



UNIVERSIDAD DISTRITAL
FRANCISCO JOSÉ DE CALDAS



Estimación de biomasa aérea de *Eucalyptus grandis* y *Pinus* spp. usando imágenes Sentinel1A y Sentinel2A en Colombia

Estimating aboveground biomass of *Eucalyptus grandis* and *Pinus* spp. using Sentinel-1A and Sentinel-2A images in Colombia

Adriana Lizeth Tovar Blanco¹ , Iván Alberto Lizarazo Salcedo²  y Nelly Rodríguez Eraso³ 

Tovar-Blanco, A.L. Lizarazo-Salcedo, I.A. y Rodríguez-Eraso, N. (2020). Estimación de biomasa aérea de *Eucalyptus grandis* y *Pinus* spp. usando imágenes Sentinel1A y Sentinel2A en Colombia. *Colombia forestal*, 23(1), 79-93.

Recepción: 30 de abril 2019

Aprobación: 16 de diciembre 2019

Resumen

La estimación de la biomasa aérea usando sistemas de aprendizaje automático es útil para conocer de forma rápida y sistemática la productividad en bosques y plantaciones. En este estudio la biomasa aérea (AGB) se estimó para las plantaciones forestales de *Eucalyptus grandis* y *Pinus* spp. ubicadas en el sector centro-oriental del departamento del Cauca (Colombia), combinando datos de radar de apertura sintética (SAR) de Sentinel-1A, datos ópticos de Sentinel-2A y datos de inventarios forestales y el uso del algoritmo Random Forest. Las variables de mayor incidencia en AGB para *E. grandis* fueron las bandas SWIR y las texturas de la polarización VV; mientras que para *P. spp* fueron Correlación_{vv}, GNDVI y B2. Los modelos obtenidos combinando datos ópticos y SAR muestran mejores resultados con un coeficiente de determinación $R^2 = 0.27$ y un error cuadrado promedio EMC = 42.75 t.ha⁻¹ en *E. grandis*, y $R^2 = 0.36$ y EMC = 141.71 t.ha⁻¹ en *Pinus* spp. El estudio demostró el potencial de combinar datos Sentinel para estimar la AGB en plantaciones comerciales y el uso de *Random forest* para la construcción de los modelos, pero aún se requiere el estudio

del acoplamiento espacial de los datos de campo y su incidencia en las estimaciones de los modelos, así como la pertinencia de adelantar estudios a nivel de especies para evaluar su incertidumbre.

Palabras clave: GLCM, índice de vegetación, percepción remota, plantación forestal comercial, Random Forest.

Abstract

Aboveground biomass estimation, using machine-learning systems, is useful for rapid and systematic knowledge of productivity in forests and plantations. In this study, forest aboveground biomass (AGB) was estimated for plantations of *Eucalyptus grandis* and *Pinus* spp. located in the central-eastern sector of the department of Cauca (Colombia), combining synthetic aperture radar (SAR) data of Sentinel-1A, Sentinel-2A optical data and forest inventory data and the use of the Random Forest algorithm. The variables with the highest incidence in AGB for *E. grandis* were the SWIR bands and the VV polarization textures, while for *Pinus* spp. were Correlation_{vv}, GNDVI and B2. The models obtained by combining optical data and SAR show better results with a

1 Universidad Nacional de Colombia. Bogotá, Colombia. altovarbl@unal.edu.co

2 Grupo de Investigación Análisis Espacial del Territorio y del Cambio Global (AET-CG), Facultad de Ciencias Agrarias, Universidad Nacional de Colombia, Bogotá, Colombia. ializarazos@unal.edu.co

3 Departamento de Biología, Facultad de Ciencias, Universidad Nacional de Colombia, Bogotá, Colombia. nrodrigueze@unal.edu.co

determination coefficient $R^2 = 0.27$ and an average square error $EMC = 42.75 \text{ t.ha}^{-1}$ in *E. grandis*, and $R^2 = 0.36$ and $EMC = 141.71 \text{ t.ha}^{-1}$ in *Pinus* spp. The study demonstrated the potential of combining Sentinel

data to estimate AGB in commercial plantations and the use of Random forest for model construction.

Keywords: GLCM, vegetation index, remote sensing, commercial forest plantation, Random Forest.

INTRODUCCIÓN

Las plantaciones forestales ocupan un área aproximada de 53.4 millones de hectáreas, de las cuales el 46.4 % se distribuyen en América Latina (Muller *et al.*, 2018) y representan la principal fuente de celulosa del mundo, lo que las convierte en determinantes para las industrias del papel, cartón, energía eléctrica, conglomerados y de mobiliario, entre otras (Long *et al.*, 2019). Adicional a esto, estas plantaciones juegan un papel importante en la conservación de los bosque naturales al reducir su presión, mejorar la conectividad del paisaje y la biodiversidad, así como secuestrar carbono y restaurar las tierras degradadas y servicios ecosistémicos (Brockerhoff *et al.*, 2017).

La biomasa aérea (AGB, por su siglas en inglés) es un indicador de la productividad de las plantaciones forestales que permite conocer su estado de desarrollo y el potencial de rendimiento en volumen $\text{m}^3.\text{ha}^{-1}$; (Gao *et al.*, 2018). Los métodos convencionales para estimar AGB de plantaciones forestales se basan en el levantamiento de datos dasométricos de inventarios forestales y el subsiguiente ajuste de modelos alométricos (Hernández-Ramos *et al.*, 2017), los cuales tienen la desventaja de poderse poner en marcha en grandes áreas por sus costos económicos, de tiempo y de mano de obra, además de la complejidad en la interpretación de los datos para áreas superiores a las inventariadas (Solano, Vega, Eras y Cueva, 2017). Por otra parte, los métodos basados en percepción remota son potencialmente adecuados para suministrar datos de buena exactitud sobre algunas variables biofísicas, a partir de los cuales se pueden obtener estimaciones confiables, eficientes y oportunas tanto de la estructura del bosque

como de la biomasa aérea (Trisasongko y Paull, 2018). Ese potencial se debe, entre otros aspectos, a la capacidad de proporcionar observaciones completas y frecuentes en escalas locales y globales (Vafaei *et al.*, 2018), a la disponibilidad de datos gratuitos y al uso de una amplia gama de índices espectrales. Este es el caso de las imágenes obtenidas mediante los satélites Sentinel de la Administración Espacial Europea (ESA), los cuales tienen una resolución espacial, espectral y temporal apropiada para muchas aplicaciones de evaluación de los recursos naturales (Veloso *et al.*, 2017).

Los métodos basados en percepción remota para estimar la biomasa aérea han sido aplicados con éxito, encontrándose que al combinar datos ópticos y datos radar de apertura sintética (SAR) junto con algoritmos de aprendizaje automático, como Random Forest (RF) o Support Vector Machine (SVM), se obtiene una mejor correlación entre la biomasa aérea y las variables obtenidas de los datos espectrales (Ghosh y Behera, 2018; Liu *et al.*, 2017; Vafaei *et al.*, 2018). Random Forest es un método estadístico no paramétrico considerado como uno de los mejores de clasificación y regresión debido a la alta precisión en la estimación, su gran velocidad de cálculo, la robustez y la capacidad para predecir las variables importantes; por esto, ha sido ampliamente usado para estimar valores dendrométricos como AGB o volumen de un bosque (Bourgoin *et al.*, 2018; Chen *et al.*, 2018; Esteban *et al.*, 2019).

En plantaciones forestales en algunas regiones de Latinoamérica, (Sandoval, 2009) y Mendoza Chichipe (2018) en Argentina y Perú respectivamente, se hallaron que existe una correlación significativa entre la biomasa total de *Eucalyptus grandis* y *Pinus patula* con algunos índices de

vegetación extraídos de imágenes Landsat 5 y Sentinel-2A. En México [Ortiz-Reyes et al. \(2015\)](#) encontró relaciones significativas entre las métricas de LiDAR y datos de campo para variables como altura, biomasa aérea, biomasa total y cobertura arbórea para especies de pino y encino. Sin embargo, en Colombia el uso de información de sensores remotos para estimar biomasa en plantaciones forestales no ha sido estudiado de manera sistemática y la mayoría de investigaciones que incorporan el uso de estos datos se han enfocado en bosques naturales ([Asner et al., 2012](#); [Fernández-Manso, 2009](#); [Galindo et al., 2011](#); [Villa, Romero y Triana, 2017](#)), dejando de lado estudios orientados al sector forestal comercial.

El vacío de conocimiento en el tema hace necesario realizar investigaciones que incorporen el uso de nuevas tecnologías satelitales dentro del sector forestal del país, las cuales podrán optimizar la estimación de la biomasa aérea mediante el diseño y prueba de métodos económicos y rápidos que presenten resultados confiables. El objetivo de esta investigación fue estimar la biomasa aérea de eucalipto (*Eucalyptus grandis*) y pino (*Pinus* spp.) en plantaciones forestales comerciales localizadas en el departamento del Cauca, a partir de imágenes ópticas Sentinel-2A, datos SAR Sentinel-1A y datos de inventarios forestales y mediante el uso del algoritmo de Random Forest (RF) para generar los mejores modelos de regresión asociados a AGB.

MATERIALES Y MÉTODOS

Área de estudio

El estudio se realizó en los municipios de Popayán, Cajibío, Sotaró y Timbío, en el departamento del Cauca, Colombia, entre las coordenadas geográficas $2^{\circ}38'44.92''$ - $2^{\circ}16'10.49''$ norte y $76^{\circ}56'0.68''$ - $76^{\circ}32'40.57''$ oeste ([figura 1](#)). La temperatura promedio anual varía entre 18°C y 20°C , el régimen de precipitación es bimodal que anualmente oscila entre 1 900 mm y 2 400 mm, la altitud varía

entre los 1674 y 3 116 m y las pendientes medias son del 24 % ([Ideam, 2017](#)). Gran parte de la actividad económica de la zona está asociada a plantaciones forestales comerciales pertenecientes a la empresa papelera Smurfit Kappa Colombia (SKC), cuyo objetivo es la elaboración de pulpa ([Valencia, 2017](#)) y fueron establecidas desde el año 2009 para las plantaciones de *E. grandis*, y desde el año 1999 para las plantaciones de *Pinus* spp. (*P. oocarpa*, *P. patula* y *P. tecunumanii*).




Figura 1. Localización del área de estudio.

Datos de campo

Los datos fueron tomados en el mes de diciembre de 2015, mediante levantamiento de inventarios forestales en parcelas circulares de 250 m² donde se registraron las variables altura (h) y diámetro a la altura del pecho (DAP), número de individuos y coordenadas del centro de las parcelas, censando todos los árboles vivos con DAP mayores a 5 cm ([Dittmann, Thiessen y Hartung, 2017](#)). En total la

zona tiene plantada un área de 39 km² de *E. grandis* y 61 km² de *P. spp* y se inventariaron 23 lotes, 13 de *E. grandis* y 10 de *P. spp*, los cuales tienen una extensión variable que oscila entre 0.15 km² a 18 km² para *E. grandis* y de 8 km² a 27 km² para *P. spp* (Smurfit Kappa Colombia, 2015). Mediante modelos alométricos construidos por la empresa Smurfit Kappa Colombia (Zapata, 2018), se estimó la biomasa aérea forestal para las dos especies en t.ha⁻¹ usando DAP como variable explicativa. La [tabla 1](#) presenta la distribución de la biomasa aérea en los lotes muestreados de acuerdo con la especie inventariada. Para el caso de datos del género *Pinus* (*P. oocarpa*, *patula* y *tecunumanii*) estos se agruparon en *P. spp*.

Datos ópticos Sentinel-2A y radar Sentinel-1A

Las imágenes usadas en el presente estudio fueron obtenidas por la Agencia Espacial Europea (ESA) el 24 de diciembre de 2015 (Sentinel-2A_MSIL1C) y 11 de junio de 2016 (Sentinel-1A_IW_GRD). La imagen Sentinel-2A cuenta con 13 bandas espectrales con tamaño de píxel 10 metros (B2 azul, B3 verde, B4 roja y B8 infrarrojo cercano), 20 metros (B5, B6 y B7 de borde rojo, B8a de infrarrojo cercano, B11 y B12 de infrarrojo de onda corta) y 60 metros (B1 de aerosoles, B9 de vapor de agua y B10 de cirrus). Tres bandas corresponden a los rangos espectrales de “borde rojo”, las cuales son importantes para derivar información asociada al estado de la vegetación (Gatti *et al.*, 2015). La

imagen Sentinel-1A de radar de apertura sintética (SAR) opera en la banda C y cuenta con polarización dual VV (Transmisión vertical y recepción vertical) / VH (Transmisión vertical y recepción horizontal), fue obtenida mediante una órbita ascendente con un ancho de franja de 250 km, tiene una resolución espacial de 5 × 5 m y un ángulo de incidencia entre 31.09 y 46.23 grados (Bourbigot, Johnsen, Piantanida y Hajdych, 2017).

Preprocesamiento de imágenes

Los datos Sentinel-2A fueron corregidos atmosféricamente transformando los datos de reflectancia en el tope de la atmósfera (TOA) (L1C) a reflectancia a nivel de la superficie (BOA) (L2A), a través de algoritmos aplicados en el módulo *Sen2Cor* del programa SNAP (Müller-Wilm, 2016). Dado que los datos de AGB en campo fueron capturados en un área circular de 250 m², se re-muestrearon las bandas 5, 6, 7 y 8a, a un tamaño de píxel de 10 m empleando el método de convolución cúbica.

La imagen SAR fue calibrada radiométricamente usando la herramienta *Terrain calibrate* del programa SNAP, para representar los valores del píxel original a valores reales de retrodispersión de la superficie reflectante. Posteriormente, se aplicó un filtro Gamma MAP de 3 × 3 píxeles para disminuir el efecto moteado o “speckle” preservando los detalles más finos de la imagen (Gao *et al.*, 2018). La imagen filtrada fue georectificada usando el modelo de elevación digital (DEM) de Alos Palsar correspondiente a octubre de 2010 (Poursanidis y

Tabla 1. Distribución de datos de biomasa aérea. n: tamaño de la muestra, S: desviación estándar

Especie	n	Media (t.ha ⁻¹)	S (t.ha ⁻¹)	Mín. (t.ha ⁻¹)	Máx. (t.ha ⁻¹)
<i>E. grandis</i>	67	201.98	47.27	70.49	338.79
<i>P. spp</i>	81	489.49	159.26	263.60	925.40
<i>P. oocarpa</i>	24	493.96	193.67	281.12	925.40
<i>P. patula</i>	35	518.28	168.83	263.59	847.33
<i>P. tecunumanii</i>	22	438.80	72.85	308.65	540.30

Fuente: Smurfit Kappa Colombia (2015).

Chrysoulakis, 2017) cuya resolución espacial es de 12.5 metros. Como resultado de este preprocesamiento se obtuvieron dos coeficientes de retrodispersión: σ_{VV}° y σ_{VH}° en decibeles (dB).

Índices espectrales a partir de datos Sentinel-2 y texturas a partir de datos Sentinel-1

Los índices espectrales fueron seleccionados de acuerdo con su poder predictivo en la estimación de AGB. El índice de vegetación de diferencia normalizada (NDVI) relaciona las bandas espectrales correspondientes al espectro rojo e infrarrojo y ha demostrado ser una variable de predicción efectiva para modelar la biomasa aérea en estudios previos (Galidaki et al., 2017), aun cuando en algunos casos este índice se satura en coberturas densas (Shi y Liu, 2017). El índice de vegetación de diferencia normalizada verde (GNDVI) es más sensible a la variación en el contenido de clorofila que el NDVI (Baloloy et al., 2018). El índice de vegetación ajustado al suelo (Savi) presenta un adecuado resultado cuando la cobertura vegetal es densa, ya que tienen rangos dinámicos amplios y menor susceptibilidad a las perturbaciones (Lu et al., 2017). Los índices se calcularon utilizando las expresiones presentadas en la tabla 2.

Los coeficientes de retrodispersión se utilizaron como entrada para el cálculo de las variables texturales para cada polarización (σ_{VH}° y σ_{VV}°),

usando la matriz de coocurrencia de niveles de gris (GLCM) (Wu et al., 2018), con una ventana de 7 por 7 píxeles y para todas las direcciones (Zhou et al., 2017). En la tabla 3 se encuentran las ecuaciones de cada textura generada con la matriz GLCM.

Posterior a esto, los valores de los píxeles se extrajeron utilizando la herramienta de estadística focal usando un *kernel* de 3 x 3 píxeles, calculando la media y la desviación para disminuir el error de los datos obtenidos con el dispositivo GPS. La utilidad de este método fue recomendada por Rodríguez-Veiga, Saatchi, Tansey y Balzter (2016) bajo el supuesto de que los valores de píxel representan un valor promedio de un área particular en el suelo.

Estimación de AGB con la técnica Random Forest (RF)

Mediante la librería Random Forest del programa estadístico R (Liaw y Wiener, 2002) se usó el algoritmo de regresión Random Forest (RF), basado en el aprendizaje automático no paramétrico a partir de una serie de árboles de decisión para identificar las variables predictoras importantes en la estimación de la AGB de cada especie (Castillo, Apan, Maraseni y Salmo, 2017). Una variable predictora es importante en el modelo de regresión si al omitirla de la lista de variables predictoras aumenta el error “out of bag” (OOB) (Liaw y Wiener, 2002; Ghosh y Behera, 2018). La importancia de las variables se cuantificó utilizando el porcentaje

Tabla 2. Índices espectrales. R: reflectancia; nir: banda infrarroja; r: banda roja; re3n: banda del borde rojo 3; v: banda verde; L: constante dependiente del tipo de suelo (0.5 para este estudio)

Acrónimo	Fórmula	Referencia
NDVI	$\frac{R_{nir} - R_r}{R_{nir} + R_r}$	(Galidaki et al., 2017)
GNDVIre3n	$\frac{R_{re3n} - R_v}{R_{re3n} + R_v}$	(Navarro et al., 2017)
GNDVI	$\frac{R_{nir} - R_v}{R_{nir} + R_v}$	(Baloloy et al., 2018)
SAVI	$\frac{(R_{nir} - R_r)}{R_{nir} + R_r + L} (1 + L)$	(Ghosh y Behera, 2018)

Tabla 3. Fórmulas de características texturales. P_{ij} : valor de probabilidad de coocurrencia de niveles de gris i, j en la ventana de estudio; μ : media; σ^2 : varianza. Cada parámetro se generó en las polarizaciones vertical-vertical (VV) y vertical-horizontal (VH)

Polarización	Parámetro	Fórmula	Descripción
VV/VH	Contraste (CON)	$\sum_{i,j=0}^{M-1} P_{ij}(i-j)^2$	Calcula el nivel de variación local en un kernel.
	Correlación (COR)	$\sum_{i,j=0}^{M-1} P_{ij} \left[\frac{(i-\mu_i)(i-\mu_j)}{(\sigma_i^2)(\sigma_j^2)} \right]$	Mide la dependencia lineal del nivel de grises de una imagen
	Disimilitud (DIS)	$\sum_{i,j=0}^{M-1} P_{ij} i-j $	Mide la variación local de la imagen
	Homogeneidad (HOM)	$\sum_{i,j=0}^{M-1} \frac{P_{ij}}{1+(i-j)^2}$	Mide la suavidad de la textura de la imagen.
	Media (MEA)	$\mu_i = \sum_{i,j=0}^{M-1} i(P_{ij})$ $\mu_j = \sum_{i,j=0}^{M-1} j(P_{ij})$	Nivel de gris promedio en la vecindad menor.
	Varianza (VAR)	$\sigma_i^2 = \sum_{i,j=0}^{M-1} P_{ij} (i-\mu_i)^2$ $\sigma_j^2 = \sum_{i,j=0}^{M-1} P_{ij} (i-\mu_j)^2$	Variabilidad de la respuesta espectral de los píxeles.
	Entropía (ENT)	$\sum_{i,j=0}^{M-1} P_{ij} (-\ln P_{ij})$	Medida estadística de la incertidumbre.

Fuente: Hall-Beyer (2017).

de aumento en el error cuadrático medio ($IncMSE$ %), eliminando las variables menos importantes para luego construir el modelo final de cada especie (Fayad et al., 2016). En este estudio se utilizaron inicialmente 500 árboles ($ntree$) para cada especie y para tres subconjuntos de datos (Sentinel-2A, Sentinel-1AA y la combinación de ambos). Para el parámetro $mtry$, es decir, el número de variables a probar en cada nodo, se utilizó el número total de variables predictoras dividido sobre 3 (Cutler, Cutler y Stevens, 2012). Los parámetros de RF ($mtry$ y $ntree$) se optimizaron con el fin de obtener el mejor poder predictivo en la estimación de AGB. La evaluación del rendimiento de los modelos se efectuó con el 70 % de los datos de campo para ajustes ($n = 50$ y $n = 57$ en *E. grandis* y *P. spp.*, respectivamente) y el 30 % para validación ($n = 22$ y $n = 24$ *E. grandis* y *P. spp.*, respectivamente),

aplicando la técnica de validación cruzada 10 veces para probar de manera sólida el rendimiento del algoritmo, tomando como criterio el menor valor de EMC (Ghosh y Behera, 2018). Finalmente, se mapeó la AGB forestal sobre cada lote usando el modelo AGB óptimo para cada especie con la interpolación Kriging (Lu et al., 2017). Los mapas resultantes fueron generados en el programa RStudio (versión 1.1.442; Team, 2015).

RESULTADOS

Importancia de las variables predictoras

Para *E. grandis* las variables derivadas de los datos Sentinel-2A más determinantes en la estimación de AGB fueron las bandas SWIR (B11 y B12), mientras

que para Sentinel-1A fueron Disimilitud_{VH}, Correlación_{VV} y σ°_{VV} (figura 2). Al combinar los datos ópticos con SAR se encontró que las variables más importantes fueron las bandas SWIR y las texturas media, varianza y correlación de la polarización VV. Para *P. spp* GNDVI, bandas B2 y B3 y σ°_{VV} ,

media y correlación de la polarización VV fueron las variables más importantes en la estimación de AGB (figuras 3a y 3b) y al combinar datos ópticos y SAR, Correlación_{VV}, σ°_{VH} , σ°_{VV} , GNDVI y B2 (figura 3c) están más asociadas a AGB mientras que Contraste_{VV}, B6 y Disimilitud_{VH} no son influyentes.




Figura 2. Ranking de variables importante para estimación de AGB en *E. grandis*. A) datos ópticos; B). datos SAR (VV: polarización vertical-vertical, VH: polarización vertical-horizontal, CON: contraste, COR: correlación, DIS: disimilitud, HOM: homogeneidad, MEA: media, VAR: varianza, ENT: entropía); C). combinación.




Figura 3. Escalafón de variables importante para estimación de AGB en *P. spp*. A) datos ópticos; B) datos SAR (VV: polarización vertical-vertical, VH: polarización vertical-horizontal, CON: contraste, COR: correlación, DIS: disimilitud, HOM: homogeneidad, MEA: media, VAR: varianza, ENT: entropía); C) combinación.

Modelo y mapa de AGB forestal

De acuerdo con los R^2 generados para cada grupo de datos, los resultados indican para *E. grandis* una relación negativa con la estimación de AGB para las imágenes de Sentinel-1A (tabla 4) a través del método RF y, por ende, se interpreta como nulo

(Zumel y Mount, 2014). Sin embargo, al combinar los datos ópticos con SAR se mejoró la capacidad predictiva ($R^2 = 0.27$) generándose el siguiente modelo con el método RF:

Finalmente, la figura 4 presenta la distribución espacial de la AGB estimada obtenida a partir del método kriging usando la función Wave, en la que

Tabla 4. Resultados de los modelos de estimación de AGB usando RF

Especie	Datos	Datos de ajuste		Datos de validación	
		R^2	EMC (t.ha ⁻¹)	R^2	EMC (t.ha ⁻¹)
<i>E. grandis</i>	Sentinel-2A	0.14	46.24	0.13	47.03
	Sentinel-1A	0*	51.39	0	50.95
	Sentinel-2 + Sentinel-1	0.27	42.75	0.26	42.96
<i>P. spp</i>	Sentinel-2	0.18	146.12	0.14	147.35
	Sentinel-1	0	161.49	0	158.37
	Sentinel-2 + Sentinel-1	0.36	141.71	0.28	150.94

$AGB_{(E. grandis)} = 711.18 - 3.247.65 * B12 - 283.2 * B11 - 428.36 * (VV_MEA) + 218.92 * (VV_VAR) + 120.84 * (VV_COR) + 5.784 * \sigma^0 (VV) + 2.03 * (VV_DIS) - 346.81 * B5 - 2.469.49 * B3 - 4.36 * \sigma^0 (VH) + 6.820.57 * B4$

*De acuerdo con el método RF las relaciones negativas se interpretan como un 0 %.

Para *P. spp* se encontró que los datos ópticos generaron EMC más bajos que los datos SAR (146.12 t.ha⁻¹; tabla 4). Sin embargo, su combinación aumentó significativamente el coeficiente de determinación del modelo ($R^2 = 0.36$). El modelo generado con el método RF para estimar AGB de *P. spp* fue:

$AGB_{(P. spp)} = 923.70 - 50.07 * (VV_COR) + 6.062 * VV - 16.530 * B2 - 48.308 * GNDVI + 21.972 * SAVI + 17.13 * (VH_MEA)$




Figura 4. Distribución de AGB estimada: A) *E. grandis*; B) *P. spp*.

el valor medio estimado de AGB fue de 185.32 t.ha⁻¹ y 499.06 t.ha⁻¹ para *E. grandis* y *P. spp* respectivamente, superior al observado en campo.

DISCUSIÓN

Ranking de variables predictoras importantes con RF

En general, las variables derivadas de Sentinel mostraron respuestas diferentes para las especies forestales incluidas en el estudio; del mismo modo, la combinación de datos ópticos y SAR incrementó el potencial para estimar AGB, tal como lo han reportado los estudios de [Ghost y Behera \(2018\)](#), [Debastiani, Sanquetta, Corte, Pinto y Rex \(2019\)](#) para plantaciones en el trópico.

A diferencia de las plantaciones de *P. spp*, en las que todas las bandas e índices espectrales mostraron ser importantes para la estimación de AGB, posiblemente por la forma de la copa y las hojas, las bandas del infrarrojo de onda corta SWIR (B11 y B12) fueron las variables más importantes en *E. grandis* y esto se asocia a características de especies latifoliadas, relacionadas con contenido de humedad de las hojas, una mayor exposición del suelo de la plantación y una mayor eficiencia en la captura de energía por parte del dosel, lo que incide en su respuesta frente a la AGB ([Dang et al., 2019](#))

Si bien la importancia de las bandas de borde rojo en la estimación de AGB se ha abordado en investigaciones anteriores ([Kumar y Mutanga, 2017](#)), en este estudio se encontró que para el caso del índice GNDVI construido con la tercera banda de borde rojo (B7) la inclusión de este rango del espectro es importante para la estimación de AGB en *E. grandis*, dada su efectividad para monitorear la información del estado de la vegetación ([Galidaki et al., 2017](#); [Ghosh y Behera, 2018](#); [Liu et al., 2018](#)). En *P. spp* GNDVI mostró ser la variable predictora más importante contradiciendo lo hallado por [Prabhakara, Hively y McCarty \(2015\)](#), pese a que en nuestro estudio la cantidad de AGB

observado fue alta (489, 49 t.ha⁻¹) y no se evidenció un efecto de saturación, posiblemente por el reemplazo de la banda roja por la banda verde (GNDVI en lugar de NDVI) ([Meyer et al., 2017](#)). Esto puede ser similar a lo presentado en *E. grandis*, donde NDVI no fue una variable importante a diferencia de lo hallado por [Dos Reis et al. \(2018\)](#) en Brasil y que GNDVI puede ser más sensible a la concentración de clorofila-a que el NDVI ([Askar, Nuthammachot, Phairuang, Wicaksono y Sayekti-sih, 2018](#)).

La variable retrodispersión σ_{VV}^o (VV) derivada de los datos SAR mostró mayor importancia al momento de estimar biomasa aérea en plantaciones *E. grandis* y *P. spp*, comparado con la retrodispersión VH. Esto se contradice con el trabajo de [Hosseini y Mcnairn \(2017\)](#), en el cual encontraron que la polarización VH obtuvo las correlaciones más fuertes ($r > 0.917$), en relación con las dos polarizaciones simples (HH y VV), y con [Behera et al. \(2016\)](#), donde usaron datos Alos-Palsar para estimar AGB en *T. grandis* ($r^2VH = 0.46$ y $r^2VV = 0.44$). No obstante, coincide con lo hallado para *S. robusta* ($r^2VH = 0.52$ y $r^2VV = 0.67$) y puede deberse a los valores que surgen de la dispersión del volumen, relacionada directamente con la AGB, y a la influencia de la humedad de la vegetación ([Vreugdenhil et al., 2018](#)). De igual manera, la retrodispersión en VV mostró mayor importancia en *P. spp*, debido a su relación con la irregularidad del dosel que se ha demostrado que es positivamente correlacionado con la biomasa de bosques tropicales más allá del punto de saturación de la relación de retrodispersión-biomasa ([Luckman et al., 1997](#); [Kuplich, Curran y Atkinson, 2005](#)).

Por otro lado, las variables texturales derivadas de SAR mostraron bajas relaciones con los datos de AGB tomados en campo para ambas especies. Sin embargo, las texturas Correlación_{VH} y Correlación_{VV} para *E. grandis* y Correlación_{VH} y Entropía_{VV} para *P. spp*, derivadas de la matriz GLCM arrojaron mejores resultados que los coeficientes de retrodispersión VH y VV. Estos resultados son similares a los encontrados por [Gao et al. \(2018\)](#), en el cual las

medidas de textura media, correlación o ambas estuvieron involucradas en casi todos los modelos de AGB en bosques de coníferas, lo que implica que estas texturas tuvieron contribuciones significativas para mejorar las predicciones de AGB. Attarchi y Gloaguen (2014) encontraron que la adición de texturas derivadas de datos Alos-Palsar a los datos multiespectrales Landsat TM mejoró la estimación de AGB en bosques de *Fagus orientalis*. La razón por la cual algunas características texturales se correlacionaron mejor con la AGB que la retrodispersión SAR, se puede deber a la homogeneidad de los tipos de vegetación estudiados dado que los parámetros de textura son más aplicables en condiciones de alta variación local (Bourgoin et al., 2018).

Estimación de AGB de *E. grandis* y *P. spp* usando el método Random Forest

Los R^2 encontrados en los modelos generados con RF son bajos comparados con otros estudios en plantaciones de coníferas y latifoliadas usando datos Landsat-5 y GLAS a través del método RF con R^2 entre 0.73 y 0.96 (Liu et al., 2017; López-Serrano et al., 2016), y con el uso de datos Alos2-Palsar-2 y Sentinel-2A en un bosque tropical con R^2 cercano a 0.70 (Galidaki et al., 2017). Nuestros resultados pudieron verse afectados por la relación entre el tamaño del píxel de los datos Sentinel y el tamaño de la parcela usada para estimar la AGB en campo, tal como lo reporta Wu et al., (2017) y por la distribución espacial de las muestras dentro del área de estudio.

El EMC obtenido para *E. grandis* fue menor que el obtenido para *P. spp*; esto puede deberse a que se usaron datos de tres especies del género *Pinus*, las cuales logran tener respuestas espectrales diferentes asociadas a la variación en las tasas de crecimiento de cada especie y, por consiguiente, en la predicción de su biomasa, lo que aumentaría la variabilidad en los resultados.

Tanto para *E. grandis* como para *P. spp* el mejor modelo para estimar AGB forestal se obtuvo combinando los datos derivados de Sentinel-2A y los

derivados de Sentinel-S1A. Este resultado coincide con Galidaki et al. (2017) y con los estudios de Bourgoin et al. (2018), Gao et al. (2018) y Ghosh y Behera (2018), quienes sugieren que el uso sinérgico de múltiples sensores ópticos y SAR tiene un mejor potencial para estimar la AGB.

También se demostró que al usar algoritmos de aprendizaje de máquina como Random Forest, en combinación con índices espectrales y datos SAR como variables predictoras, se generan mejores resultados para la estimación de AGB (Fassnacht et al., 2014; Ghosh y Behera, 2018; Liu et al., 2017; Wang et al., 2016).

CONCLUSIONES

Los resultados indicaron que la combinación de datos Sentinel-2A y Sentinel-1A pueden ser usados para generar mejores estimaciones de AGB forestal para las especies *E. grandis* y *P. spp*, usando el método Random Forest y apoyando el mapeo y monitoreo de plantaciones forestales a un bajo costo y de manera más rápida que las mediciones tradicionales en campo. La retrodispersión con polarización VV mostró ser una variable importante para la estimación de AGB en el área de estudio, así como el GNDVI y lo anterior está relacionado con la rugosidad de la vegetación y el contenido de humedad. Sin embargo, los resultados indican bajos valores de R^2 en los modelos, por lo que se recomienda considerar un mayor tamaño de muestra y una mayor área de las parcelas en campo que incluyan más de un píxel para reducir el nivel de incertidumbre respecto a la asociación espacial entre los datos de las imágenes y los datos levantados en campo. De igual manera, para *Pinus* spp. es necesario discriminar las especies para la estimación de la biomasa usando el método Random Forest con el fin de reducir los EMC y obtener predicciones más confiables, aumentando el número de la muestra.

Finalmente, uno de los beneficios clave que ofrece el uso de imágenes de Sentinel es que tanto

los datos de radar SAR como las imágenes multi-espectrales están disponibles de forma gratuita que pueden procesarse en el programa gratuito SNAP. Por último, en países donde los recursos para la adquisición de imágenes y programas especializados son limitados el potencial de aplicación de esta metodología es alta.

AGRADECIMIENTOS

Agradecemos a la empresa Smurfit Kappa Colombia S. A. por proporcionar los datos de campo, esenciales para el desarrollo de esta investigación; en especial a los ingenieros Nórman Parra, Alberto Uribe y Edgar Agudelo por su buena disposición.

CONFLICTO DE INTERESES

Los autores declaran no tener conflicto de intereses.

CONTRIBUCIÓN POR AUTOR

Los autores son los únicos responsables de la obra en todos los aspectos que condujeron a la elaboración de su publicación.

REFERENCIAS

- Askar, Nuthammachot, N., Phairuang, W., Wicaksono, P. y Sayektiningsih, T. (2018). Estimating Above-ground Biomass on Private Forest Using Sentinel-2 Imagery. *Journal of Sensors*, 2018, 1-11.
<https://doi.org/10.1155/2018/6745629>
- Asner, G. P., Clark, J. K., Mascaro, J., Galindo García, G. A., Chadwick, K. D., Navarrete Encinales, D. A., ... Ordóñez, M. F. (2012). High-resolution mapping of forest carbon stocks in the Colombian Amazon. *Biogeosciences*, 9(7), 2683-2696.
<https://doi.org/10.5194/bg-9-2683-2012>
- Attarchi, S. y Gloaguen, R. (2014). Improving the estimation of above ground biomass using dual polarimetric PALSAR and ETM+ data in the Hyrcanian mountain forest (Iran). *Remote Sensing*, 6(5), 3693-3715.
<https://doi.org/10.3390/rs6053693>
- Baloloy, B. A., Blanco, C. A., Candido, G. C., Argamasa, R. J. L., Dumalag, J. B. L. C., Dimapilis, L. L. C. y Paringit, E. C. (2018). Estimation of mangrove forest aboveground biomass using multispectral bands, vegetation indices and biophysical variables derived from optical satellite imageries: rapideye, planetscope and sentinel-2. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 4(3), 29-36.
<https://doi.org/10.5194/isprs-annals-IV-3-29-2018>
- Behera, M. D., Tripathi, P., Mishra, B., Kumar, S., Chitale, V. S. y Behera, S. K. (2016). Above-ground biomass and carbon estimates of Shorea robusta and Tectona grandis forests using QuadPOL ALOS PALSAR data. *Advances in Space Research*, 57(2), 552-561.
<https://doi.org/10.1016/j.asr.2015.11.010>
- Bourbigot, M., Johnsen, H., Piantanida, R. y Hajdudh, G. (2017). Sentinel-1 Sentinel-1 Product Specification S-1 MPC Nomenclature: DI-MPC-PB S-1 MPC Reference: MPC-0240. *European Space Agency*. Recuperado de
https://sentinels.copernicus.eu/documents/247904/349449/Sentinel-1_Product_Specification
- Bourgoin, C., Blanc, L., Bailly, J., Cornu, G., Berenguer, E., Oszwald, J., ... Forest, A. (2018). The Potential of Multisource Remote Sensing for Mapping the Biomass of a Degraded Amazonian Forest.
<https://doi.org/10.3390/f9060303>
- Bourgoin, C., Blanc, L., Bailly, J. S., Cornu, G., Berenguer, E., Oszwald, J., ... Gond, V. (2018). The potential of multisource remote sensing for mapping the biomass of a degraded Amazonian forest. *Forests*, 9(6), 1-21.
<https://doi.org/10.3390/f9060303>
- Brockhoff, E. G., Barbaro, L., Castagneyrol, B., Forrester, D. I., Gardiner, B., González-Olabarria, J. R., ... Jactel, H. (2017). Forest biodiversity,

- ecosystem functioning and the provision of ecosystem services. *Biodiversity and Conservation*, 26(13), 3005-3035.
<https://doi.org/10.1007/s10531-017-1453-2>
- Castillo, J. A. A., Apan, A. A., Maraseni, T. N. y Salmo, S. G.** (2017). Estimation and mapping of above-ground biomass of mangrove forests and their replacement land uses in the Philippines using Sentinel imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 134, 70-85.
<https://doi.org/10.1016/j.isprsjprs.2017.10.016>
- Chen, L., Ren, C., Zhang, B., Wang, Z. y Xi, Y.** (2018). Estimation of forest above-ground biomass by geographically weighted regression and machine learning with sentinel imagery. *Forests*, 9(10), 1-20.
<https://doi.org/10.3390/f9100582>
- Cutler, A., Cutler, D. R. y Stevens, J. R.** (2012). Random forests. *Ensemble Machine Learning: Methods and Applications*, 157-175.
https://doi.org/10.1007/9781441993267_5
- Dang, A. T. N., Nandy, S., Srinet, R., Luong, N. V., Ghosh, S. y Senthil Kumar, A.** (2019). Forest aboveground biomass estimation using machine learning regression algorithm in Yok Don National Park, Vietnam. *Ecological Informatics*, 50(julio 2018), 24-32.
<https://doi.org/10.1016/j.ecoinf.2018.12.010>
- Debastiani, A. B., Sanquetta, C. R., Corte, A. P. D., Pinto, N. S. y Rex, F. E.** (2019). Evaluating SAR-optical sensor fusion for aboveground biomass estimation in a Brazilian tropical forest. *Annals of Forest Research*, 0(0), 109-122.
<https://doi.org/10.15287/afr.2018.1267>
- Dittmann, S., Thiessen, E. y Hartung, E.** (2017). Applicability of different non-invasive methods for tree mass estimation: A review. *Forest Ecology and Management*, 398, 208-215.
<https://doi.org/10.1016/j.foreco.2017.05.013>
- dos Reis, A. A., Carvalho, M. C., de Mello, J. M., Gomide, L. R., Ferraz Filho, A. C. y Acerbi, F. W.** (2018). Spatial prediction of basal area and volume in *Eucalyptus* stands using Landsat TM data: an assessment of prediction methods. *New Zealand Journal of Forestry Science*, 48(1), 1-17.
<https://doi.org/10.1186/s40490-017-0108-0>
- Esteban, J., McRoberts, R., Fernández-Landa, A., Tomé, J. y Næsset, E.** (2019). Estimating Forest Volume and Biomass and Their Changes Using Random Forests and Remotely Sensed Data. *Remote Sensing*, 11(16), 1944.
<https://doi.org/10.3390/rs11161944>
- Fassnacht, F. E., Hartig, F., Latifi, H., Berger, C., Hernández, J., Corvalán, P. y Koch, B.** (2014). Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sensing of Environment*, 154, 102-114.
<https://doi.org/10.1016/j.rse.2014.07.028>
- Fayad, I., Baghdadi, N., Guitet, S., Bailly, J.-S., Hérault, B., Gond, V., ... Tong Minh, D. H.** (2016). Aboveground biomass mapping in French Guiana by combining remote sensing, forest inventories and environmental data. *International Journal of Applied Earth Observation and Geoinformation*, 52, 502-514.
<https://doi.org/10.1016/j.jag.2016.07.015>
- Fernández-Manso, A. Ó.** (2009). Estimación de biomasa forestal usando imágenes del sensor ASTER en masas de pino. *V Congreso Forestal Español*.
- Galidaki, G., Zianis, D., Gitas, I., Radoglou, K., Karathanassi, V., Tsakiri-Strati, M., ... Mallinis, G.** (2017). Vegetation biomass estimation with remote sensing: focus on forest and other wooded land over the Mediterranean ecosystem. *International Journal of Remote Sensing*, 38(7), 1940-1966.
<https://doi.org/10.1080/01431161.2016.1266113>
- Galindo, G., Cabrera, E., Vargas, D., Pabón, H., Yepes, A., Phillips, J. F., ... Ordoñez, M. F.** (2011). *Estimación de la biomasa aérea usando datos de campo e información de sensores remotos Versión 1.0*. Recuperado de <http://documentacion.ideam.gov.co/openbiblio/bvirtual/022105/PARTE3.pdf>
- Gao, Y., Lu, D., Li, G., Wang, G., Chen, Q., Liu, L. y Li, D.** (2018). Comparative analysis of modeling algorithms for forest aboveground biomass estimation in a subtropical region. *Remote Sensing*, 10(4).
<https://doi.org/10.3390/rs10040627>
- Gatti, A., Bertolini, A., Nasuti, C. y Carriero, F.** (2015). Sentinel-2 Products Specification, 1-496.

- Ghosh, S. M. y Behera, M. D.** (2018). Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. *Applied Geography*, 96, 29-40.
<https://doi.org/10.1016/j.apgeog.2018.05.011>
- Hall-Beyer, M.** (marzo de 2017). (b)GLCM Texture: A Tutorial v. 3.0.
<https://doi.org/10.1080/01431161.2016.1278314>
- Hernández-Ramos, J., De los Santos-Posadas, M., Valdez-Lazalde, R., Tamarit-Urias, C., Ángeles-Pérez, G., Hernández-Ramos, A. y Peduzzi, A.** (2017). Biomasa aérea y factores de expansión en plantaciones forestales comerciales de *Eucalyptus urophylla* S. T. Blake. *Agrociencia*, 51, 921-938.
- Hosseini, M. y Mcnairn, H.** (2017). Using multi-polarization C- and L-band synthetic aperture radar to estimate biomass and soil moisture of wheat fields. *International Journal of Applied Earth Observations and Geoinformation*, 58, 50-64.
<https://doi.org/10.1016/j.jag.2017.01.006>
- Ideam** (2017). Indicadores climatológicos (promedios climatológicos). Recuperado de
<http://institucional.ideam.gov.co/JSP/1772>
- Kumar, L. y Mutanga, O.** (2017). Remote Sensing of Above-Ground Biomass. *Remote Sensing*, 9(9), 935.
<https://doi.org/10.3390/rs9090935>
- Kuplich, T. M., Curran, P. J. y Atkinson, P. M.** (2005). Relating SAR image texture to the biomass of regenerating tropical forests. *International Journal of Remote Sensing*, 26(21), 4829-4854.
- Liaw, A. y Wiener, M.** (2002). Classification and Regression by randomForest. *R News*, 2, 18-22.
<https://doi.org/10.1177/154405910408300516>
- Liu, B., Zhi, L., Liu, B., Yu, X., Zhang, P., Tan, X., ... Zhi, L.** (2018). AGB prediction by Sentinel-1 multitemporal data in central Italy with integration of ALOS2 and Sentinel. *Journal of Applied Remote Sensing*, 12(1).
<https://doi.org/10.1117/1.JRS.12>
- Liu, K., Wang, J., Zeng, W. y Song, J.** (2017). Comparison and evaluation of three methods for estimating forest above ground biomass using TM and GLAS data. *Remote Sensing*, 9(4).
<https://doi.org/10.3390/rs9040341>
- Long, T., Pan, H., Dong, C., Qin, T. y Ma, P.** (2019). Exploring the competitive evolution of global wood forest product trade based on complex network analysis. *Physica A: Statistical Mechanics and Its Applications*, 525, 1224-1232.
<https://doi.org/10.1016/j.PHYSA.2019.04.187>
- López-Serrano, P. M., Sánchez, C. A. L., Solís-Moreno, R. y Corral-Rivas, J. J.** (2016). Geospatial estimation of above ground forest biomass in the Sierra Madre Occidental in the state of Durango, Mexico. *Forests*, 7(3), 1-13.
<https://doi.org/10.3390/f7030070>
- Lu, X., Zheng, G., Miller, C. y Alvarado, E.** (2017). Combining multi-source remotely sensed data and a process-based model for forest aboveground biomass updating. *Sensors (Switzerland)*, 17(9).
<https://doi.org/10.3390/s17092062>
- Luckman, A., Baker, J., Kuplich, T. M., da Costa Freitas Yanasse, C. y Frery, A. C.** (1997). A study of the relationship between radar backscatter and regenerating tropical forest biomass for spaceborne SAR instruments. *Remote Sensing of Environment*, 60(1), 1-13.
[https://doi.org/10.1016/S0034-4257\(96\)00121-6](https://doi.org/10.1016/S0034-4257(96)00121-6)
- Mendoza Chichipe, M. E.** (2018). Estimación de carbono en plantaciones de *Pinus patula* mediante el análisis espectral de una imagen satelital sentinel-2, Distrito de Luya Viejo, Amazonas (Trabajo de grado, ingeniería ambiental). Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas. Chachapoyas, Perú. 49 p.
- Meyer, H., Lehnert, L. W., Wang, Y., Reudenbach, C., Nauss, T. y Bendix, J.** (2017). From local spectral measurements to maps of vegetation cover and biomass on the Qinghai-Tibet-Plateau: Do we need hyperspectral information? *International Journal of Applied Earth Observation and Geoinformation*, 55, 21-31.
<https://doi.org/10.1016/j.jag.2016.10.001>
- Müller-Wilm, U.** (2016). Sen2Cor Configuration and User Manual, Ref. S2-PDGS-MPC-L2A- SUM-V2.3. European Space Agency.
- Muller, E. U., Kushlin, A. V., Linhares-Juvenal, T., Muchoney, D., Wertz-Kanounnikoff, S. y**

- Henderson-Howat, D.** (2018). *The state of the world's forests : forest pathways to sustainable development*. FAO
- Navarro, G., Caballero, I., Silva, G., Parra, P.-C., Vázquez, Á. y Caldeira, R.** (2017). Evaluation of forest fire on Madeira Island using Sentinel-2A MSI imagery. *International Journal of Applied Earth Observation and Geoinformation*, 58, 97-106.
<https://doi.org/10.1016/j.jag.2017.02.003>
- Ortiz-Reyes, A. D., Valdez-Lazalde, J. R., los Santos-Posadas, D., Héctor, M., Ángeles-Pérez, G., Paz-Pellat, F. y Martínez-Trinidad, T.** (2015). Inventario y cartografía de variables del bosque con datos derivados de LiDAR: comparación de métodos. *Madera y Bosques*, 21(3), 111-128.
- Poursanidis, D. y Chrysoulakis, N.** (2017). Remote Sensing, natural hazards and the contribution of ESA Sentinels missions. *Remote Sensing Applications: Society and Environment*, 6, 25-38.
<https://doi.org/10.1016/j.rsase.2017.02.001>
- Prabhakara, K., Hively, W. D. y McCarty, G. W.** (2015). Evaluating the relationship between biomass, percent groundcover and remote sensing indices across six winter cover crop fields in Maryland, United States. *International Journal of Applied Earth Observation and Geoinformation*, 39, 88-102.
<https://doi.org/10.1016/j.jag.2015.03.002>
- Rodríguez-Veiga, P., Saatchi, S., Tansey, K. y Balzter, H.** (2016). Magnitude, spatial distribution and uncertainty of forest biomass stocks in Mexico. *Remote Sensing of Environment*, 183, 265-281.
<https://doi.org/10.1016/j.rse.2016.06.004>
- Sandoval, M.** (2009). Evaluación de las existencias y cambios de las superficies implantadas con *Eucalyptus grandis* en la zona de Humaitá, Departamento de Colón, Entre Ríos. Universidad Nacional de la Plata, Argentina. 28 p.
- Shi, L. y Liu, S.** (2017). Methods of Estimating Forest Biomass: A Review, Biomass Volume Estimation and Valorization for Energy. *IntechOpen, i(tourism)*, 13.
<https://doi.org/http://dx.doi.org/10.5772/57353>
- Smurfit Kappa Colombia** (2015). Datos de inventario forestal en Cauca, Colombia.
- Solano, D., Vega, C., Eras, V. H. y Cueva, K.** (2017). Generation of models allometric to determine aerial biomass at the species level, by the destructive method of low intensity for the layer of forest dry Pluviestacional of Ecuador. *Revista Cedamaz*, 4(1), 32-44.
- Team, R** (2015). RStudio: integrated development for R. RStudio, Inc. Boston. Recuperado de <http://www.rstudio.com>
- Trisasonkho, B. H. y Paull, D.** (2018). A review of remote sensing applications in tropical forestry with a particular emphasis in the plantation sector. *Geocarto International*, (September), 1-23.
<https://doi.org/10.1080/10106049.2018.1516245>
- Vafaei, S., Soosani, J., Adeli, K., Fadaei, H., Naghavi, H., Pham, T. D. y Bui, D. T.** (2018). Improving accuracy estimation of Forest Aboveground Biomass based on incorporation of ALOS-2 PALSAR-2 and Sentinel-2A imagery and machine learning: A case study of the Hyrcanian forest area (Iran). *Remote Sensing*, 10(2).
<https://doi.org/10.3390/rs10020172>
- Valencia, C.** (2017). Criterios e indicadores aplicables en la gestión sostenible de plantaciones forestales de ciclo corto en Colombia: una revisión. Recuperado de <https://repository.javeriana.edu.co/handle/10554/20487#.W2M1yBCU67c.mendeley>
- Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Plannells, M., Dejoux, J. F. y Ceschia, E.** (2017). Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote Sensing of Environment*, 199, 415-426.
<https://doi.org/10.1016/j.rse.2017.07.015>
- Villa S., C., Romero B., V. y Triana G., M.** (2017). *Estimación de carbono contenido en la biomasa de las coberturas boscosas pertenecientes a la microcuenca La Hermosa del municipio La Palma, Cundinamarca*.
- Vreugdenhil, M., Wagner, W., Bauer-Marschallinger, B., Pfeil, I., Teubner, I., Rüdiger, C. y Strauss, P.** (2018). Sensitivity of Sentinel-1 backscatter to vegetation

dynamics: An Austrian case study. *Remote Sensing*, 10(9), 1-19.

<https://doi.org/10.3390/rs10091396>

Wang, L., Zhou, X., Zhu, X., Dong, Z. y Guo, W. (2016). Estimation of biomass in wheat using Random Forest regression algorithm and remote sensing data. *The Crop Journal*, 4(3), 212-219.

<https://doi.org/10.1016/j.cj.2016.01.008>

Wu, C., Tao, H., Zhai, M., Lin, Y., Wang, K., Deng, J., ... Yang, H. (2018). Using nonparametric modeling approaches and remote sensing imagery to estimate ecological welfare forest biomass. *Journal of Forestry Research*, 29(1), 151-161.

<https://doi.org/10.1007/s11676-017-0404-9>

Zapata Duque, C. M. (2018). Dinámica del fósforo en el suelo y su relación con el crecimiento del *Eucalyptus grandis* para la región alto andina de Colombia (tesis doctoral). Universidad Nacional de Colombia, Sede Palmira.

Zhou, J., Yan Guo, R., Sun, M., Di, T. T., Wang, S., Zhai, J. y Zhao, Z. (2017). The Effects of GLCM parameters on LAI estimation using texture values from Quickbird Satellite Imagery. *Scientific Reports*, 7(1), 1-12.

<https://doi.org/10.1038/s41598-017-07951-w>

Zumel, N. y Mount, J. (2014). Practical data science with R. Manning Publications Co.

