confusiones entre cultivos arbóreos y bosques, algunos corredores riparios fueron clasificados como plantaciones y algunas plantaciones fueron clasificadas parcialmente como bosques naturales. Otra característica que dificulta la clasificación es la similitud en la respuesta espectral de los suelos desnudos y el tejido urbano que tienden a ser muy similares en la región óptica del espectro electromagnético. Al adicionar la capa SRTM se obtuvo la mejor exactitud global, 83%. Esta variable obtuvo el valor mayor de MDGini y mayor valor MDAccuracy (Tabla 5), dado que explica, en parte, el uso del suelo propio de diferentes pisos altitudinales, por ejemplo, la mayor cantidad de plantaciones arbóreas del área de estudio se dan en zonas planas, con baja altura respecto al nivel del mar. La variable Elevación fue especialmente importante para mejorar la exactitud del productor de las clases bosque de tierra firme, cultivos,

Tabla 4. Presentación de la matriz de confusión normalizada y la exactitud para distintas variables explicativas de productos Sentinel. Se incluye exactitud del productor (PA), exactitud del usuario (UA) para las nueve clases.

	1	2	3	4	5	6	7	8	9	UA		
1	0.94	0.00	0.00	0.01	0.00	0.04	0.00	0.00	0.01	94%		
2	0.01	0.43	0.05	0.31	0.00	0.01	0.00	0.18	0.00	43%	Acuerdos:	523
3	0.01	0.03	0.42	0.49	0.03	0.01	0.00	0.00	0.00	42%	Exactitud:	0.62
4	0.00	0.02	0.03	0.90	0.03	0.01	0.00	0.02	0.00	90%	Capas:	B2, B3, B4, B8
5	0.00	0.04	0.00	0.29	0.57	0.02	0.02	0.05	0.00	57%		
6	0.06	0.05	0.01	0.12	0.03	0.29	0.05	0.38	0.01	29%		
7	0.00	0.02	0.00	0.00	0.02	0.07	0.61	0.08	0.20	61%		
8	0.00	0.11	0.00	0.00	0.00	0.11	0.02	0.69	0.06	69%		
9	0.07	0.00	0.00	0.00	0.00	0.00	0.07	0.09	0.76	76%		
PA	87%	67%	78%	46%	85%	46%	73%	56%	66%			

1	0.96	0.00	0.00	0.00	0.00	0.02	0.00	0.00	0.01	96%		
2	0.00	0.41	0.07	0.32	0.00	0.01	0.00	0.19	0.00	41%	Acuerdos:	541
3	0.01	0.04	0.43	0.48	0.01	0.01	0.00	0.00	0.00	43%	Exactitud:	0.64
4	0.00	0.04	0.05	0.88	0.01	0.00	0.00	0.01	0.00	88%	Capas:	B1, B2, B3, B4
5	0.00	0.03	0.00	0.28	0.61	0.02	0.00	0.05	0.00	61%		B5, B6, B7
6	0.05	0.07	0.02	0.08	0.01	0.38	0.02	0.35	0.01	38%		B8, B8A
7	0.00	0.02	0.00	0.00	0.00	0.02	0.66	0.12	0.18	66%		
8	0.00	0.11	0.00	0.00	0.00	0.07	0.02	0.69	0.10	69%		
9	0.13	0.00	0.00	0.00	0.00	0.00	0.02	0.08	0.77	77%		
PA	88%	63%	61%	52%	93%	67%	88%	54%	58%			

1	0.99	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	99%		
2	0.00	0.53	0.00	0.30	0.00	0.00	0.00	0.17	0.00	53%	Acuerdos:	637
3	0.04	0.00	0.92	0.02	0.00	0.02	0.00	0.00	0.00	92%	Exactitud:	0.76
4	0.00	0.03	0.01	0.93	0.01	0.01	0.00	0.01	0.00	93%	Capas:	B1, B2, B3, B4
5	0.00	0.02	0.00	0.22	0.71	0.01	0.00	0.04	0.00	71%		B5, B6, B7
6	0.04	0.04	0.01	0.10	0.00	0.47	0.03	0.30	0.00	47%		B8, B8A
7	0.00	0.02	0.00	0.00	0.00	0.03	0.69	0.11	0.16	69%		B9, B11, B12
8	0.00	0.12	0.00	0.00	0.00	0.06	0.01	0.71	0.10	71%		
9	0.09	0.00	0.00	0.00	0.00	0.00	0.02	0.06	0.83	83%		
PA	90%	66%	94%	74%	97%	69%	90%	66%	61%			

1	0.96	0.00	0.01	0.00	0.00	0.02	0.00	0.00	0.00	96%		
2	0.00	0.55	0.00	0.26	0.00	0.00	0.00	0.19	0.00	55%	Acuerdos:	645
3	0.06	0.00	0.94	0.00	0.00	0.00	0.00	0.00	0.00	94%	Exactitud:	0.77
4	0.00	0.04	0.01	0.92	0.01	0.01	0.00	0.02	0.00	92%	Capas:	B1, B2, B3, B4
5	0.00	0.01	0.00	0.15	0.79	0.01	0.00	0.04	0.00	79%		B5, B6, B7
6	0.04	0.07	0.01	0.09	0.00	0.46	0.01	0.30	0.01	46%		B8, B8A
7	0.00	0.02	0.00	0.00	0.00	0.00	0.76	0.06	0.16	76%		B9, B11, B12
8	0.00	0.07	0.00	0.01	0.00	0.07	0.01	0.71	0.14	71%		VV, VH
9	0.10	0.00	0.00	0.00	0.00	0.03	0.00	0.08	0.80	80%		
PA	89%	73%	94%	78%	97%	67%	96%	65%	50%			

1	0.98	0.00	0.01	0.00	0.00	0.01	0.00	0.00	0.00	98%		
2	0.01	0.60	0.00	0.30	0.00	0.00	0.01	0.08	0.00	60%	Acuerdos:	701
3	0.00	0.00	0.98	0.00	0.00	0.02	0.00	0.00	0.00	98%	Exactitud:	0.83
4	0.01	0.03	0.00	0.95	0.00	0.00	0.00	0.02	0.00	95%	Capas:	B1, B2, B3, B4
5	0.00	0.03	0.00	0.03	0.91	0.00	0.03	0.00	0.00	91%		B5, B6, B7
6	0.04	0.03	0.03	0.04	0.00	0.63	0.01	0.21	0.00	63%		B8, B8A
7	0.00	0.03	0.00	0.00	0.00	0.02	0.76	0.03	0.16	76%		B9, B11, B12
8	0.00	0.06	0.00	0.01	0.00	0.01	0.00	0.82	0.11	82%		VV, VH
9	0.05	0.00	0.00	0.00	0.00	0.00	0.00	0.09	0.86	86%		SRTM, PENDIENTE
PA	92%	76%	94%	82%	100%	90%	92%	80%	58%			

Tabla 5. Contribución relativa de cada banda para mejorar la clasificación. Disminución media en Gini y disminución media en exactitud.

CAPA		MD Gini	MD Accuracy
1	B1	1147	0.212
2	B2	242	0.058
3	B3	356	0.092
4	B4	164	0.039
5	B5	225	0.041
6	B6	130	0.027
7	B7	267	0.050
8	B8	154	0.045
9	B8A	331	0.065
10	B9	578	0.106
11	B11	1327	0.192
12	B12	1286	0.190
13	VV	780	0.106
14	VH	689	0.092
15	Elevación	1778	0.290
16	Pendiente	366	0.042

pastos limpios; por el contrario, la exactitud del productor disminuyó para la clase de extracción minera o suelo.

La distribución de cultivos arbóreos coincide con los cultivos de palma identificados recientemente (Descals et al., 2021). Estos cultivos se encuentran principalmente en los municipios de María La Baja, al oriente de la Ciénaga Grande de Santa Marta, en los municipios de Copey y Algarrobo, y en las estribaciones de la cordillera oriental, al

sur del municipio de Agustín Codazzi, también se encuentra cultivos arbóreos entre Zambrano y San Juan Nepomuceno en las orillas del Río Magdalena. En los suelos desnudos destaca la actividad minera de carbón y las zonas de alta montaña donde no hay condiciones para el crecimiento de la vegetación sobre los 4000 m s.n.m. Algunos suelos desnudos que probablemente han sido sometidos a sobrepastoreo o actividades mineras se encuentran en las partes bajas de la Sierra Nevada de Santa Marta.

En zonas costeras se observa vegetación con gran tolerancia a la humedad, tanto a lo largo de ríos y ciénagas como a lo largo de la costa. Esta vegetación fue dividida en arbórea y herbazales y predomina a lo largo del canal del dique y en el complejo de la Ciénaga Grande de Santa Marta (Figura 4). Por su parte, los cultivos permanentes arbóreos con 1618 km² (161 800 ha) que equivalen al 2% del área de estudio (Tabla 6), se encuentran principalmente en zona plana y frecuentemente asociados a vegetación de humedal.

Hacia el departamento de la Guajira existen fragmentos importantes en la parte baja que corresponden a arbustos o a bosques en distintos niveles de degradación, pero representativos de bosque seco. Estos fragmentos marcan el inicio de los bosques que se extienden hacia el norte en condiciones de muy baja precipitación propias del clima desértico de la Guajira.

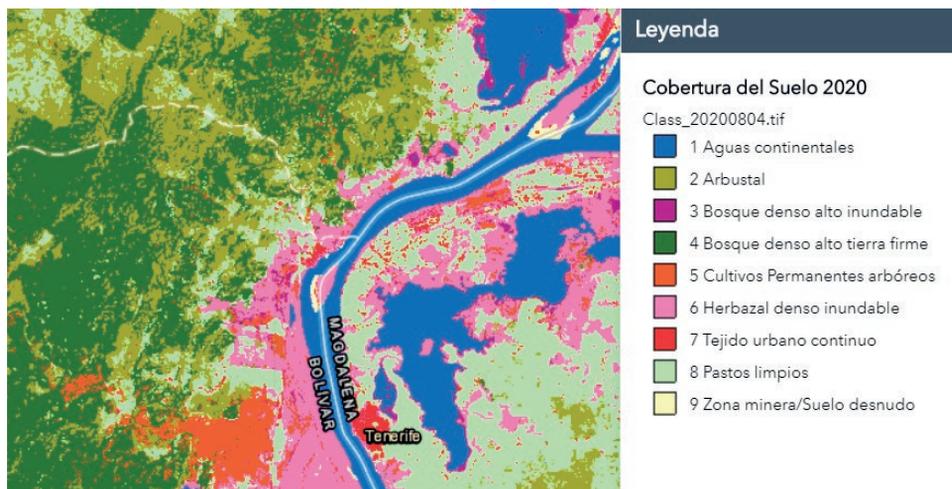


Figura 4. Detalle del mapa de coberturas en el sector de Zambrano, Guamo y Tenerife, al margen del Río Magdalena, con un mosaico de cultivos, bosques de tierra firme, arbustal, pastos y herbazal inundable.

Tabla 6. La clase predominante es pastos (30%) seguida de arbustal (26%) y bosques de tierra firme (22%). La mayor parte de bosques está ubicada en la Sierra Nevada de Santa Marta y en la parte alta de la cordillera oriental.

Clase	Área (km ²)	(%)
Aguas continentales	6.852	10
Arbustal	17.583	26
Bosque denso alto inundable	1.045	2
Bosque denso alto tierra firme	14.980	22
Cultivos permanentes arbóreos	1.618	2
Herbazal denso inundable	2.756	4
Tejido urbano continuo	978	1
Pastos limpios	20.301	30
Zona de extracción minera/suelo	973	1
Total	67.085	

4. Discusión

Sentinel-2, tiene resolución espacial de 10 m en cuatro bandas espectrales y espectrales, mientras sensores similares como los del programa Landsat solo tienen bandas multispectrales de 30 m. Este mayor nivel de detalle espacial mejora la interpretación visual de la densidad de árboles y arbustales en zonas de potreros, mejora la interpretación visual de pérdida de bosque y la diferenciación entre bosques plantados y bosques naturales. Landsat sigue siendo una misión de gran importancia por su archivo histórico, pero los resultados de este estudio muestran las ventajas de las misiones Sentinel.

La región del SWIR tiene una resolución espacial de menor detalle, pero también es de gran interés en la identificación de coberturas dado que es fuertemente influenciado por la humedad lo cual es relevante en ambientes secos (Andrade et al., 2021). Por otro lado, la región de microondas es de gran utilidad en zonas de alta nubosidad, pues las longitudes de onda de los sensores activos radar pueden atravesar las nubes. Utilizamos datos de Sentinel-1 dado que se presenta alta nubosidad en los trópicos andinos (Anaya et al., 2015). En la ladera occidental de la cordillera de los Andes y en la Sierra Nevada de Santa Marta, encontramos diferentes proporciones de nubosidad en Sentinel-2 con un valor medio de 34%. En este tipo de ecosistemas secos, con pérdida de hojas en época de bajas precipitaciones, vale la pena considerar conceptos de fenología (Vélez y Álvarez-Mozos, 2020). En la Comunitat Valenciana se ha encontrado que el uso de las series de tiempo de datos Sentinel-2 es

útil para describir los procesos fenológicos y por ende caracterizar las clases de cobertura a partir de su dinámica interanual (Campos-Taberner et al., 2020). También se han utilizado series de tiempo de Sentinel-1 para generar clasificaciones de coberturas vegetales en Francia, aunque en este caso las series de tiempo no son relacionadas directamente con procesos fenológicos (Ndikumana et al., 2018). En este estudio no se ha considerado el potencial que tiene la resolución temporal que tiene Sentinel para generar series de tiempo y determinar la dinámica de las coberturas vegetales, pero la inclusión de variables temporales es sin duda una línea de interés en próximos estudios. De la misma manera, la tendencia a seleccionar píxeles libres de nubes en Sentinel 2 limita la detección de diferencias que se puedan presentar entre las diferentes clases de coberturas en la época de lluvias. Una solución en trabajos futuros sería la caracterización fenológica exclusivamente con series de tiempo generadas con imágenes Sentinel 1.

La pérdida de hojas durante la época seca y el dosel discontinuo de algunos bosques secos (árboles dispersos con baja densidad) genera dificultades en la separación de la clase bosque y la clase arbustal. A pesar de que se utilizaron todas las imágenes disponibles para 2020, el filtro de calidad de Sentinel 2 está diseñado para seleccionar observaciones sin nubes, predominantemente de los meses secos de enero, febrero y marzo. Esto implica que la observación de la mediana probablemente corresponde a la época seca, es decir, cuando el bosque seco caducifolio ha perdido sus hojas. Esto puede conllevar a una interpretación del bosque seco como un arbustal y por tanto una proporción de los arbustales son en realidad bosque seco, tal como lo advierte Fagan en (2020). Así mismo, encontramos dificultades en separar las clases arbustales y pastizales probablemente debido a la selección de píxeles de la época más seca del año. Sugerimos evaluar el mismo método incluyendo datos de la época de lluvias, donde el índice de área foliar será más alto y eventualmente mejorará la discriminación entre pastos y arbustales, y arbustales y bosques, tal como se realizó en una zona dominada por cultivos en Australia con Sentinel-2 (Vuolo et al., 2018). En la época de lluvias, después de marzo el dosel debe tender a cerrarse dado que los árboles recuperan su cobertura foliar. Otros ensayos en este sentido se

pueden realizar con Sentinel-1, dado que la longitud de onda de radar es sensible a cambios en la parte superior del dosel y al no ser afectado por nubes podría generarse una serie de tiempo que permita de mejor manera identificar los bosques de otras coberturas similares.

5. Conclusiones

Una de las mayores dificultades en la generación de mapas de coberturas vegetales es la nubosidad y la complejidad de los mosaicos que se presentan en áreas fuertemente fragmentadas, especialmente la confusión que se genera entre bosques naturales y cultivos permanentes arbóreos, lo cual disminuye la exactitud temática. En este estudio se muestra la importancia relativa de las bandas de Sentinel para generar la clasificación. En el mapa generado se discriminan bosques naturales y los cultivos permanentes arbóreos con el fin de tener un estimado actualizado de la extensión y distribución de los remanentes de bosques naturales, especialmente de ambientes secos. La exactitud de la clasificación solo con Sentinel 2 de 10 m fue de 62% y llegó hasta 83% cuando se incluyó SWIR, radar y variables auxiliares. La variable auxiliar SRTM fue la de mayor importancia según la métrica Disminución Media en Gini, esto puede estar asociado a las diferentes condiciones bioclimáticas que se presentan desde el nivel del mar y los 5730 m s.n.m. de la Sierra Nevada de Santa Marta. El beneficio de incluir SWIR fue de particular importancia pues se aumentó la exactitud global del 66% al 74% y tanto SWIR1 como SWIR2, adicionalmente presentaron altos valores de importancia en la disminución media en Gini. Se espera que en zonas de alta nubosidad los datos radar cobren mayor importancia, pero en zonas de alta pendiente se debe prestar especial atención al efecto de la topografía sobre la dirección que toma la retrodispersión. Esto puede limitar el uso efectivo de datos Sentinel-1 disponibles en GEE en zonas de alta pendiente. La información generada en este trabajo servirá para optimizar los procesos de clasificación supervisada y sus resultados para priorizar los remanentes de bosque en el contexto de los distintos proyectos de conservación y monitoreo ubicados en la zona (parcelas, PNN, reservas, planes de ordenamiento territorial).

Agradecimientos

Esta publicación ha sido producida con el apoyo total o parcial de NAS y del pueblo de los Estados Unidos de América a través de la Agencia de Estados Unidos para el Desarrollo Internacional (USAID), número de subvención USAID AID-OAA-A-11-00012. El contenido de esta publicación es la responsabilidad total del Instituto de Investigación de recursos biológicos Alexander von Humboldt y de la corporación Universidad de Medellín, no necesariamente reflejan las opiniones de NAS, USAID o del gobierno de los Estados Unidos.

Referencias

- Achard, F., y Hansen, M.C. 2013. *Global forest monitoring from earth observation* (E. Chuvieco, Ed.; p. 316). CRC Press, Taylor y Francis Group.
- Anaya, J.A., Colditz, R.R., y Valencia, G.M. 2015. Land cover mapping of a tropical region by integrating multi-year data into an annual time series. *Remote Sensing*, 7(12). <https://doi.org/10.3390/rs71215833>
- Anaya, J.A., Gutiérrez-Vélez, V.H., Pacheco-Pascagaza, A.M., Palomino-Ángel, S., Han, N., y Balzter, H. 2020. Drivers of Forest Loss in a Megadiverse Hotspot on the Pacific Coast of Colombia. *Remote Sensing*, 12(8), 1235. <https://doi.org/10.3390/rs12081235>
- Andrade, J., Cunha, J., Silva, J., Rufino, I., y Galvão, C. 2021. Evaluating single and multi-date Landsat classifications of land-cover in a seasonally dry tropical forest. *Remote Sensing Applications: Society and Environment*, 22, 100515. <https://doi.org/10.1016/j.rsase.2021.100515>
- Arias, M., Campo-Bescós, M.Á., y Álvarez-Mozos, J. 2020. Crop Classification Based on Temporal Signatures of Sentinel-1 Observations over Navarre Province, Spain. In *Remote Sensing*, 12(2), 278. <https://doi.org/10.3390/rs12020278>
- Barlow, J., Lennox, G.D., Ferreira, J., Berenguer, E., Lees, A.C., Nally, R. mac, Thomson, J.R., Ferraz, S.F. de B., Louzada, J., Oliveira, V.H.F., Parry, L., Ribeiro de Castro Solar, R., Vieira, I.C.G., Aragão, L.E.O.C., Begotti, R.A., Braga, R.F., Cardoso, T.M., Jr, R.C. de O., Souza Jr, C.M., ... Gardner, T.A. 2016. Anthropogenic disturbance in tropical forests can double biodiversity loss from deforestation. *Nature*, 535(7610), 144–147. <https://doi.org/10.1038/nature18326>

- Bastin, J.-F., Berrahmouni, N., Grainger, A., Maniatis, D., Mollicone, D., Moore, R., Patriarca, C., Picard, N., Sparrow, B., Abraham, E.M., Aloui, K., Atesoglu, A., Attore, F., Bassüllü, Ç., Bey, A., Garzuglia, M., García-Montero, L.G., Groot, N., Guerin, G., ... Castro, R. 2017. The extent of forest in dryland biomes. *Science*, 356(6338), 635 LP – 638. <https://doi.org/10.1126/science.aam6527>
- Breiman, L. 2001. Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Campos-Taberner, M., García-Haro, F.J., Martínez, B., y Gilbert, M.A. 2020. Deep learning for agricultural land use classification from sentinel-2. *Revista de Teledetección*, 2020(56 Special issue), 35–48. <https://doi.org/10.4995/raet.2020.13337>
- Cartus, O., Kelldorfer, J., Walker, W., Franco, C., Bishop, J., Santos, L., y Fuentes, J.M.M. 2014. A national, detailed map of forest aboveground carbon stocks in Mexico. *Remote Sensing*, 6, 5559–5588. <https://doi.org/10.3390/rs6065559>
- Cavalcante, R.B.L., Ferreira, D.B. da S., Pontes, P.R.M., Tedeschi, R.G., da Costa, C.P.W., y de Souza, E.B. 2020. Evaluation of extreme rainfall indices from CHIRPS precipitation estimates over the Brazilian Amazonia. *Atmospheric Research*, 238, 104879. <https://doi.org/10.1016/j.atmosres.2020.104879>
- Chastain, R., Housman, I., Goldstein, J., Finco, M., y Tenneson, K. 2019. Empirical cross sensor comparison of Sentinel-2A and 2B MSI, Landsat-8 OLI, and Landsat-7 ETM+ top of atmosphere spectral characteristics over the conterminous United States. *Remote Sensing of Environment*, 221, 274–285. <https://doi.org/10.1016/j.rse.2018.11.012>
- Chazdon, R.L., Brancalion, P.H.S., Laestadius, L., Bennett-Curry, A., Buckingham, K., Kumar, C., Moll-Rocek, J., Vieira, I.C.G., y Wilson, S.J. 2016. When is a forest a forest? Forest concepts and definitions in the era of forest and landscape restoration. *Ambio*, 45(5), 538–550. <https://doi.org/10.1007/s13280-016-0772-y>
- Chen, B., Li, X., Xiao, X., Zhao, B., Dong, J., Kou, W., Qin, Y., Yang, C., Wu, Z., Sun, R., Lan, G., y Xie, G. 2016. Mapping tropical forests and deciduous rubber plantations in Hainan Island, China by integrating PALSAR 25-m and multi-temporal Landsat images. *International Journal of Applied Earth Observation and Geoinformation*, 50, 117–130. <https://doi.org/10.1016/j.jag.2016.03.011>
- Congalton, R.G., y Green, Kass. 2009. *Assessing the accuracy of remotely sensed data* (2nd ed.). CRC Press.
- Correa-Ayram, C.A., Etter, A., Díaz-Timoté, J., Rodríguez-Buriticá, S., Ramírez, W., y Corzo, G. 2020. Spatiotemporal evaluation of the human footprint in Colombia: Four decades of anthropic impact in highly biodiverse ecosystems. *Ecological Indicators*, 117, 106630. <https://doi.org/10.1016/j.ecolind.2020.106630>
- Descals, A., Wich, S., Meijaard, E., Gaveau, D.L.A., Peedell, S., y Szantoi, Z. 2021. High-resolution global map of smallholder and industrial closed-canopy oil palm plantations. *Earth Syst. Sci. Data*, 13(3), 1211–1231. <https://doi.org/10.5194/essd-13-1211-2021>
- Fagan, M.E. 2020. A lesson unlearned? Underestimating tree cover in drylands biases global restoration maps. *Global Change Biology*, 26(9), 4679–4690. <https://doi.org/10.1111/gcb.15187>
- Hansen, M.C., Krylov, A., Tyukavina, A., Potapov, P. v, Turubanova, S., Zutta, B., Ifo, S., Margono, B., Stolle, F., y Moore, R. 2016. Humid tropical forest disturbance alerts using Landsat data. *Environmental Research Letters*, 11(3), 34008. <https://doi.org/10.1088/1748-9326/11/3/034008>
- Himeur, Y., Rimal, B., Tiwary, A., y Amira, A. 2022. Using artificial intelligence and data fusion for environmental monitoring: A review and future perspectives. *Information Fusion*, 86–87, 44–75. <https://doi.org/10.1016/j.inffus.2022.06.003>
- Hong, D., Hu, J., Yao, J., Chanussot, J., y Zhu, X.X. 2021. Multimodal remote sensing benchmark datasets for land cover classification with a shared and specific feature learning model. *ISPRS Journal of Photogrammetry and Remote Sensing*, 178, 68–80. <https://doi.org/10.1016/j.isprsjprs.2021.05.011>
- IAvH, y MADS. 2014. *Mapa de coberturas de bosque seco tropical en Colombia (escala 1:100.000, 2.0v). 1 hoja cartográfica*. <http://www.humboldt.org.co/images/documentos/pdf/investigacion/ariza-et-al-2014-memoria-tecnica-validacion.pdf>
- IDEAM. 2010. *Leyenda Nacional de Coberturas de la Tierra. Metodología CORINE Land Cover adaptada para Colombia Escala 1:100.000*. (M. y E. Ambientales. Instituto de Hidrología, Ed.; p. 72).
- IDEAM. 2016. *Mapa de Bosque No Bosque Colombia Área Continental* (p. Landsat). <http://www.siac.gov.co/catalogo-de-mapas>
- Jin, H., y Mountrakis, G. 2022. Fusion of optical, radar and waveform LiDAR observations for land cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 187, 171–190. <https://doi.org/10.1016/j.isprsjprs.2022.03.010>

- Kellndorfer, J., Walker, W., Pierce, L., Dobson, C., Fites, J.A., Hunsaker, C., Vona, J., y Clutter, M. 2004. Vegetation height estimation from Shuttle Radar Topography Mission and National Elevation Datasets. *Remote Sensing of Environment*, 93, 339–358. <https://doi.org/10.1016/j.rse.2004.07.017>
- Lapini, A., Fontanelli, G., Pettinato, S., Santi, E., Paloscia, S., Tapete, D., y Cigna, F. 2020. Application of deep learning to optical and SAR images for the classification of agricultural areas in Italy. *IEEE Geoscience and Remote Sensing Letters*, 4163–4166.
- Lillesand, T.M., y Kiefer, R.W. 2000. *Remote sensing and image interpretation* (J.W. and Sons, Ed.; Fourth). Wiley.
- Miles, L., Newton, A.C., DeFries, R.S., Ravilious, C., May, I., Blyth, S., Kapos, V., y Gordon, J.E. 2006. A global overview of the conservation status of tropical dry forests. *Journal of Biogeography*, 33(3), 491–505. <https://doi.org/10.1111/j.1365-2699.2005.01424.x>
- Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., y Reiche, J. 2021. Sentinel-1 SAR Backscatter Analysis Ready Data Preparation in Google Earth Engine. *Remote Sensing*, 13(10). <https://doi.org/10.3390/rs13101954>
- NASA JPL. 2020. *NASADEM Merged DEM Global 1 arc second*. https://lpdaac.usgs.gov/products/nasadem_hgtv001/
- Ndikumana, E., Ho Tong Minh, D., Baghdadi, N., Courault, D., y Hossard, L. 2018. Deep Recurrent Neural Network for Agricultural Classification using multitemporal SAR Sentinel-1 for Camargue, France. In *Remote Sensing*, 10(8), 1217. <https://doi.org/10.3390/rs10081217>
- Olofsson, P., Foody, G.M., Stehman, S.V., y Woodcock, C.E. 2013. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment*, 129(0), 122–131. <https://doi.org/10.1016/j.rse.2012.10.031>
- Olofsson, P., Foody, G.M., Herold, M., Stehman, S. v, Woodcock, C.E., y Wulder, M.A. 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>
- Palomino-Ángel, S., Anaya-Acevedo, J.A., y Botero, B.A. 2019. Evaluation of 3B42V7 and IMERG daily-precipitation products for a very high-precipitation region in northwestern South America. *Atmospheric Research*, 217, 37–48. <https://doi.org/10.1016/j.atmosres.2018.10.012>
- Pizano, C., y García, H. 2014. *El bosque seco tropical en Colombia*. Instituto de investigación de recursos biológicos Alexander von Humboldt.
- Portillo-Quintero, C., Sanchez-Azofeifa, A., Calvo-Alvarado, J., Quesada, M., y do Espirito Santo, M.M. 2015. The role of tropical dry forests for biodiversity, carbon and water conservation in the neotropics: lessons learned and opportunities for its sustainable management. *Regional Environmental Change*, 15(6), 1039–1049. <https://doi.org/10.1007/s10113-014-0689-6>
- Soudani, K., Delpierre, N., Berveiller, D., Hmimina, G., Vincent, G., Morfin, A., y Dufrêne, É. 2021. Potential of C-band Synthetic Aperture Radar Sentinel-1 time-series for the monitoring of phenological cycles in a deciduous forest. *International Journal of Applied Earth Observation and Geoinformation*, 104, 102505. <https://doi.org/10.1016/j.jag.2021.102505>
- Vélez, D.A., y Álvarez-Mozos, J. 2020. Land use and land cover classification and change analysis in the area surrounding the manglares churute ecological reserve (Ecuador) using sentinel-1 time series. *Revista de Teledetección*, 2020(56), 131–146. <https://doi.org/10.4995/raet.2020.14099>
- Vollrath, A., Mullissa, A., y Reiche, J. 2020. Angular-Based Radiometric Slope Correction for Sentinel-1 on Google Earth Engine. *Remote Sensing*, 12(11). <https://doi.org/10.3390/rs12111867>
- Vuolo, F., Neuwirth, M., Immitzer, M., Atzberger, C., y Ng, W.-T. 2018. How much does multi-temporal Sentinel-2 data improve crop type classification? *International Journal of Applied Earth Observation and Geoinformation*, 72, 122–130. <https://doi.org/10.1016/j.jag.2018.06.007>
- Whelen, T., y Siqueira, P. 2018. Time-series classification of Sentinel-1 agricultural data over North Dakota. *Remote Sensing Letters*, 9(5), 411–420. <https://doi.org/10.1080/2150704X.2018.1430393>
- Zhang, F., y Yang, X. 2020. Improving land cover classification in an urbanized coastal area by random forests: The role of variable selection. *Remote Sensing of Environment*, 251, 112105. <https://doi.org/10.1016/j.rse.2020.112105>
- Zhang, H., Li, J., Wang, T., Lin, H., Zheng, Z., Li, Y., y Lu, Y. 2018. A manifold learning approach to urban land cover classification with optical and radar data. *Landscape and Urban Planning*, 172, 11–24. <https://doi.org/10.1016/j.landurbplan.2017.12.009>