



UNIVERSIDAD  
**NACIONAL**  
DE COLOMBIA

# **Estimación de biomasa aérea de eucalipto (*Eucalyptus grandis*) y pino (*Pinus spp*) en plantaciones forestales comerciales, usando imágenes satelitales Sentinel**

**Adriana Lizeth Tovar Blanco**

Universidad Nacional de Colombia  
Facultad de Ciencias Agrarias  
Bogotá, Colombia  
2018



# **Estimación de biomasa aérea de eucalipto (*Eucalyptus grandis*) y pino (*Pinus spp*) en plantaciones forestales comerciales, usando imágenes satelitales Sentinel**

**Adriana Lizeth Tovar Blanco**

Tesis de investigación presentada como requisito parcial para optar al título de:

**Magister en Geomática**

Director:

Ph.D. Iván Alberto Lizarazo Salcedo

Codirectora:

Ph.D. Nelly Rodríguez Eraso

Línea de Investigación:

Geoinformación para el uso sostenible de los recursos

Universidad Nacional de Colombia

Facultad de Ciencias Agrarias

Bogotá, Colombia

2018



*“Madre, toda palabra que yo diga  
no alcanza a descifrar lo que te quiero.*

*Eres mi amanecer y mi asidero,  
el árbol dulce que del frío me abriga.”*

*Madre, doy gracias al Universo  
por tu santa presencia en mi vida.*



## **Agradecimientos**

Como primera instancia agradezco a mi familia y amigos por el apoyo y la paciencia durante este tiempo, especialmente a mi madre, quién ha sido mi soporte emocional para enfrentar las decisiones que he tomado en mi vida profesional.

A mi director Iván Lizarazo, por todo el apoyo y paciencia durante este proceso y los espacios para intercambiar ideas, gracias por creer en mí.

A mi co-directora Nelly Rodriguez, porque gracias a su experiencia y exigencia me ayudó a generar mejores resultados.

Deseo agradecer a mis amigos y colegas Manuel Restrepo, Ricardo Mancera, Luisa Osorio y Luis Armando Niño por el apoyo tanto académico como emocional.

Finalmente agradezco a Smurfit Kappa Colombia S.A por proporcionarme los datos de campo, esenciales para el desarrollo de esta investigación, especialmente a los ingenieros Nórman Parra, Alberto Uribe y Edgar Agudelo por su buena disposición.



## Resumen

La estimación de la biomasa aérea forestal es necesaria para diversas aplicaciones técnicas y científicas, lo que permite mejorar el manejo de los bosques y plantaciones. Dado que las mediciones locales son costosas, existe un gran interés en obtener estimaciones confiables sobre grandes áreas a partir de datos de sensores remotos. Actualmente, dichas estimaciones se obtienen con una variedad de fuentes de datos, métodos estadísticos y estándares de predicción. Los datos de percepción remota en combinación con algoritmos de aprendizaje automático basados en árboles de decisión han generado resultados favorables en la estimación de valores de biomasa aérea (AGB, siglas en inglés). En este estudio, la biomasa aérea se estimó para dos especies de árboles principales, *Eucalyptus grandis* (*E. grandis*) y *Pinus spp* (*P. spp*), de plantaciones forestales comerciales en el departamento del Cauca, Colombia. La biomasa aérea se estimó combinando los datos SAR (Radar de apertura sintética) de banda C del satélite Sentinel-1A, las imágenes de textura generadas a partir de los datos de Sentinel-1A, los índices de vegetación producidos con los datos de Sentinel-2A y datos de inventarios forestales. Se usaron regresiones paramétrica lineales y regresiones no paramétricas con Random Forest para establecer una relación entre los valores medidos en campo y los parámetros de percepción remota. El uso de un modelo de Random Forest en combinación de índices de vegetación con la retrodispersión de Radar de Apertura Sintética (SAR, siglas en inglés) como variables predictoras mostró el mejor resultado para el bosque de *E. grandis*, con un coeficiente de valor de determinación de 0,273 y un valor RMSE de 346,62 t.ha<sup>-1</sup>. En *P. spp*, el mejor resultado se pudo encontrar en la misma combinación ( $R^2 = 0,617$  y EMC = 9.025 t.ha<sup>-1</sup>). Este estudio muestra que los datos satelitales Sentinel tienen la capacidad de estimar AGB en plantaciones forestales comerciales y que el algoritmo de aprendizaje automático Random Forest puede ser muy útil para hacerlo.

**Palabras clave:** Percepción remota, plantación forestal comercial, Random Forest, Sentinel, banda C, GLCM, índice de vegetación.

## Abstract

The estimation of the forest aboveground biomass (AGB) is necessary for diverse technical and scientific applications, which allows to improve the management of forests and plantations. Since local measurements are expensive, there is necessary to get reliable estimates over large areas from remote sensing data. Currently, these estimations are obtained with a variety of data sources, statistical methods and prediction standards. Remote sensing data in combination with machine learning algorithms based on decision trees have generated favorable results in the estimation of aboveground biomass values. In this study, aboveground biomass was estimated for two main tree species, *Eucalyptus grandis* (*E. grandis*) and *Pinus spp* (*P. spp*), from commercial forest plantations in Cauca, Colombia. AGB was estimated by combining C-band SAR data from Sentinel-1A satellite, texture images generated from Sentinel-1A data, vegetation indices produced with Sentinel-2A data, and forest inventory data. Linear parametric regressions and nonparametric regressions as Random Forest were used to establish a relationship between the values measured in field and the parameters of remote sensing. The use of a Random Forest model in combination of vegetation indices with SAR data as predictor variables showed the best result for the *E. grandis* forest, with a coefficient of determination value of 0.273 and an RMSE value of 346, 62 t.ha<sup>-1</sup>. In *P. spp*, the best result could be found in the same combination (R<sup>2</sup> = 0.617 and RMSE = 9.025 t.ha<sup>-1</sup>). This study shows that Sentinel satellite data have the ability to estimate AGB in commercial forest plantations and that the Random Forest machine learning algorithm can be very useful to do so.

**Keywords:** Remote sensing, comercial forest plantation, Random Forest, Sentinel, C-band, GLCM, Vegetation index, textures, AGB.

# Contenido

	Pág.
<b>1. Introducción .....</b>	<b>4</b>
1.1 Contexto.....	4
1.2 Antecedentes .....	5
1.3 Planteamiento del problema.....	6
1.4 Objetivo.....	8
Objetivo general .....	8
Objetivos específicos .....	8
<b>2. Marco de referencia .....</b>	<b>9</b>
2.1 Conceptos teóricos.....	9
2.1.1 Biomasa forestal.....	9
2.1.2 Sensores remotos.....	12
2.1.3 Índices espectrales, coeficiente de retrodispersión y características texturales .....	16
2.1.4 Métodos de aprendizaje de máquina .....	18
2.2 Estado del arte .....	19
<b>3. Datos y métodos .....</b>	<b>23</b>
3.1 Área de estudio .....	23
3.2 Datos.....	24
3.2.1 Datos de biomasa aérea forestal .....	24
3.2.2 Datos ópticos Sentinel-2 y de radar Sentinel-1 .....	26
3.3 Metodología .....	28
3.3.1 Índices espectrales a partir de datos Sentinel-2 y coeficientes y texturas a partir de datos Sentinel-1 .....	30
3.3.2 Generación de modelos de regresión lineal .....	32
3.3.3 Generación de modelos con el método Random Forest .....	33
3.3.4 Evaluación de los modelos de regresión.....	34
3.3.5 Cálculo de AGB forestal.....	35
<b>4. Resultados.....</b>	<b>36</b>
4.1 Índices espectrales, coeficientes y texturas.....	36
4.2 Generación de modelos de regresión lineal a partir de los parámetros obtenidos .....	39
4.3 Random Forest .....	41
4.4 Evaluación de los modelos de regresión usados .....	42
4.5 Modelo final y mapa AGB forestal .....	48

---

<b>5. Discusión.....</b>	<b>53</b>
5.1 Índices espectrales y coeficientes de retrodispersión asociados al contenido de biomasa aérea forestal.....	53
5.2 Estimación de AGB de <i>E. grandis</i> y <i>P. spp</i> usando datos Sentinel .....	55
5.3 Mapeo de AGB de <i>E. grandis</i> y <i>P. spp</i> usando el método Random Forest.....	57
<b>6. Conclusiones y recomendaciones .....</b>	<b>59</b>
6.1 Conclusiones .....	59
6.2 Recomendaciones .....	61
<b>Anexos.....</b>	<b>62</b>
<b>Bibliografía .....</b>	<b>89</b>

# Lista de figuras

	Pág.
<b>Figura 1.</b> Componentes de la biomasa forestal.....	10
<b>Figura 2.</b> Método destructivo para estimar biomasa aérea forestal.....	10
<b>Figura 3.</b> Procedimiento de levantamiento de inventario forestal.....	12
<b>Figura 4.</b> Bandas espectrales vs. resolución espacial. <i>Fuente: ESA, 2015.</i> .....	14
<b>Figura 5.</b> Localización geográfica de las plantaciones de eucalipto ( <i>E. grandis</i> ) y pino ( <i>P. patula</i> , <i>P. oocarpa</i> y <i>P. tecunumanii</i> ). Fuente: Elaboración propia.....	24
<b>Figura 6.</b> Imagen óptica Sentinel-2 con combinación RGB 4-3-2. a). <i>P.spp</i> ; c). <i>E.</i> .....	27
<b>Figura 7.</b> Imagen de radar Sentinel-1 con combinación de bandas RGB VH-VV-(VV-VH). b). <i>P.spp</i> ; d). <i>E. grandis</i> .....	27
<b>Figura 8.</b> Flujo de trabajo.....	29
<b>Figura 9.</b> Correlación entre AGB y datos ópticos.....	38
<b>Figura 10.</b> Correlación entre AGB y datos SAR.....	38
<b>Figura 11.</b> Reducción de EMC para <i>E. grandis</i> . a). Datos ópticos; b). Datos SAR; c). Combinación.....	41
<b>Figura 12.</b> Reducción de EMC para <i>P. spp</i> . a). Datos ópticos; b). Datos SAR; c) Combinación.....	42
<b>Figura 13.</b> Relación entre valores observados y valores estimados de biomasa aérea forestal de <i>E. grandis</i> con índices espectrales. a). $GNDVI_{re3n}$ ; b). $GNDVI$ ; c). $NDVI$ y d). $SAVI$ .....	43
<b>Figura 14.</b> AGB de <i>E. grandis</i> generada de los modelos de regresión en el área de estudio.....	45
<b>Figura 15.</b> Relación entre valores observados y valores estimados de biomasa aérea forestal de <i>P. spp</i> con índices espectrales. a). $GNDVI_{re3n}$ ; b). $GNDVI$ ; c). $NDVI$ y d). $SAVI$ .....	46
<b>Figura 16.</b> AGB de <i>P. spp</i> generada de los modelos de regresión en el área de estudio.....	48
<b>Figura 17.</b> Distribución de AGB de <i>E. grandis</i> estimada vs. AGB obtenida en campo....	50
<b>Figura 18.</b> Distribución de AGB de <i>P. spp</i> estimada vs. AGB obtenida en campo.....	51

## Lista de tablas

	Pág.
<b>Tabla 1.</b> Resolución espacial y espectral de Sentinel-2. ....	14
<b>Tabla 2.</b> Resumen de investigaciones recientes. ....	20
<b>Tabla 3.</b> Distribución de datos de biomasa aérea. ....	25
<b>Tabla 4.</b> Fórmulas de índices espectrales. ....	31
<b>Tabla 5.</b> Fórmulas de características texturales. ....	31
<b>Tabla 6</b> Correlación entre AGB y bandas espectrales e índices espectrales. ....	36
<b>Tabla 7.</b> Correlación entre AGB y datos SAR. ....	37
<b>Tabla 8.</b> Modelos de regresión lineal basados en las estimaciones de AGB de <i>E. grandis</i> a partir de los índices de vegetación. ....	39
<b>Tabla 9.</b> Modelos de regresión lineal basados en las estimaciones de AGB de <i>E. grandis</i> a partir de texturas. ....	39
<b>Tabla 10.</b> Modelos de regresión lineal basados en las estimaciones de AGB de <i>P. spp</i> a partir de los índices de vegetación. ....	40
<b>Tabla 11.</b> Modelos de regresión lineal para la estimación de AGB de <i>P. spp</i> a partir de texturas. ....	40
<b>Tabla 12.</b> Pruebas de validación en datos de AGB de <i>E. grandis</i> con índices espectrales. ....	44
<b>Tabla 13.</b> Validación para texturas y AGB de <i>E. grandis</i> . ....	44
<b>Tabla 14.</b> Pruebas de validación para índices espectrales en <i>P. spp</i> . ....	46
<b>Tabla 15.</b> Pruebas de validación para texturas en <i>P. spp</i> . ....	47
<b>Tabla 16.</b> Resultados del modelado de AGB para <i>E. grandis</i> usando RF. ....	49
<b>Tabla 17.</b> Resultados del modelado de AGB para <i>P. spp</i> usando RF. ....	49
<b>Tabla 18.</b> Parámetros de los variogramas de kriging para AGB. ....	50

# Lista de Símbolos y abreviaturas

<b>AGB</b>	Aboveground biomass
<b>DAP</b>	Diámetro a la altura del pecho (1.3 m de altura)
<b>EMC</b>	Error medio cuadrático
<b>GNDVI</b>	Green Normalized Difference Vegetation Index
<b>GPS</b>	Global positioning system
<b>h</b>	Altura
<b>ha</b>	Hectárea
<b>IW</b>	Interferometric-Wide
<b>L</b>	Constante que depende del tipo de suelo
<b>m<sup>3</sup></b>	Metros cúbicos
<b>NDVI</b>	Normalized Difference Vegetal Index
<b>nir</b>	Banda infrarroja
<b>R</b>	Reflectancia
<b>r</b>	Banda roja
<b>re3n</b>	Banda del borde rojo 3
<b>SAR</b>	Synthetic-aperture radar
<b>SAVI</b>	Soil-adjusted vegetation index
<b>SKC</b>	Smurfit Kappa Colombia
<b>t</b>	Tonelada
<b>TOA</b>	Top of the Atmosphere
<b>v</b>	Banda verde

# 1. Introducción

## 1.1 Contexto

Las plantaciones forestales representan la principal fuente de celulosa del mundo, razón por la cual su importancia es determinante para las industrias del papel, cartón, energía eléctrica, conglomerados y de mobiliario, entre otras (Owens *et al.*, 2009). En la actualidad, existen aproximadamente 53,4 millones de hectáreas (ha) de plantaciones forestales a nivel global, de las cuales, el 22% se distribuyen en América Latina (Indufor, 2012), donde las principales especies pertenecen a los géneros *Pinus*, *Eucalyptus*, *Acacia*, *Tectona* y *Gmelina* (Evans, 2009). Colombia por su parte presenta un área plantada relativamente baja de aproximadamente 478.000 ha conformada principalmente por plantaciones de las especies pino pátula (*Pinus patula* Schiede ex Schldl. & Cham.), eucalipto (*Eucalyptus grandis* W.Hill) y ceiba tolúa (*Pachira quinata* (Jacq.) W.S.Alverson). Los principales usos dados a la madera en el país a escala industrial son la producción de papel, cartón y aglomerados (FAO, 2010), siendo las plantaciones de eucalipto y pino las que han tenido gran éxito por presentar tasas relativamente altas de rendimiento, tanto en altura como diámetro y aumento de biomasa aérea (Ospina *et al.*, 2006).

La biomasa aérea forestal (AGB, por su siglas en inglés) es un indicador de la productividad de las plantaciones forestales, dado que permite conocer el estado del desarrollo y el potencial de rendimiento en volumen ( $m^3 \cdot ha^{-1}$ ) de una especie, en un lugar específico, una cierta edad y un cierto tipo de manejo (Castañeda-Mendoza *et al.*, 2012). Los métodos convencionales para estimar la AGB de rodales coetáneos de especies forestales para fines comerciales se basan en el levantamiento de datos dasométricos de inventarios forestales y el subsiguiente ajuste de modelos alométricos (Yepes *et al.*, 2011). Estos métodos convencionales presentan algunas desventajas como la dificultad de implementarse en grandes áreas debido a los elevados costos económicos, el tiempo y la mano de obra que requieren. Además, la interpretación de los datos para áreas superiores a las

inventariadas suele ser compleja y en muchas ocasiones, inviable (Navarro-Cerrillo *et al.*, 2014). A pesar de lo anterior, estos métodos convencionales continúan siendo ampliamente usados en Colombia.

Por otra parte, los métodos de percepción remota son potencialmente adecuados para proporcionar datos precisos de algunos recursos naturales, a partir de los cuales se pueden obtener estimaciones confiables, eficientes y oportunas, tanto de la estructura del bosque como de la biomasa aérea (Schowengerdt, 2007). Lo anterior, se debe entre otros aspectos a la capacidad de proporcionar observaciones completas y repetitivas en escalas locales y globales (Somers *et al.*, 2010) y a una amplia oferta de datos disponible de forma gratuita; este es el caso de Sentinel, una fuente de datos de una adecuada resolución espacial y espectral, así como de resolución temporal (Karlson & Ostwald, 2016). Específicamente, el uso de métodos de percepción remota han sido implementados con éxito para áreas de plantaciones en algunas regiones de Suramérica, por ejemplo, en Argentina, Sandoval (2009) encontró que existe una correlación significativa entre los distintos índices de vegetación extraídos de imágenes LANDSAT 5 TM y la biomasa total de *E. grandis*; en México se encontró una relación significativa entre las métricas de LiDAR y datos de campo para las variables altura, biomasa aérea, biomasa total y cobertura arbórea (Ortiz-Reyes *et al.*, 2015); sin embargo, para Colombia, el uso de información de sensores remotos para estimar biomasa en plantaciones forestales ha sido poco estudiado.

## 1.2 Antecedentes

Los sensores remotos proporcionan imágenes útiles para estudiar y comparar áreas, siempre que su resolución permita la identificación del fenómeno temático en cuestión (Koch, 2012). La alta correlación entre las bandas espectrales y los parámetros de la vegetación brindan información para la estimación de biomasa en grandes áreas (Ahamed *et al.*, 2011), y es así que los datos obtenidos a partir de

imágenes multiespectrales y de radar pueden ser usados para cuantificar la capacidad de producción en bosques y ecosistemas agroforestales usando la biomasa como un indicador por medio de índices de vegetación (de Araujo Barbosa *et al.*, 2015). Lu (2005) reportó que la combinación de la respuesta espectral (bandas espectrales o índices espectrales) y los datos SAR mejoraron el rendimiento de la estimación de la biomasa aérea en comparación con el uso de manera individual de estos datos. Vafaei *et al.* (2018) encontraron que la combinación de los datos Sentinel-2A, ALOS-2 PALSAR-2 y el aprendizaje automático fue adecuada para estimar biomasa forestal en un bosque natural en Irán. Se ha reportado que al utilizar la sinergia de datos y los algoritmos de aprendizaje automático, se obtiene una mejor correlación entre la biomasa aérea y las variables obtenidas de los datos espectrales (Ghosh & Behera, 2018; Liu *et al.*, 2017; Wang *et al.*, 2016).

La percepción remota no sustituye la necesidad de obtener sólidos datos de campo, pero su combinación con los inventarios forestales puede dar mejores resultados que los obtenidos utilizando cada uno de los métodos por separado (Galidaki *et al.*, 2017). Si bien convencionalmente el manejo y planificación del aprovechamiento en las plantaciones forestales se ha basado en los inventarios de variables dendrométricas como fuentes primarias de información, existen tecnologías emergentes que ofrecen herramientas de vanguardia para la obtención de datos a partir de sensores remotos (Vaglio Laurin *et al.*, 2016).

### **1.3 Planteamiento del problema**

La mayoría de investigaciones en Colombia que incorporan el uso de datos obtenidos a partir de sensores remotos con datos de biomasa aérea tomada en campo se han hecho enfocadas en bosques naturales (Galindo. *et al.*, IDEAM 2011; Sacristán & Romero, 2017, Anaya *et al.*, 2008, Asner *et al.*, (2012)), dejando de lado estudios orientados al sector forestal comercial, representado en plantaciones

forestales productivas. Lo anterior genera un vacío de conocimiento en el tema, siendo necesario realizar investigaciones que incorporen el uso de nuevas tecnologías satelitales dentro del sector forestal, las cuales podrán optimizar la estimación de la biomasa aérea, al basarse en métodos económicos y rápidos y que junto con datos de campo presenten resultados confiables.

De acuerdo con lo mencionado antes, en esta tesis se planteó la siguiente pregunta de investigación: ¿La estimación de biomasa aérea en plantaciones forestales a partir de imágenes ópticas y de radar permite obtener resultados confiables?

La hipótesis de este estudio es que las estimaciones de biomasa aérea en plantaciones forestales, obtenidas a partir de imágenes multiespectrales Sentinel 1 y Sentinel 2, no presentan diferencias estadísticamente significativas con las obtenidas a partir de los inventarios forestales convencionales. Para su verificación se realiza un estudio en 13 lotes de plantaciones forestales comerciales de eucalipto y 10 de pino, localizadas en el occidente de Colombia.

## 1.4 Objetivo

### Objetivo general

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-2, datos SAR Sentinel-1 y datos de inventarios forestales para diversas cohortes.

### Objetivos específicos

- Identificar los índices espectrales y coeficientes de retrodispersión que están asociados al contenido de biomasa aérea forestal.
- Generar modelos de regresión de biomasa aérea con base en los parámetros obtenidos y comparar los valores estimados con los valores registrados en inventarios forestales.
- Mapear la biomasa aérea forestal de plantaciones de *E. grandis* y *P. spp* usando datos ópticos y de radar.

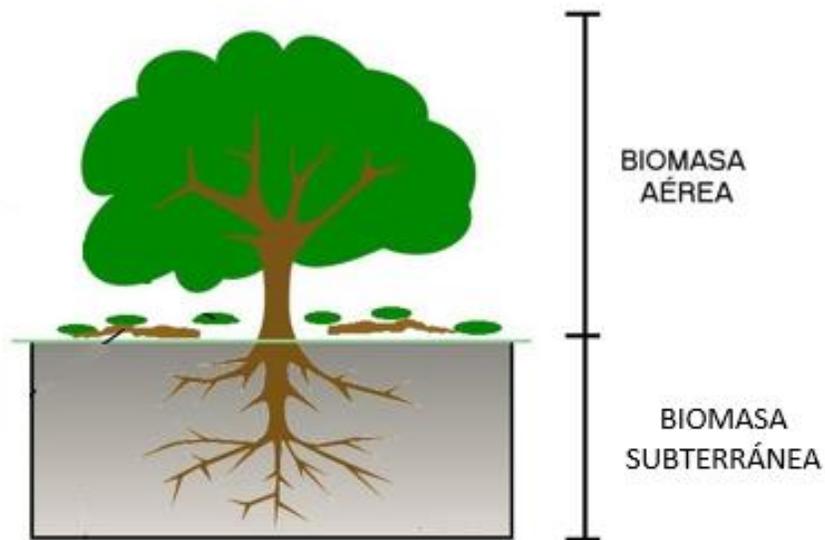
## **2. Marco de referencia**

### **2.1 Conceptos teóricos**

#### **2.1.1 Biomasa forestal**

Una plantación forestal comercial es el establecimiento y manejo de especies forestales en terrenos de uso agropecuario o terrenos que han perdido su vegetación forestal natural, con el objeto de producir materias primas maderables y no maderables, para su industrialización y/o comercialización (Conafor, 2015). Dichas plantaciones están formadas por rodales coetáneos, los cuales son agrupaciones de árboles de una determinada especie establecida en forma artificial (Prodan *et al.*, 1997), establecidas en un período de tiempo relativamente breve, lo que permite que los árboles alcancen tamaños relativamente uniformes (Corvalán & Hernández, 2006). La mayoría de las investigaciones que se han desarrollado tanto en plantaciones comerciales como en bosques naturales se centran en la estimación de biomasa forestal dado que da un indicio de la productividad de dichas coberturas y son fuente de materiales para diversas industrias y para la regulación climática.

La biomasa forestal comprende tanto la biomasa aérea como la biomasa subterránea o radicular (Figura 1) (Schlegel, 2001). La biomasa aérea o AGB se define como la cantidad total de materia orgánica viva en los árboles por encima del suelo donde se incluyen ramas, fuste y hojas, expresada en toneladas por unidad de área (Herold *et al.*, 2009). La biomasa subterránea se refiere a toda la biomasa viva de las raíces vivas, donde se excluyen generalmente las raíces pequeñas de menos de 2 mm de diámetro dado que estas a menudo no pueden distinguirse, de manera empírica, de la materia orgánica del suelo u hojarasca (GIEC, 2003).



**Figura 1.** Componentes de la biomasa forestal.  
Fuente: Cámara forestal, 2016

De acuerdo con Herold *et al.* (2009), la biomasa aérea puede estimarse por medio de varios métodos: el directo o destructivo, el indirecto o no destructivo, y a través de sensores remotos. El método destructivo consiste en talar algunos árboles y pesar sus componentes (fuste, ramas y hojas) de forma separada, siendo el método con resultados más precisos pero no óptimo debido al alto costo de mano de obra y materiales usados y al tiempo que requiere esta actividad (Figura 2).



**Figura 2.** Método destructivo para estimar biomasa aérea forestal.  
Fuente: Adriana Tovar.

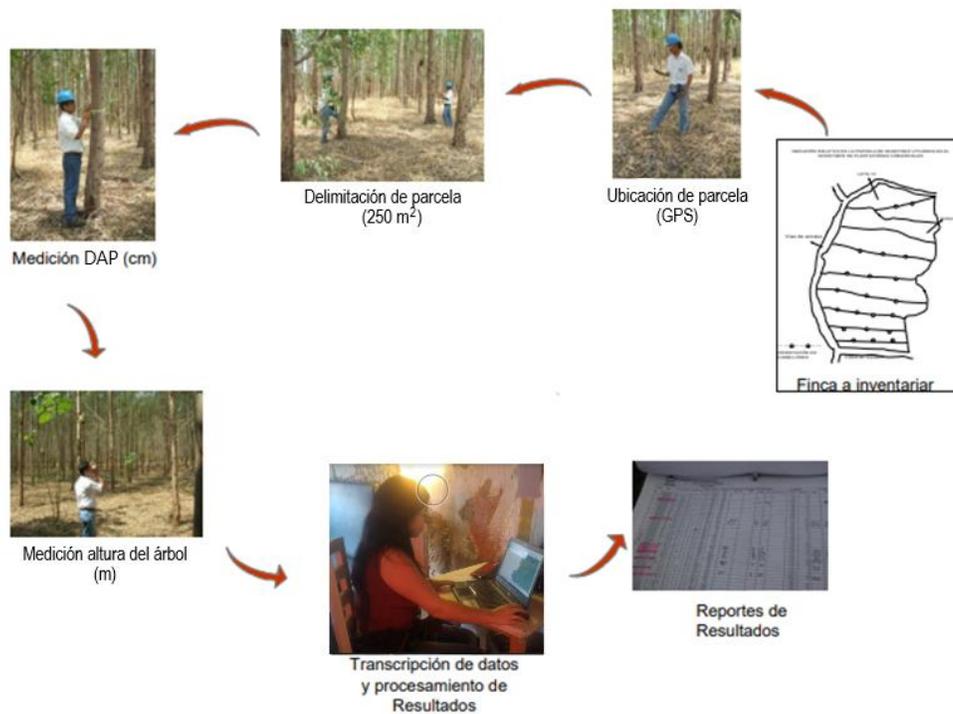
La estimación no destructiva requiere generar ecuaciones alométricas para poder extrapolar los datos a la unidad de área (Herold *et al.*, 2009). Una ecuación alométrica es una fórmula que relaciona una variable respuesta (biomasa aérea) con una o varias variables independientes, como diámetro a la altura del pecho o a 1.3 m sobre el suelo (DAP) o altura del árbol (h) de forma cuantitativa (Picard *et al.*, 2012) (Ecuación 1). En el Anexo A se encuentran otras alternativas de ecuaciones alométricas.

$$Y = aX^b$$

### **Ecuación 1.** Modelo alométrico

Donde Y: biomasa aérea del árbol; X: DAP o h; a: característica de la clase de organismo; b-exponente de escalamiento.

El registro de estas variables en un momento dado se hace convencionalmente a través del desarrollo de inventarios forestales (inventarios de una muestra de árboles si la superficie es grande), con el fin de obtener información necesaria para conocer las características fundamentales del rodal de estudio (IDEAM, 2009). En la Figura 3 se encuentran los pasos a seguir para la construcción de un inventario forestal. La metodología de muestreo define la técnica para seleccionar la muestra probabilística y el método para obtener estimaciones de la población a partir de una muestra seleccionada; de acuerdo con el método estadístico, los tipos de muestreos pueden ser aleatorios, sistemáticos o estratificados (Orozco, & Brumer, 2009). Es importante tener en cuenta que la elección y la organización de los métodos, y los instrumentos de medición, tales como la cinta métrica, la forcípula, el clinómetro Suunto, el medidor Vertex, el GPS, entre otros, influyen tanto en la fiabilidad, como en la calidad de las mediciones (Kleinn, Bhandari & Fehrmann, 2006). Los modelos alométricos representan herramientas útiles para planificar el manejo y aprovechamiento de las plantaciones forestales (Montagnini & Jordan, 2005) y actualmente es el método estadístico más usado debido a su fácil aplicación aunque los resultados no son tan precisos como con el método directo.



**Figura 3.** Procedimiento de levantamiento de inventario forestal.  
Fuente: Smurfit Kappa Colombia, 2014.

Por último está el método de estimación por medio de sensores remotos, donde se mide la radiación óptica o infrarroja que es reflejada o dispersada por la vegetación; este método relaciona directamente la respuesta del sensor remoto con los niveles de la vegetación, o indirectamente estima los atributos de la vegetación a partir de índices, como el índice de área foliar (IAF), la estructura o fracción sombra que luego se usan en las ecuaciones para estimar la biomasa (Herold *et al.*, 2009).

### 2.1.2 Sensores remotos

Los sensores remotos son instrumentos capaces de medir la radiación electromagnética y se pueden clasificar de acuerdo con la fuente de radiación incidente del sensor en i) sensores activos generan y recogen su propia radiación y ii) sensores pasivos que se limitan a recibir la radiación electromagnética reflejada o emitida por la cobertura terrestre (Roy *et al.*, 2017).

### ▪ **Sensores pasivos**

Estos sensores dependen de una fuente de radiación externa, siendo sensibles únicamente a la radiación de origen natural, usualmente la luz solar o la energía emitida por un objeto de la Tierra. Existe una gama de sensores que son sensibles a las radiaciones a diferentes longitudes de onda dentro del espectro electromagnético (Toth & Józskóv, 2016). Por ejemplo, algunos sensores están diseñados para recibir todas las longitudes de onda "verdes", mientras que otros están más enfocados hacia longitudes de onda infrarrojas. El visor de infrarrojos, por ejemplo, está hecho especialmente para "ver" objetos que emiten radiación infrarroja (incluso en la oscuridad) (Roy *et al.*, 2017).

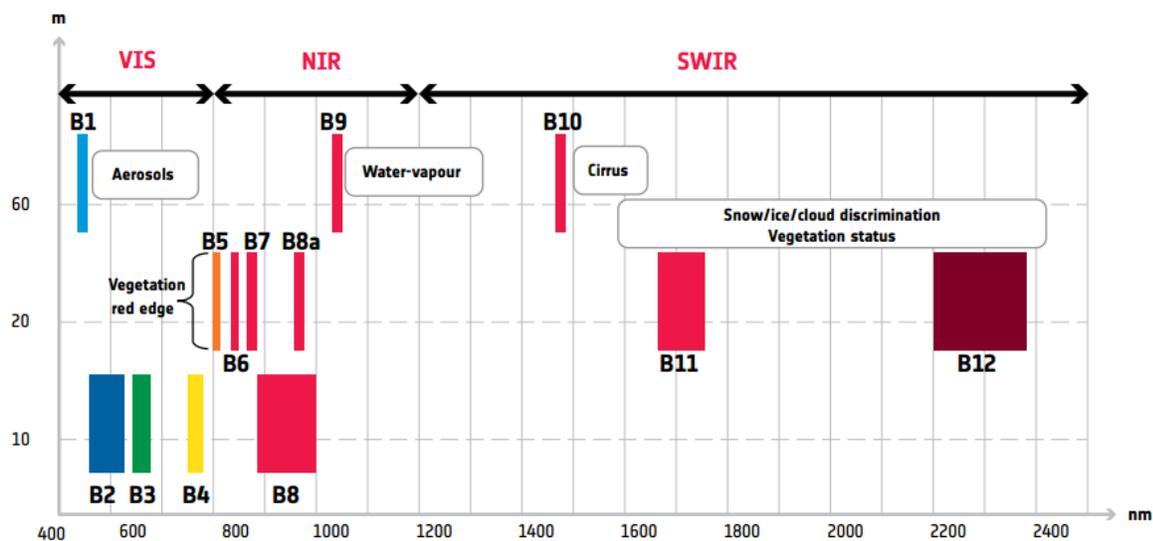
#### *Sentinel-2*

La misión Sentinel-2, de la Agencia Espacial Europea (ESA), fue puesta en órbita en junio de 2015 y fue diseñada para alimentar el sistema de Monitoreo Global para el Medio Ambiente y la Seguridad (GMES) con imágenes continuas y operativas de alta resolución para el monitoreo global y continuo de las áreas terrestres y costeras de la Tierra (ESA, 2015). Sentinel-2 se basa en operaciones simultáneas de dos satélites idénticos que vuelan en un solo plano de órbita gradualmente a 180°, cada uno alojando un instrumento multi-espectral (MSI), que abarca un rango espectral desde la parte visible hasta el infrarrojo de onda corta. El sistema cuenta con 13 bandas espectrales de 10, 20 y 60 metros de resolución espacial, de las cuales cinco bandas corresponden a los rangos espectrales de "borde rojo", importantes para proporcionar información clave sobre el estado de la vegetación (Tabla 1 y Figura 4). La distribución de las imágenes de alta resolución espacial es a escala global y con una frecuencia de revisita de 5 días (ESA, 2015).

**Tabla 1.** Resolución espacial y espectral de Sentinel-2.

Bandas	Resolución espacial (m)	Centro de ancho de banda (nm)	Ancho de banda (nm)
Banda 1 (Aerosol)	60	443	20
Banda 2 (Azul)	10	490	65
Banda 3 (Verde)	10	560	35
Banda 4 (Rojo)	10	665	30
Banda 5 (Borde rojo)	20	705	15
Banda 6 (Borde rojo)	20	740	15
Banda 7 (Borde rojo)	20	783	20
Banda 8 (Infrarrojo cercano - NIR)	10	842	115
Banda 8a (Infrarrojo cercano - NIR)	20	865	20
Banda 9 (Vapor de agua)	60	9945	20
Banda 10 (Cirrus)	60	1375	30
Banda 11 (Infrarrojo medio - SWIR)	20	1610	90
Banda 12 (Infrarrojo medio - SWIR)	20	2190	180

Fuente: ESA, 2015

**Figura 4.** Bandas espectrales vs. resolución espacial. Fuente: ESA, 2015.

#### ▪ Sensores activos

Los sensores activos son aquellos que proporcionan su propia fuente de energía para controlar el doble funcionamiento de la emisión de señales y la recepción de características conocidas. El sistema de radar (Ratio Detection and Ranging)

emite energía de longitud de onda comprende entre 1 m y 1 mm, desde plataformas aerotransportadas o satelitales; esta energía es reflejada por la superficie terrestre para ser detectada de nuevo por las antenas receptoras del radar (Muñoz, 2008). Los sistemas de radar y LiDAR son los más conocidos (Pizaña *et al.*, 2016).

La gran longitud de onda con que el radar trabaja (región de microondas), atraviesa toda clase de obstáculos atmosféricos como nubes y lluvia y su capacidad para capturar información a cualquier hora del día o de la noche, hacen de este sistema uno de los más baratos en percepción remota, siendo aconsejado para trabajar en grandes áreas en estudios previos de reconocimiento (Oliver, 2004). La señal captada por el radar se denomina backscattering o retrodispersión que es el reflejo o eco de la señal, generalmente difuso y que se dispersa en todas las direcciones opuestas a la señal incidente (Grant *et al.*, 2015). Todas las imágenes de radar suelen aparecer con algún grado de lo que se conoce como ruido o Speckle; esto aparece con un aspecto granuloso dentro de la textura de la imagen y es causado por interferencias constructivas y destructivas al azar, provenientes de la múltiple dispersión ocurrida dentro de cada celda de resolución. Este ruido degrada la calidad de la imagen y puede hacer que la interpretación sea más difícil. De este modo, es primordial tratar de reducir el ruido antes de la interpretación y el análisis. La reducción del ruido se logra por medio de dos procesos: procesamiento de múltiples vista y filtrado espacial (Pérez, 2001).

El principal problema de estos sensores es su baja resolución espacial, el tamaño mínimo de un objeto identificable que es directamente proporcional a la longitud de onda y altura de la observación e inversamente proporcional al diámetro de apertura (Ghasemi *et al.*, 2011). Para disminuir este problema se emplea el Radar de Apertura Sintética (SAR) cuyo principio de operación se basa en el efecto Doppler que afecta a la observación realizada cuando existe un movimiento relativo entre el objeto y sensor (Cutler *et al.*, 2012). La dependencia de la cantidad de biomasa con respecto a la señal de radar es función de la longitud de onda, la polarización y el ángulo incidente de dicha señal (Ferrazzoli *et al.*, 2011); la

intensidad de la señal de radar retrodispersada por la cobertura vegetal se satura cuando se alcanza una cierta cantidad de biomasa, este punto de saturación es mayor cuanto mayor es la longitud de la onda radar incidente (Izagirre, 2011). Las texturas derivadas de las estadísticas locales y la matriz de co-ocurrencia de niveles de grises permiten identificar relaciones con las características de la superficie teledetectada (Culler *et al.*, 2012). La principal clase de característica extraída depende de la suposición de que la textura se puede definir por las propiedades estadísticas locales de un píxel en escala de grises (Eckert, 2012). A partir del histograma de la imagen se pueden derivar los estadísticos de primer orden y usarse como características de textura (Kuplich *et al.*, 2005).

### *Sentinel-1*

Es una misión espacial compuesta por los satélites Sentinel-1A y Sentinel-1B, los cuales llevan un instrumento de radar de apertura sintética que opera en la banda C con polarizaciones horizontal y vertical y se basa en una antena plana desplegable por etapas donde lleva módulos de transmisión/recepción (Periasamy, 2018). La antena cuenta con dos instalaciones de dirección del haz de azimut y elevación, lo que permite la adquisición de datos SAR en cuatro modos diferentes de acuerdo con las necesidades de la aplicación particular y cuyo ciclo de repetición es de 12 días (Bourgoin *et al.*, 2018).

## **2.1.3 Índices espectrales, coeficiente de retrodispersión y características texturales**

Una técnica muy utilizada para la estimación de biomasa implica el uso de índices de vegetación como el índice de razón de vegetación (RVI), índice de vegetación de diferencia normalizada (NDVI) y el índice de la vegetación del suelo ajustado (SAVI) (Hills & Hanan, 2013). Un índice de vegetación se define como un parámetro calculado a partir de valores de la reflectancia a distintas longitudes de onda cuyo fin es extraer información relativa a la vegetación, minimizando las perturbaciones debidas a factores tales como el suelo o la atmósfera (Olaya, 2014). Algunos índices de vegetación pueden ser usados como indicadores de productividad en un período de crecimiento de los cultivos y plantaciones, ya que son capaces de

caracterizar la variación en la fenología y el potencial fotosintético de los cultivos y ayudar a identificar el ciclo de cultivo y el crecimiento (de Araujo Barbosa *et al.*, 2015).

Los componentes forestales dispersan la energía transmitida por los sistemas SAR en todas las direcciones. Una porción de la energía registrada por el radar se traduce a una proporción entre la densidad de energía dispersada y la densidad de energía transmitida desde los objetivos de superficie por unidad de área. El coeficiente de retrodispersión ( $\sigma^\circ$ ) o la sigma nula es la cantidad de sección transversal del radar. En general, esta magnitud se expresa como un logaritmo a través de unidades de decibelios como la siguiente ecuación de forma lineal (Ec. 2):

$$\sigma^\circ_{(db)} = 10 * \log_{10}\sigma^\circ$$

**Ecuación 2.** Coeficiente de retrodispersión

El valor del coeficiente de retrodispersión está relacionado con dos variables de sensores y parámetros de destino. Las características del sensor son una función de la longitud de onda, la polarización y el ángulo de incidencia, mientras que las características del objetivo están asociadas con la rugosidad, la geometría y las propiedades dieléctricas. El modelado de biomasa a través de este enfoque se ha aplicado generalmente a partir de modelos de regresión simples bajo el supuesto de correlación entre el coeficiente de retrodispersión y la biomasa aérea. Los resultados son diferentes porque dependen de la saturación de la señal, que es una función de la longitud de onda, la polarización y las características de la cubierta vegetal, así como de las dificultades causadas por las propiedades específicas del suelo como pendiente y aspecto. Recientemente, algunos de ellos han combinado modelos espaciales con datos de detección remota para mejorar las estimaciones geoestadísticas utilizando el coeficiente de retrodispersión como variables secundarias espaciales (Pizaña *et al.*, 2016).

Hay muchos métodos disponibles para extraer texturas de imágenes de teledetección, y las medidas de textura basadas en la matriz de co-ocurrencia de niveles de grises (GLCM) pueden ser las más utilizadas, donde se derivan las características media, varianza, homogeneidad, contraste, disimilitud, entropía, segundo momento angular y correlación (Lu *et al.*, 2016).

#### **2.1.4 Métodos de aprendizaje de máquina**

Las técnicas de aprendizaje de máquina son métodos de regresión no-lineales altamente poderosos los cuales pueden ser usados como una alternativa para solucionar problemas complejos, no lineales (Breiman, 2001) y no dependen de la distribución de los datos (Cracknell & Reading, 2014).

- **Modelo con Random Forest**

El método de bosques aleatorios, o Random Forest, es un algoritmo de aprendizaje de máquina no paramétrico (Breiman, 2001). En este algoritmo, una parte de los datos de entrenamiento se toman aleatoriamente para construir un árbol de decisión e identificar las variables importantes; una variable se considera importante si incrementa el error “Out of Bag” (OOB) cuando esta se omite (Liaw & Wiener, 2002). La parte restante de los datos de entrenamiento, los cuales no han sido usados para la construcción del árbol, se usa para estimar el error de cada árbol (Pal, 2005). En cada nodo del árbol, se toman aleatoriamente un conjunto de variables predictores para determinar la división. Cientos de árboles se construyen similarmente y finalmente, los nuevos datos se predicen por la agregación de los predictores de todos los árboles. Random Forest (RF) no es sensible al ruido de los datos, y además no genera sobreestimación (Pandit *et al.*, 2018). En el dominio de la percepción remota, RF se ha aplicado como un algoritmo de clasificación; sin embargo, actualmente se está usando para aplicaciones basadas en regresión (Hlatshwayo *et al.*, 2019; Vafaei *et al.*, 2018; Chemura *et al.*, 2018; Ghosh & Behera, 2018; Wang *et al.*, 2016).

## 2.2 Estado del arte

El uso de sensores remotos para estimar biomasa es una técnica relativamente nueva; sin embargo, en diferentes regiones del mundo se ha utilizado con resultados favorables. En los bosques mediterráneos, los modelos basados solo en datos ópticos han generado estimaciones de AGB precisas ( $R^2 = 0.70$ ); sin embargo, cuando se involucran datos de sensores activos, la precisión de las estimaciones puede aumentar ( $R^2 > 0.80$ ) (Galidaki *et al.*, 2017). En el bosque natural hircano de Irán, Vafaei *et al.*, (2018) encontraron que la combinación de los datos de Sentinel-2A y ALOS-2 PALSAR-2 mejoró la precisión de estimación de AGB ( $R^2 = 0.73$ ,  $EMC = 38.68 \text{ t.ha}^{-1}$ ), en comparación con la de las imágenes de Sentinel-2A solamente ( $R^2 = 0.68$ ,  $EMC = 42.04 \text{ t.ha}^{-1}$ ). También se ha demostrado que usando algoritmos de aprendizaje de máquina como Random Forest, en combinación con índices espectrales y datos SAR como variables predictoras, se generaron mejores resultados para la estimación de AGB de *Shorea robusta* y *Tectona grandis* en un bosque natural tropical, con un  $R^2 = 0.71$  y un  $EMC = 105.027 \text{ t.ha}^{-1}$  (Ghosh & Behera, 2018).

En la actualidad, los datos LiDAR se han utilizado para estimar la biomasa forestal en bosques mixtos caducifolios y en bosques tropicales (Drake *et al.*, 2003), dado que son poderosos para estimar la estructura del dosel, aunque tienen información espectral limitada porque la intensidad del punto del láser es de una sola longitud de onda (Lu *et al.*, 2016). Fagan *et al.*, (2018) encontraron que las métricas LiDAR de la estructura del bosque tuvieron la mayor precisión para la estimación de AGB en plantaciones de pino (*P. taeda*, *P. echinata* y *P. ellotii*), ( $R^2 = 0.90$ ), pero la combinación de datos espectrales y temporales de Landsat generó una precisión comparable ( $R^2 = 0.91$ ).

En Colombia se han generado estimaciones de AGB (biomasa aérea por su nombre en inglés) a nivel regional usando datos ópticos MODIS donde han encontrado intervalos de confianza de 3.7 a 25.2 millones de  $\text{t.ha}^{-1}$  (Anaya, Chuvieco, & Palacios-Orueta, 2009). Asner *et al.*, (2012) cuantificaron el

almacenamiento de carbono en la Amazonía colombiana utilizando un método basado en datos LiDAR, donde se obtuvieron mapas de carbono con un 14% de incertidumbre en una resolución de 1 ha, y un mapa regional basado en la estratificación con un 28% de incertidumbre en cualquier hectárea dada. Angarita & Gaitán (2016) encontraron que la banda L del sistema ALOS PALSAR mostró una fuerte correlación con los datos de AGB de parcelas permanentes en el parque Bataclán, en el Valle del Cauca, y se perfiló como una alternativa rápida para la evaluación de biomasa aérea en los bosques tropicales ( $R^2=0,76$ ). Bedoya (2017) estimó la AGB de un bosque de *Quercus humboldtii* en Antioquia, basándose en imágenes satelitales LANDSAT 8 y encontró que no existieron tendencias consistentes entre la AGB y los datos obtenidos por teledetección usando ecuaciones alométricas. Por otro lado, Clerici *et al.* (2016) desarrollaron un método para estimar la AGB periurbana de los bosques andinos secundarios cerca de Bogotá, Colombia, basados en imágenes GeoEye-1, Pleiades-1A y datos de campo, donde encontraron que los modelos lineales que relacionaban el índice RVI arrojaron los mejores resultados ( $R^2= 0.582$ ).

A modo de resumen, en la Tabla 2 se encuentran algunas investigaciones donde se ha logrado estimar la biomasa aérea usando datos tanto tomados en campo como de radar o multiespectrales en donde se demuestra la eficacia del uso de datos espectrales para la estimación de biomasa aérea forestal.

**Tabla 2.** Resumen de investigaciones recientes.

Objetivo	Datos y métodos	Resultados	Referencia
Investigar la capacidad de dos sensores SAR diferentes, TerraSAR-X (banda X) y ALOS PALSAR (banda L) en uso único y combinado para estimar biomasa aérea forestal en un	TerraSAR-X y ALOS PALSAR. Modelos de regresión lineal.	$R^2 = 53\%$ , EMC = 79 ton/ha. El modelo es válido hasta 307 t.ha <sup>-1</sup> con un requerimiento de precisión de 50 t.ha <sup>-1</sup> y hasta 614 t.ha <sup>-1</sup> con un requerimiento de precisión de 100 t.ha <sup>-1</sup> en terreno plano.	Englhart, Keuck, & Siegert; 2011

bosque tropical de Kalimantan, Indonesia	Desarrollar modelos mejorados de estimación de biomasa y carbono, evaluando la información espectral y textural.	Datos de inventario y WorldView-2. Modelos de regresión lineal.	R <sup>2</sup> = 81%, ECMr= 11,8%	Eckert; 2012
Comprobar la capacidad de las observaciones de polarización de doble haz de ALOS-PALSAR para estimar biomasa aérea en copas complejas en humedales boscosos y bosques secos de tierras altas.		ALOS PALSAR. Modelos de regresión univariados y multivariados.	EMCr de entre 25% y 32% de la biomasa estimada usando retrodispersión HV polarizado.  R <sup>2</sup> de entre 35% y 49%	Peregon & Yamagata; 2013
Evaluar el potencial de combinar los datos ALOS PALSAR y WorldView-2 para mapear la biomasa aérea forestal.		ALOS PALSAR y WorldView-2. Análisis de componentes principales y regresión lineal multivariada (RLM).	R <sup>2</sup> = 65% a 71% El uso del conjunto de datos adicional desarrollado a partir de la fusión de datos FBD y WorldView-2 mejoró el rendimiento a 79% con un EMC de 35,13 t.ha <sup>-1</sup> al utilizar el método RL.	Deng, Katoh, Guan, Yin, & Li; 2014

Comprender las funciones de las texturas de los datos de Landsat TM y ALOS PALSAR para mitigar los impactos de la saturación de datos en la exactitud de estimación de biomasa aérea forestal.	Landsat 5 TM y ALOS PALSAR.	Modelos de regresión lineal.	La combinación de los datos TM y PALSAR como bandas extra dio lugar a los valores mayores de $R^2$ y EMC y EMCr más pequeños.	Zhao <i>et al.</i> ; 2016
Estimar la biomasa aérea de un bosque tropical de la India, usando datos SAR en combinación con datos ópticos.	Sentinel-1 y Sentinel-2.	Algoritmos de aprendizaje automático: Random Forest (RF) y Stochastic Gradient Boosting (SGB)	El uso de un modelo de RF con una combinación de índices de vegetación con retrodispersión SAR generó el mejor resultado para el bosque de <i>S. robusta</i> ( $R^2 = 71\%$ y ECM = $105.027 \text{ t.ha}^{-1}$ ).	Ghosh & Behera; 2018.

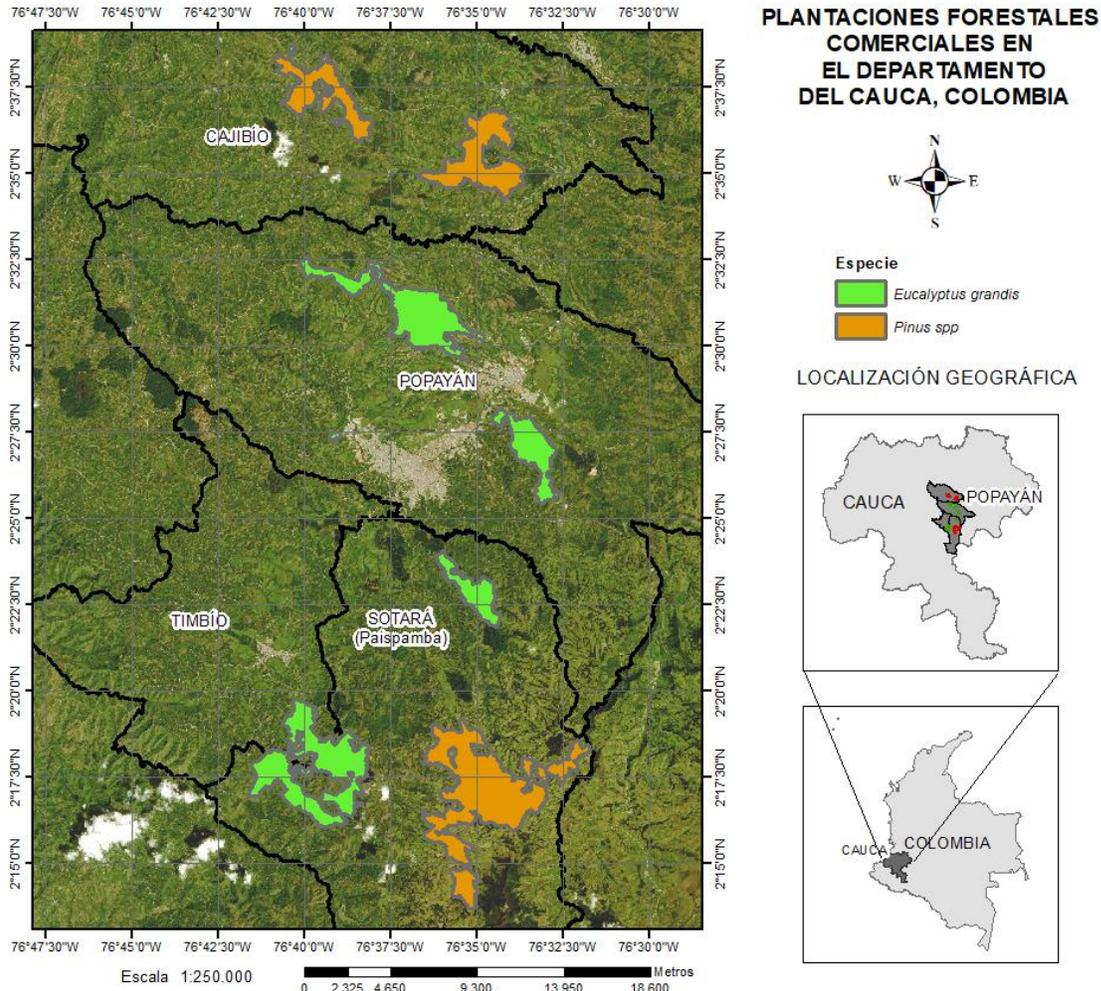
---

EMC: Error medio cuadrático, EMCr: Error medio cuadrático relativo, LR: Regresión lineal.

## 3. Datos y métodos

### 3.1 Área de estudio

El estudio se realizó en los municipios de Popayán, Cajibío, Sotará y Timbío, en el departamento del Cauca, Colombia (Figura 5) entre las coordenadas geográficas 2°38'44,92" – 2°16'10,49" Norte y 76°56'0,68" – 76°32'40,57" Oeste. La zona presenta una nubosidad la mayor parte del año (69 %), que se concentra desde finales de septiembre hasta el mes de junio. La temperatura promedio anual varía entre 18°C y 20°C, la precipitación presenta un régimen bimodal que anualmente oscila entre 1.900 mm y 2.400 mm, una altitud comprendida entre los 1.674 msnm y 3.116 msnm y con pendientes medias del 24%. Gran parte de la actividad económica de la zona está asociada a plantaciones forestales comerciales cuyo objetivo es la elaboración de pulpa. Las plantaciones de *Eucalyptus grandis*, *Pinus patula*, *Pinus tecunumanii* y *Pinus oocarpa* pertenecen a la empresa papelera Smurfit Kappa Colombia (SKC), y fueron establecidas desde el año 2009 para las plantaciones de *E. grandis*, y desde el año 1999 para las plantaciones de *P. spp.*



**Figura 5.** Localización geográfica de las plantaciones de eucalipto (*E. grandis*) y pino (*P. patula*, *P. oocarpa* y *P. tecunumanii*). Fuente: Elaboración propia.

## 3.2 Datos

### 3.2.1 Datos de biomasa aérea forestal

Los datos del levantamiento de inventarios forestales proceden de áreas de plantaciones de eucalipto y pino. Los inventarios forestales se levantaron en el mes de diciembre de 2015, en parcelas circulares de 250 m<sup>2</sup>, donde se registraron las variables: altura (h), capturada con los instrumentos Suunto PM-5/1520 y Haglöf Vertex; diámetro a la altura del pecho (DAP) capturado con cinta métrica; número de individuos y coordenadas del centro de las parcelas. En total se inventariaron

23 lotes, 13 de *E. grandis* y 10 de *P. spp*, los cuales tienen una extensión variable que va de 0,15 km<sup>2</sup> a 18 km<sup>2</sup> para *E. grandis* y de 8 km<sup>2</sup> a 27 km<sup>2</sup> para *P. spp*. Las coordenadas se capturaron con un receptor Trimble Juno 3 B de GNSS con una precisión posicional de 3 m (después de la corrección de post-procesamiento). Para todos los árboles vivos con DAP mayores a 5 cm, se midió el DAP. A través de modelos alométricos construidos por la empresa Smurfit Kappa Colombia, se estimó la biomasa aérea forestal para las dos especies en t.ha<sup>-1</sup> usando DAP como variable explicativa. Los modelos alométricos se construyeron de la siguiente manera:

$$Y = \frac{2.713,38}{1 + \exp\left(\frac{-(X - 38,496)}{7,557}\right)}$$

$$Y = \frac{2.280,9}{1 + \exp\left(\frac{-(X - 37,737)}{7,326}\right)}$$

Donde Y: biomasa aérea en Kg; X: diámetro a la altura del pecho; exp: función exponencial. (Smurfit-Kappa, 2009).

En la Tabla 3 se encuentra un resumen de la distribución de la biomasa aérea en los lotes de acuerdo con la especie inventariada. Los datos del género *Pinus* se agruparon en *P. spp*. En los anexos B y C se encuentran los detalles de los datos de AGB para cada especie.

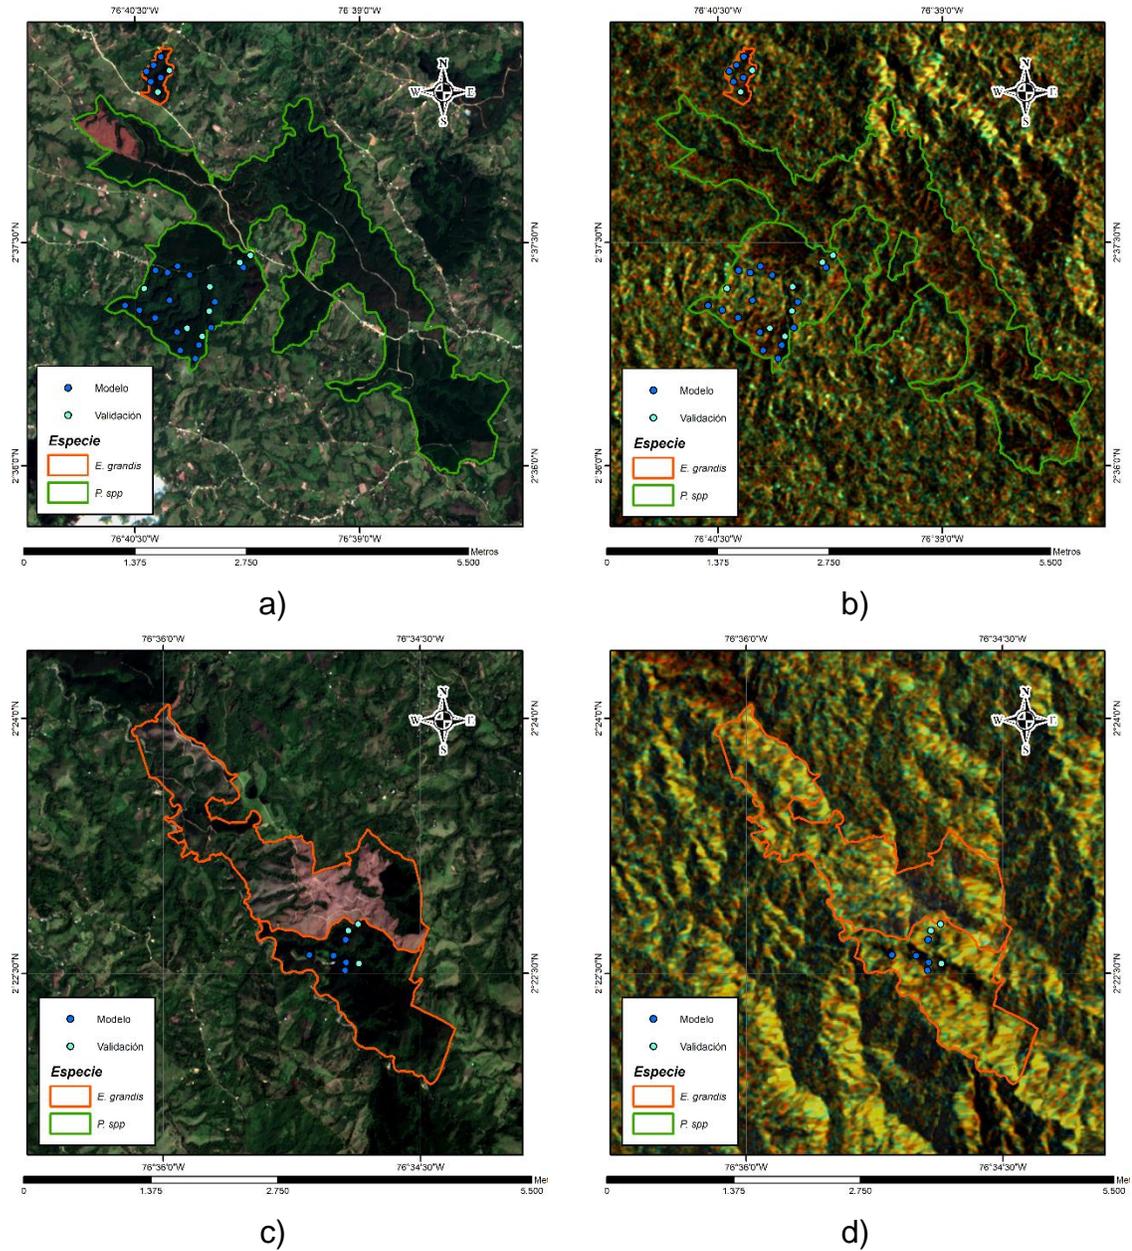
**Tabla 3.** Distribución de datos de biomasa aérea.

<b>Especie</b>	<b>n</b>	<b>Media (t.ha<sup>-1</sup>)</b>	<b>S (t.ha<sup>-1</sup>)</b>	<b>Mín. (t.ha<sup>-1</sup>)</b>	<b>Máx. (t.ha<sup>-1</sup>)</b>
<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	72.854	308.65	540.30

Fuente: Smurfit Kappa Colombia

### **3.2.2 Datos ópticos Sentinel-2 y de radar Sentinel-1**

La imagen óptica Sentinel-2 fue descargada del portal de la Agencia Espacial Europea, con nivel 1C que corresponde a la reflectancia al tope de la atmósfera (TOA), la cual se refiere a la razón de la energía reflejada con respecto al total de la energía incidente (ESA, 2015). Esta imagen fue generada el 24 de diciembre de 2015 (Figura 6). La imagen Sentinel-1 (banda C con polarización dual VV (Transmisión vertical y recepción vertical) / VH (Transmisión vertical y recepción horizontal), dirección de paso ascendente), fue tomada el 11 de junio de 2016, a 10 m de resolución espacial y en modo de franja Interferometric-Wide (IW), con un ancho de franja de 250 km a una resolución espacial de 5 × 20 m y un ángulo de incidencia entre 31,09 y 46.23 grados (Figura 7).

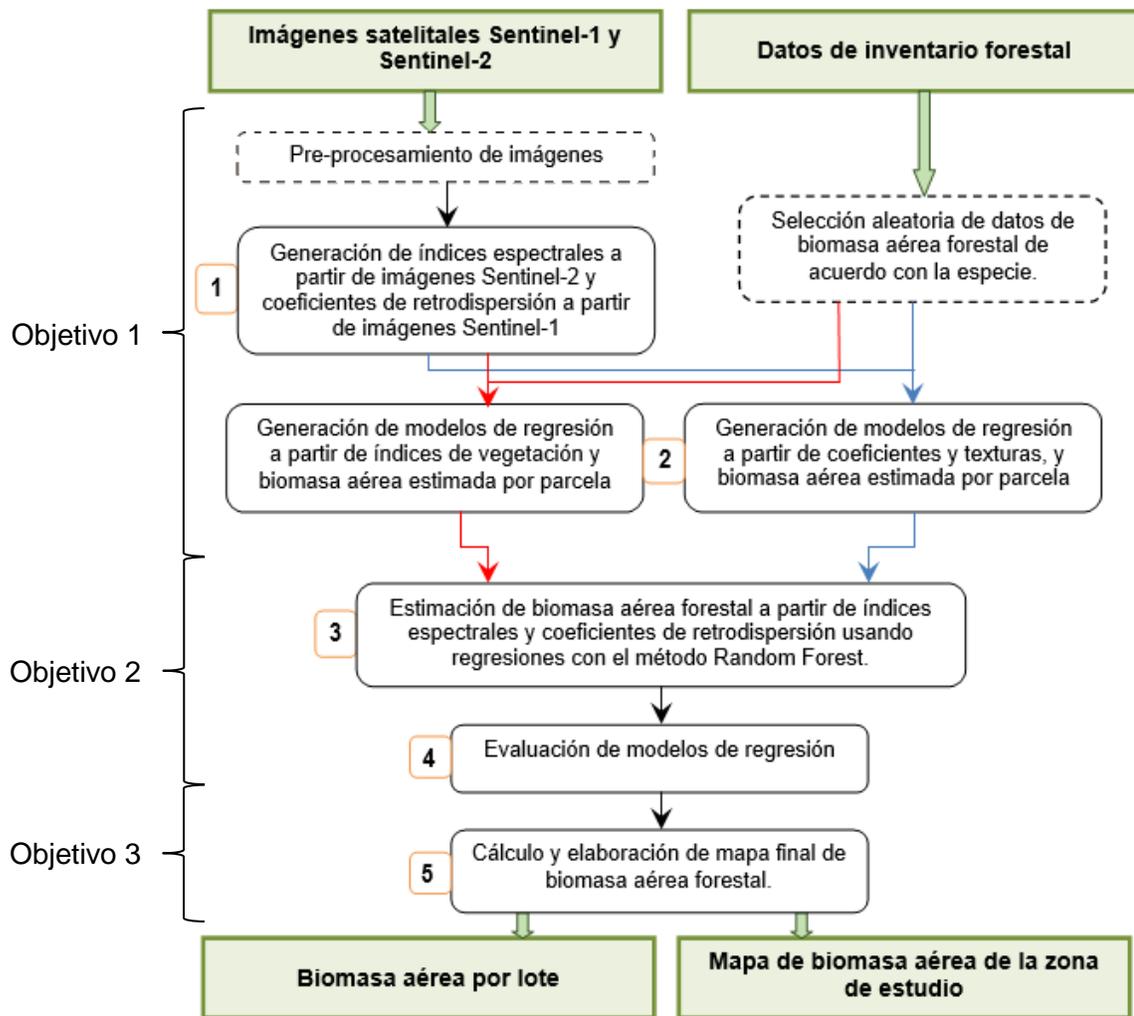


**Figura 6.** Imagen óptica Sentinel-2 con combinación RGB 4-3-2. a). *P.spp*; c). *E. grandis*.

**Figura 7.** Imagen de radar Sentinel-1 con combinación de bandas RGB VH-VV-(VV-VH). b). *P.spp*; d). *E. grandis*.

### 3.3 Metodología

La Figura 8 presenta el proceso metodológico utilizado para el cumplimiento de los objetivos propuestos, los cuales en términos generales son: la primera fase fue la selección y pre-procesamiento de las imágenes Sentinel-1 y Sentinel-2 por medio del software Sentinel Application Platform (SNAP), desarrollado por la ESA. El primer proceso fue el cálculo de índices espectrales a partir de las imágenes satelitales multiespectrales, así como el coeficiente de retrodispersión y las texturas de la imagen de radar Sentinel-1. El tercer proceso fue la generación de modelos de regresión lineal donde se vincularon los parámetros obtenidos de las imágenes multiespectrales Sentinel-2 con la biomasa estimada a partir de datos de inventario. En este proceso también se generaron modelos de regresión lineal relacionando los coeficientes de retrodispersión y las texturas derivadas de GLCM de la imagen de radar Sentinel-1 con la biomasa obtenida en campo. El cuarto proceso corresponde a la implementación del algoritmo de aprendizaje de máquina o machine learning, Random Forest (RF), usado para predecir la biomasa aérea en los lotes de eucalipto y pino. El quinto proceso fue la evaluación de los modelos de regresión obtenidos en los procesos anteriores y el sexto proceso fue el cálculo de la AGB forestal a partir del mejor modelo y la generación de mapas de biomasa aérea para el área de estudio.



**Figura 8.** Flujo de trabajo

Los datos Sentinel-2 fueron corregidos atmosféricamente en el software gratuito SNAP, pasando los datos de reflectancia al tope de la atmósfera (TOA) a reflectancia a nivel de la superficie (BOA), a través de algoritmos desarrollados por la DLR/Telespazio, ejecutados indistintamente de manera manual desde la Caja de herramientas (toolbox) Sentinel-2 bajo el módulo Sen2Cor (ESA, 2016). Dado que los datos de biomasa aérea fueron capturados en un área circular de 250 m<sup>2</sup>, se re-muestrearon las bandas 5, 6, 7 y 8a, correspondientes al borde rojo, a un tamaño de pixel de 10 m para poder hacer uso de estas bandas en los índices espectrales.

El pre-procesamiento de los datos Sentinel-1A se hizo igualmente con el software gratuito SNAP. La imagen SAR fue calibrada con la herramienta Terrain calibrate del software SNAP y posteriormente se generó un filtrado para disminuir el efecto moteado o speckle usando el filtro Gamma MAP con un tamaño de ventana de 3 por 3 píxeles. Este filtro elimina el moteado preservando los detalles más finos de la imagen. La imagen filtrada fue georectificada usando el modelo de elevación digital (DEM) de Alos Palsar correspondiente a octubre de 2010, descargado de Alaska Satellite Facility ([www.asf.alaska.edu/](http://www.asf.alaska.edu/)).

### **3.3.1 Índices espectrales a partir de datos Sentinel-2 y coeficientes y texturas a partir de datos Sentinel-1**

Para la estimación de biomasa a partir de los datos de inventario y de la imagen Sentinel-2 se usó el software SNAP y se emplearon algunos índices de espectrales teniendo en cuenta el poder predictivo de cada uno y la capacidad de comparación con otros estudios relacionados. El Índice de Vegetación de Diferencia Normalizada (NDVI) ha demostrado ser una variable de predicción efectiva para modelar la biomasa aérea en estudios previos (Liang *et al.*, 2012); sin embargo, se han evidenciado casos en los que este índice se satura en coberturas densas (Tilly *et al.*, 2015). El índice de vegetación de diferencia normalizada verde (GNDVI), es más sensible a la variación en el contenido de clorofila que el NDVI (Gitelson *et al.*, 1996) El Soil Adjusted Vegetation Index (SAVI) presenta un adecuado resultado cuando la cobertura vegetal es densa, ya que estos índices tienen rangos dinámicos amplios y menor susceptibilidad a las perturbaciones atmosféricas (Saadat *et al.*, 2011). Los índices se calcularon utilizando las expresiones presentadas en la Tabla 4.

**Tabla 4.** Fórmulas de índices espectrales

Acrónimo	Índice	Fórmula	Referencia
NDVI	Índice de Vegetación Normalizada	$\frac{R_{nir} - R_r}{R_{nir} + R_r}$	Liang <i>et al.</i> , 2012
GNDVIre3n	Índice de Vegetación Normalizada Verde del borde rojo 3	$\frac{R_{re3n} - R_v}{R_{re3n} + R_v}$	Navarro <i>et al.</i> , 2017
GNDVI	Índice de Vegetación Normalizada Verde	$\frac{R_{nir} - R_v}{R_{nir} + R_v}$	Kross, A., <i>et al.</i> , 2015
SAVI	Soil Adjusted Vegetation Index	$\frac{(R_{nir} - R_r)}{R_{nir} + R_r + L} (1 + L)$	(Wang <i>et al.</i> , 2016)

Donde R: reflectancia; nir: banda infrarroja; r: banda roja; re3n: banda del borde rojo 3; v: banda verde; L: constante que depende del tipo de suelo (0,5 para este estudio).

Los coeficientes de retrodispersión y las texturas generadas a partir de la matriz de co-ocurrencia de niveles de gris (GLCM) se obtuvieron en SNAP. Las texturas fueron calculadas usando el algoritmo de la matriz de co-ocurrencia de niveles de gris (GLCM) con una ventana de 7 por 7 píxeles y para todas las direcciones. En la Tabla 5 se encuentran las ecuaciones de cada textura generada con la GLCM.

**Tabla 5.** Fórmulas de características texturales.

Parámetro	Fórmula	Descripción
Contraste	$\sum_{ij=0}^{M-1} P_{ij}(i - j)^2$	Calcula el nivel de variación local en una ventada (Yuan <i>et al.</i> , 1991)
Correlación	$\sum_{ij=0}^{M-1} P_{ij} \left[ \frac{(i - \mu_i)(i - \mu_j)}{(\sigma_i^2)(\sigma_j^2)} \right]$	Mide la dependencia lineal del nivel de grises de una imagen (Kayitakire <i>et al.</i> , 2006)
Disimilitud	$\sum_{ij=0}^{M-1} P_{ij} i - j $	Mide la variación local de la imagen (Rubner <i>et al.</i> , 2001)
Homogeneidad	$\sum_{ij=0}^{M-1} \frac{P_{ij}}{1 + (i - j)^2}$	Mide la suavidad de la textura de la imagen
Media	$\mu_i = \sum_{ij=0}^{M-1} i(P_{ij})$ $\mu_j = \sum_{ij=0}^{M-1} j(P_{ij})$	Nivel de gris promedio en la vecindad menor (Materka & Strzelecki, 1998)
Segundo Momento Angular (ASM)	$\mu_i = \sum_{ij=0}^{M-1} P_{ij}^2$	Es un indicador de la homogeneidad local (Yuan <i>et al.</i> , 1991)

Varianza	$\sigma_i^2 = \sum_{ij=0}^{M-1} P_{ij} (i - \mu_i)^2$ $\sigma_j^2 = \sum_{ij=0}^{M-1} P_{ij} (i - \mu_j)^2$	Variabilidad de la respuesta espectral de los píxeles (Materka & Strzelecki, 1998)
Entropía	$\sum_{ij=0}^{M-1} P_{ij} (-\ln P_{ij})$	Medida estadística de la incertidumbre (Yuan <i>et al.</i> , 1991)

Donde  $P_{i,j}$ : Probabilidad de co-ocurrencia de los valores de gris  $i$  y  $j$ , para una distancia dada. Fuente: Hlatshwayo *et al.*, 2019.

Posteriormente, los valores de los píxeles se extrajeron utilizando la herramienta de estadística focal en ArcGIS 10.4.1 usando un kernel de 3 por 3 píxeles, calculando la media y la desviación de los píxeles para así disminuir el error de los datos obtenidos con el GPS. La utilidad de este método fue recomendada por Franklin *et al.* (1995), con el supuesto de que los valores de píxel representan un valor promedio de un área particular en el suelo.

### 3.3.2 Generación de modelos de regresión lineal

Los modelos de regresión lineal (LR) en combinación con funciones paramétricas se usaron para generar una relación entre los datos de percepción remota y los datos de AGB tomados en campo. LR puede expresarse como (Ec.4):

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n + \varepsilon$$

**Ecuación 4.** Modelo de regresión lineal.

Donde  $a_0$  es una constante,  $x_1, \dots, x_n$ , son las variables explicativas,  $a_1, a_2, \dots, a_n$ , son los coeficientes de regresión asociados con las variables correspondientes,  $y$  es el valor de la AGB obtenida de datos tomados en campo,  $n$  es el número de variables explicativas y  $\varepsilon$  es el término de error. Los modelos de regresión se generaron en el software libre RStudio (Versión 1.1.442), las variables explicativas  $x_1, \dots, x_n$  correspondieron individualmente a los índices espectrales,  $\sigma^\circ$  y texturas de SAR. Antes de la generación de estos modelos, se realizaron correlaciones lineales (correlación de Pearson) entre los valores de índices espectrales, retrodispersión y textura, y los valores de AGB obtenida en campo.

Para el análisis de los modelos de regresión, se evaluaron los coeficientes de determinación ( $R^2$ ) y los errores medios cuadráticos (EMC) de los modelos. Además, para examinar si hubo diferencias estadísticamente significativas entre los resultados estimados de diferentes modelos, se realizó un análisis de varianza (ANOVA) unidireccional al nivel  $p < 0.05$  con el uso de la prueba Duncan.

### 3.3.3 Estimación de AGB con el método Random Forest

En este estudio se usó el paquete RandomForest del software estadístico R para implementar la regresión RF en cada especie (*E. grandis* y *P. spp*). Primero se identificaron las variables importantes usando la función importancia de variables de RF. Se considera que una variable es importante en el modelo de bosque aleatorio si al omitirla de la lista de variables de predictor aumenta el error OOB (Liaw & Wiener, 2002). La importancia de las variables seleccionadas para el modelo de RF se cuantificó utilizando el porcentaje de aumento en el error cuadrático medio (IncMSE%). Las variables de predicción menos importantes se eliminan sucesivamente del modelo hasta que se minimiza el MSE de la predicción. La clasificación inicial de las variables (todas las variables predictoras) se usó en todas las iteraciones, y se seleccionó el subconjunto más pequeño de variables predictoras con el MSE más bajo para construir el modelo final. Los modelos resultantes del proceso de selección de variables se compararon con los modelos basados en el conjunto completo de datos de la variable predictora en términos de sus capacidades para predecir la AGB. En este estudio, se utilizaron inicialmente 500 árboles (ntree) para cada especie y para tres subconjuntos (datos Sentinel-2A, Sentinel 1A y combinación). Para el parámetro mtry (es decir, el número de variables a probar en cada nodo), se utilizó el número total de variables predictoras sobre 3 (Breiman, 2001). Los parámetros de RF (mtry y ntree) se optimizaron para obtener el mejor poder predictivo durante la regresión. Para seleccionar el mejor modelo para la estimación de AGB forestal de *E. grandis* y *P. spp*, se tuvo en cuenta el EMC más bajo.

### 3.3.4 Evaluación de los modelos de regresión

Para evaluar el rendimiento de los modelos, el conjunto de datos de *E. grandis* y *P. spp* ( $n = 67$  y  $n = 80$ , respectivamente) se dividió en 70% de entrenamiento ( $n = 47$  y  $n = 56$ ) y 30% de prueba ( $n = 20$  y  $n = 24$ ), y se implementó la técnica de validación cruzada para probar de manera sólida el rendimiento del algoritmo. El conjunto de datos de entrenamiento se utilizó para optimizar y entrenar el modelo y el conjunto de datos de prueba se usó para verificar la capacidad predictiva de cada modelo; el coeficiente de determinación ( $R^2$ ) (Ec. 7) y el valor p de la prueba F fueron calculados para determinar la significancia de los modelos construidos. El rendimiento de cada modelo en la estimación de la biomasa se examinó usando el error medio cuadrático (EMC) (Ec. 5), el error medio cuadrático relativo (EMCr) (Ec. 6), la prueba t para comparar medias, la prueba Wilcoxon de medianas y la prueba de comparación de distribuciones de Kolmogorov-Smirnov. En la validación cruzada se calculó el EMC y  $R^2$  a partir del conjunto de datos de prueba para medir la precisión del modelo.

$$EMC = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}}$$

**Ecuación 5.** Error medio cuadrático.

$$EMCr = \frac{EMC}{\bar{Y}} \times 100$$

**Ecuación 6.** Error medio cuadrático relativo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{Y})^2}$$

**Ecuación 7.** Coeficiente de determinación.

Donde  $\hat{y}_i$  y  $y_i$  son la biomasa estimada y observada para la trama  $i$ , respectivamente;  $n$  representa el número de predictores involucrados en la construcción del modelo;  $\bar{Y}$  es el valor medio observado de la biomasa. El modelo

con el EMC más bajo y el valor más alto de  $R^2$  se usó para predecir el AGB forestal. Estos criterios estadísticos se emplean ampliamente en la estimación de la AGB forestal para evaluar la diferencia entre los datos observados y los datos de AGB forestales estimados (Vafaei *et al.*, 2018).

### 3.3.5 Cálculo de AGB forestal

Después de comparar los resultados de la precisión del modelado y la validación cruzada, se determinó el modelo AGB óptimo para *E. grandis* y para *P. spp*, de forma individual. Finalmente, se mapeó el AGB forestal sobre cada lote usando el modelo AGB óptimo para cada especie con la interpolación Kriging. Los mapas resultantes fueron generados en el software RStudio. El interpolador Kriging, creado por el ingeniero en minas surafricano D.G. Krige, permite generar predicciones y superficies de respuesta requeridas, además de mapas de probabilidades (Johnston *et al.* 2001). El método Kriging cuantifica la estructura espacial de los datos mediante el uso de variogramas o semivariogramas (debido a su similitud en el cálculo), y los predice mediante la interpolación usando estadística (Oliver & Webster, 2014). Se asume que los datos más cercanos a un punto conocido tienen mayor peso o influencia sobre la interpolación, influencia que va disminuyendo conforme se aleja del punto de interés (Tobler, 2004).

## 4. Resultados

### 4.1 Índices espectrales, coeficientes y texturas

La Tabla 6 muestra los resultados de las correlaciones para cada variable utilizada para la formulación de modelos de regresión lineal donde se relacionaron los valores de AGB observada ( $t\cdot ha^{-1}$ ) con las bandas y los índices espectrales obtenidos a partir de las imágenes ópticas, para *E. grandis* y *P. spp*. En la Tabla 7 se muestran las relaciones lineales entre los coeficientes de retrodispersión y texturas, con los datos de AGB de *E. grandis* y *P. spp* tomados en campo.

**Tabla 6** Correlación entre AGB y bandas espectrales e índices espectrales.

Variable	<i>E. grandis</i>			<i>P. spp</i>		
	r	Min	Máx	r	Mín	Máx
B2	-0,294	0,054	0,094	-0,348	0,052	0,074
B3	-0,321	0,038	0,091	-0,210	0,039	0,072
B4	-0,265	0,022	0,118	-0,260	0,024	0,059
B5	-0,298	0,031	0,138	-0,127	0,035	0,088
B6	-0,021	0,092	0,230	0,097	0,087	0,197
B7	0,049	0,118	0,301	0,102	0,102	0,246
B8	0,031	0,112	0,298	0,142	0,102	0,239
B8A	0,004	0,127	0,334	0,097	0,118	0,275
B11	-0,308	0,035	0,312	-0,162	0,047	0,183
B12	-0,314	0,013	0,177	-0,200	0,022	0,091
GNDVI <sub>RE3N</sub>	0,290	0,352	0,720	0,184	0,287	0,609
GNDVI	0,284	0,364	0,720	0,257	0,264	0,603
NDVI	0,288	0,386	0,818	0,162	0,299	0,755
SAVI	0,185	0,160	0,486	0,059	0,100	0,393

**Tabla 7.** Correlación entre AGB y datos SAR.

	Variable	<i>E. grandis</i>	<i>P. spp</i>
		r	r
$\sigma^\circ$	VH	<b>-0,203</b>	<b>0,137</b>
	VV	-0,138	0,067
Polarización VH	ASM	0,077	-0,160
	Contraste	-0,105	0,006
	Disimilitud	-0,083	0,045
	Entropía	-0,115	0,149
	<b>Correlación</b>	<b>-0,314</b>	<b>0,234</b>
	Media	-0,255	0,145
	Varianza	-0,227	0,111
	Homogeneidad	-0,008	-0,147
Polarización VV	ASM	-0,149	-0,187
	Contraste	0,193	0,151
	Disimilitud	0,194	0,179
	Entropía	0,128	<b>0,197</b>
	<b>Correlación</b>	<b>-0,493</b>	0,189
	Media	-0,362	0,140
	Varianza	-0,315	0,129
	Homogeneidad	-0,217	-0,166

Donde  $\sigma^\circ$ =Coeficiente de retrodispersión; ASM = Segundo Momento Angular

Se encontró que la biomasa aérea de *E. grandis* y *P. spp* presenta una relación lineal negativa con las bandas espectrales del espectro visible (430 a 700 nm), donde B3 mostró la mayor relación con *E. grandis* ( $r = -0,321$ ) y B2 con *P. spp* ( $r = -0,348$ ) (Tabla 6 y Figura 9); también se encontró que la banda 12 (infrarrojo medio), obtuvo una relación de -0.314 y -0,2 para *E. grandis* y *P. spp*, respectivamente. Además, se encontró una relación positiva con la AGB de *E. grandis* y los índices estudiados, donde mostró la mayor relación con GNDVI<sub>re3n</sub> ( $r = 0,29$ ). Con respecto a los datos SAR, se encontró una baja relación entre la biomasa aérea y los coeficientes de retrodispersión (Tabla 7 y Figura 10). La textura correlación mostró un r de -0,314 para *E. grandis* y 0,234 para *P. spp*, mayor en la polarización VH. A pesar de que el coeficiente de retrodispersión de VV generó una relación muy baja con la biomasa aérea, las textura Entropía mostró un  $r = 0,493$  para *E. grandis* y la textura Entropía con un  $r = -0,197$  para *P. spp*.

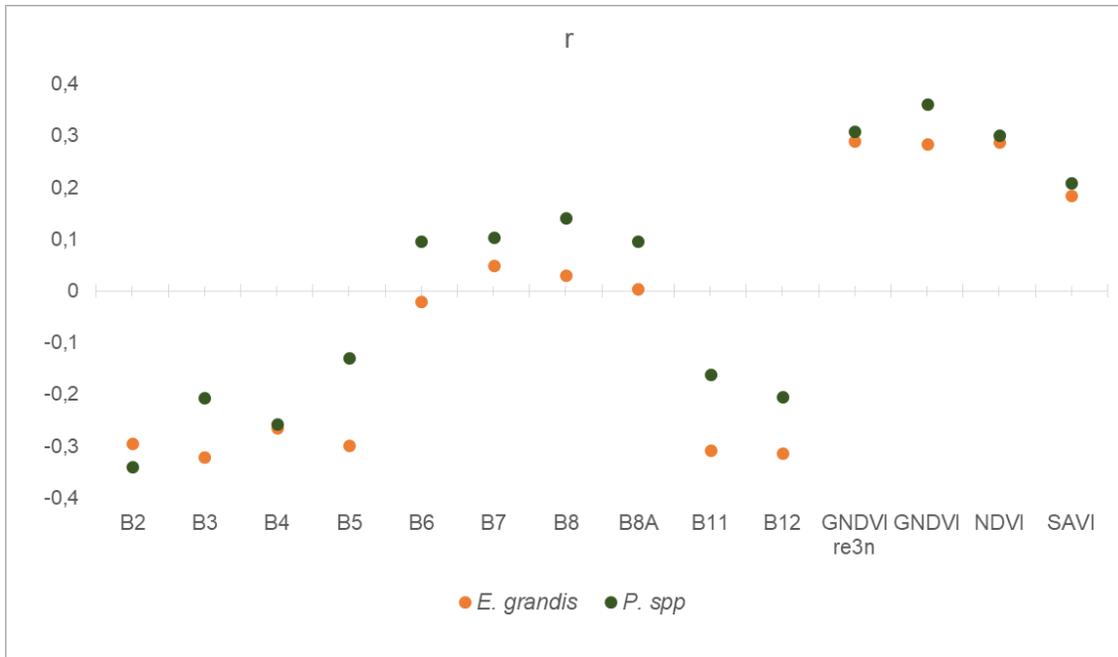


Figura 9. Correlación entre AGB y datos ópticos.

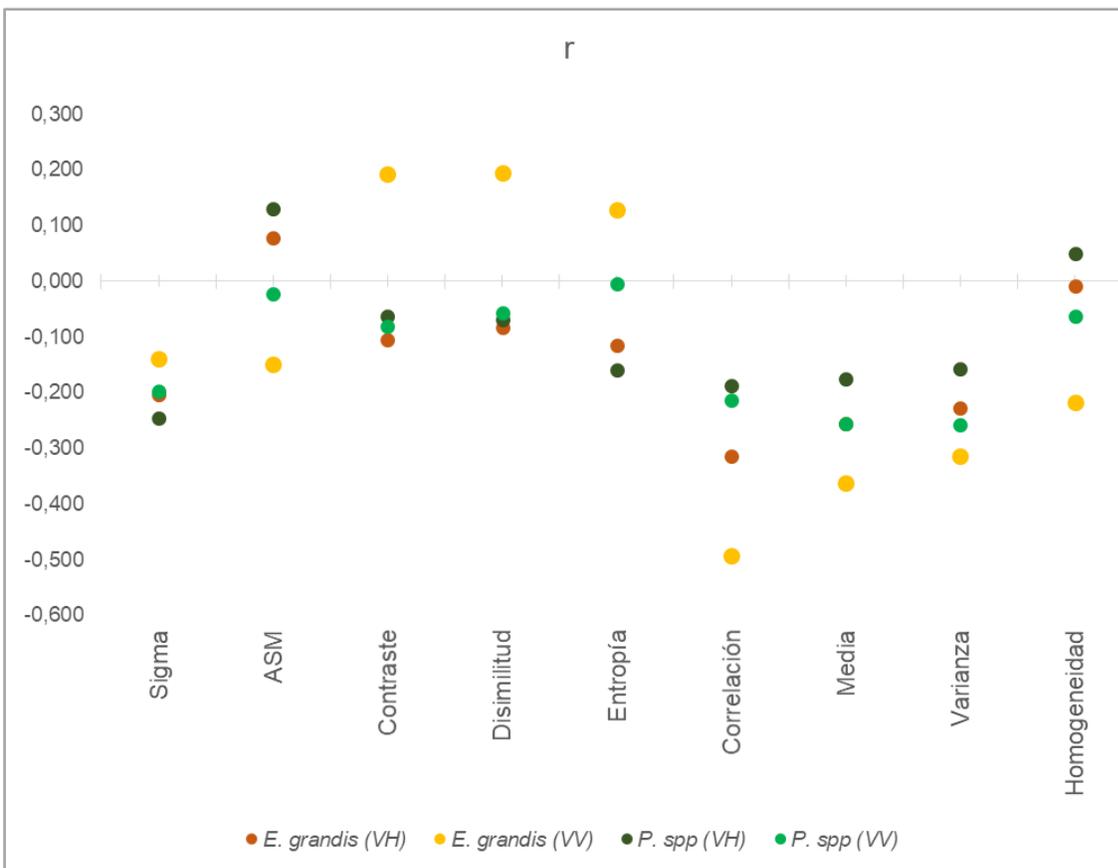


Figura 10. Correlación entre AGB y datos SAR.

## 4.2 Generación de modelos de regresión lineal a partir de los parámetros obtenidos

Los modelos generados a partir de índices espectrales mostraron una relación significativa (valor  $p < 0,05$ ), para la estimación de AGB (Tabla 8), siendo el modelo que mostró un mejor ajuste para *E. grandis*, el índice  $GNDVI_{RE3N}$  con un  $R^2$  de 22,7%. Los modelos de regresión lineal generados a partir de datos SAR mostraron un bajo poder predictivo (Tabla 9), donde solo las texturas Correlación de la polarización VH, Correlación, Media y Varianza de la polarización VV presentaron un nivel de confianza del 95%. En los anexos D y E se encuentran los índices de vegetación y datos de radar, respectivamente, usados para la generación de los modelos de regresión para la estimación de AGB en *E. grandis*.

**Tabla 8.** Modelos de regresión lineal basados en las estimaciones de AGB de *E. grandis* a partir de los índices de vegetación.

Índice espectral	Modelo	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )	Prueba F (Valor p)
<b>GNDVI<sub>RE3N</sub></b>	6,021 + 1,729 Ln (x)	<b>0,227</b>	0,056	0,0007
GNDVI	5,763 + 1,087 Ln (x)	0,139	0,063	0,0096
NDVI	97,009 + 186,485x <sup>2</sup>	0,125	2.262,93	0,0147
SAVI	5,673 + 0,428 Ln (x)	0,060	0,069	0,0961

Donde x=Índice espectral

**Tabla 9.** Modelos de regresión lineal basados en las estimaciones de AGB de *E. grandis* a partir de texturas.

	Variable	Modelo	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )	Prueba F (Valor p)
$\sigma^\circ$	<b>VH</b>	158,89 - 3,250 (x)	0,045	2143,5	0,156
	<b>VV</b>	181,463 - 2,523 (x)	0,031	2175,1	0,242
Polarización VH	ASM	140,41 - 5,063 (x)	0,023	2193,89	0,318
	Contraste	219,056 - 0,684 (x)	0,030	2237,93	0,718
	Disimilitud	227 - 2,023 (x)	0,070	2228,86	0,579
	Entropía	355,579 - 17,695 (x)	0,021	2197,55	0,336
	<b>Correlación</b>	176,657 - 16,845 (x)	<b>0,138</b>	1933,08	<b>0,010</b>
	Media	269,019 - 5,062 (x)	0,069	2089,24	0,077
	Varianza	260,622 - 2,358 (x)	0,050	2132,67	0,135
Polarización VV	Homogeneidad	211,538 + 1,292 (x)	0,003	2237,17	0,703
	ASM	189,889 - 1,917 (x)	0,052	2127,09	0,126
	Contraste	179,534 + 1,269 (x)	0,045	2143,84	0,157
	Disimilitud	182,534 + 2,269 (x)	0,050	2131,47	0,133
	Entropía	187,209 + 2,682 (x)	0,042	2150,22	0,171
	<b>Correlación</b>	188,365 - 29,741 (x)	<b>0,169</b>	1865,25	<b>0,004</b>

<b>Media</b>	451,185 - 14,733 (x)	<b>0,111</b>	1996,42	<b>0,023</b>
<b>Varianza</b>	467,249 - 8,494 (x)	<b>0,089</b>	2043,48	<b>0,043</b>
Homogeneidad	193,967 - 3,319 (x)	0,065	2098,06	0,086

Donde x = textura

De acuerdo con la Tabla 10, los modelos generados a partir de índices espectrales para la estimación de AGB de *P. spp* mostraron un poder predictivo significativo, donde GNDVI generó un R<sup>2</sup> de 17,4%. Los modelos generados a partir de datos SAR VH y VV mostraron significancia para la estimación de AGB de *P. spp* (valor p < 0,05) (Tabla 11). En los anexos F y G se encuentran los índices de vegetación y datos de radar, respectivamente, usados para la generación de los modelos de regresión para la estimación de AGB en *P. spp*.

**Tabla 10.** Modelos de regresión lineal basados en las estimaciones de AGB de *P. spp* a partir de los índices de vegetación.

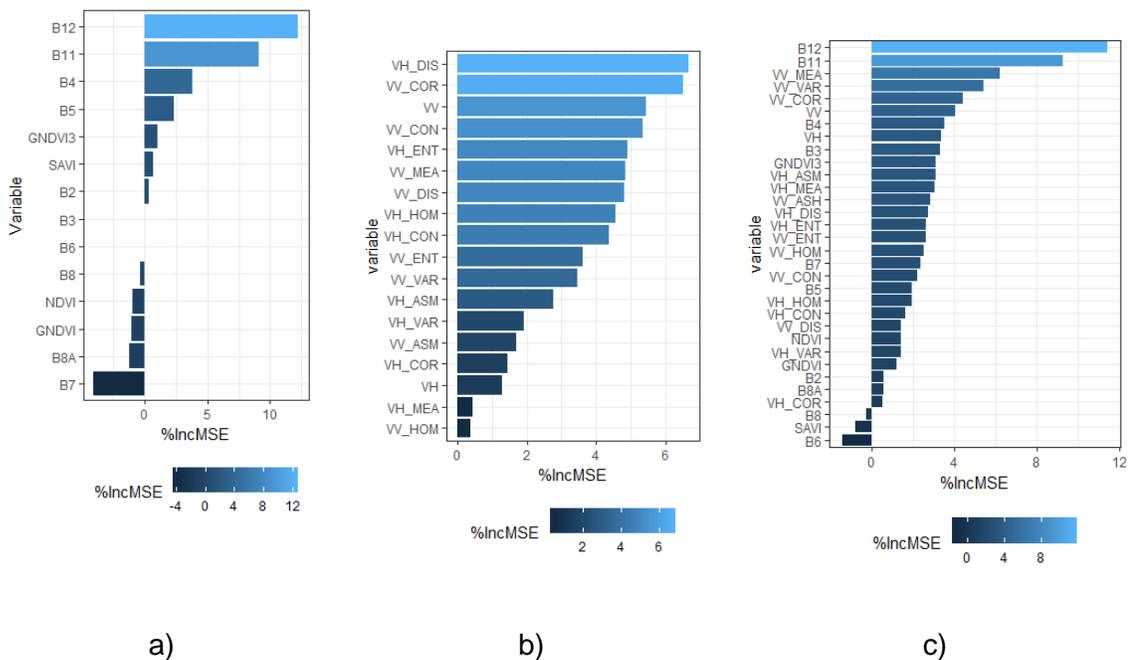
Índice espectral	Modelo	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )	Prueba F (Valor p)
GNDVI <sub>RE3N</sub>	6,706 + 0,915 Ln (x)	0,138	0,096	0,005
<b>GNDVI</b>	6,748 + 0,955 Ln (x)	<b>0,174</b>	0,092	0,001
NDVI	6,444 + 0,759 Ln (x)	0,134	0,096	0,005
SAVI	6,600 + 0,369 Ln (x)	0,083	0,102	0,031

**Tabla 11.** Modelos de regresión lineal para la estimación de AGB de *P. spp* a partir de texturas.

	Variable	Modelo	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )	Prueba F (Valor p)
σ°	VH	244,554 - 16,073 (x)	0,074	24279,6	0,045
	VV	348,002 - 13,417 (x)	0,070	26170,9	0,048
polarización VH	ASM	690,264 + 16,848 (x)	0,034	27192,0	0,179
	Contraste	341,424 + 7,34976 (x)	0,057	26548,7	0,076
	Disimilitud	343,639 + 13,5076 (x)	0,027	27395,5	0,227
	Entropía	79,3468 + 47,7933 (x)	0,013	27774,9	0,395
	<b>Correlación</b>	390,623 - 58,8368 (x)	<b>0,109</b>	25067,3	<b>0,013</b>
	Media	735,164 - 19,9104 (x)	0,066	26287,1	0,055
	Varianza	728,319 - 10,3282 (x)	0,057	26533,6	0,075
	Homogeneidad	531,543 + 8,39147 (x)	0,013	27784,0	0,401
polarización VV	ASM	426,614 - 6,79961 (x)	0,032	27239,2	0,184
	Contraste	344,683 + 6,66532 (x)	0,022	27521,4	0,271
	Disimilitud	333,611 + 13,8144 (x)	0,046	26845,8	0,111
	Entropía	285,661 + 25,7792 (x)	0,039	27065,0	0,146
	<b>Correlación</b>	425,111 - 90,6019 (x)	<b>0,147</b>	24022,0	<b>0,004</b>
	<b>Media</b>	966,572 - 29,7153 (x)	<b>0,089</b>	25634,0	<b>0,025</b>
	<b>Varianza</b>	949,155 - 15,5399 (x)	<b>0,079</b>	25936,6	<b>0,036</b>
	Homogeneidad	436,22 - 13,1144 (x)	0,058	26521,0	0,074

### 4.3 Random Forest

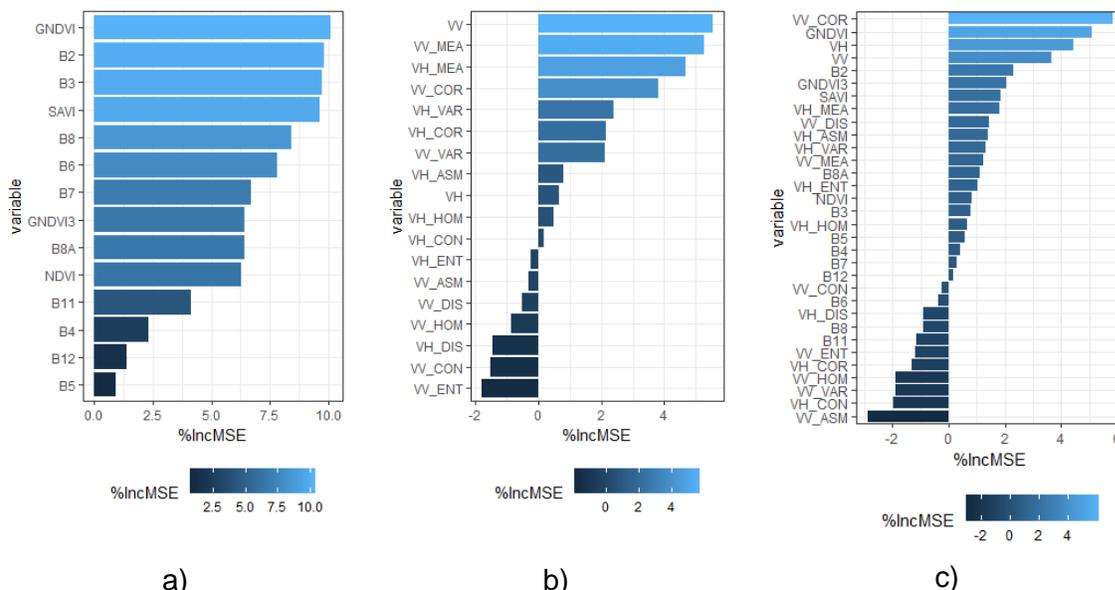
Las variables derivadas de los datos Sentinel-2A más influyentes en la estimación de AGB fueron las bandas SWIR (B11 y B12) para *E. grandis*; respecto a Sentinel-1A, se encontró que las variables más importantes para la construcción del modelo fueron disimilitud<sub>VH</sub>, correlación<sub>VV</sub> y  $\sigma^{\circ}$ <sub>VV</sub> (Figura 11). Al combinar los datos ópticos con SAR, se encontró que las variables más influyentes en el comportamiento de AGB de *E. grandis* fueron las bandas SWIR y las texturas Media, Varianza y Correlación de la polarización VV. En el Anexo H se encuentran los valores de importancia de las variables para la estimación de AGB de *E. grandis*.



**Figura 11.** Reducción de EMC para *E. grandis*. a). Datos ópticos; b). Datos SAR; c). Combinación.

Para *P. spp* se encontró que GNDVI y las bandas B2 y B3 fueron las variables más importantes para la estimación de AGB (Figura 12-a). En la Figura 12-b se observa que las variables  $\sigma^{\circ}$ , media y correlación de la polarización VV influyeron en la estimación de AGB de *P. spp*. La combinación de los datos ópticos y SAR mostró

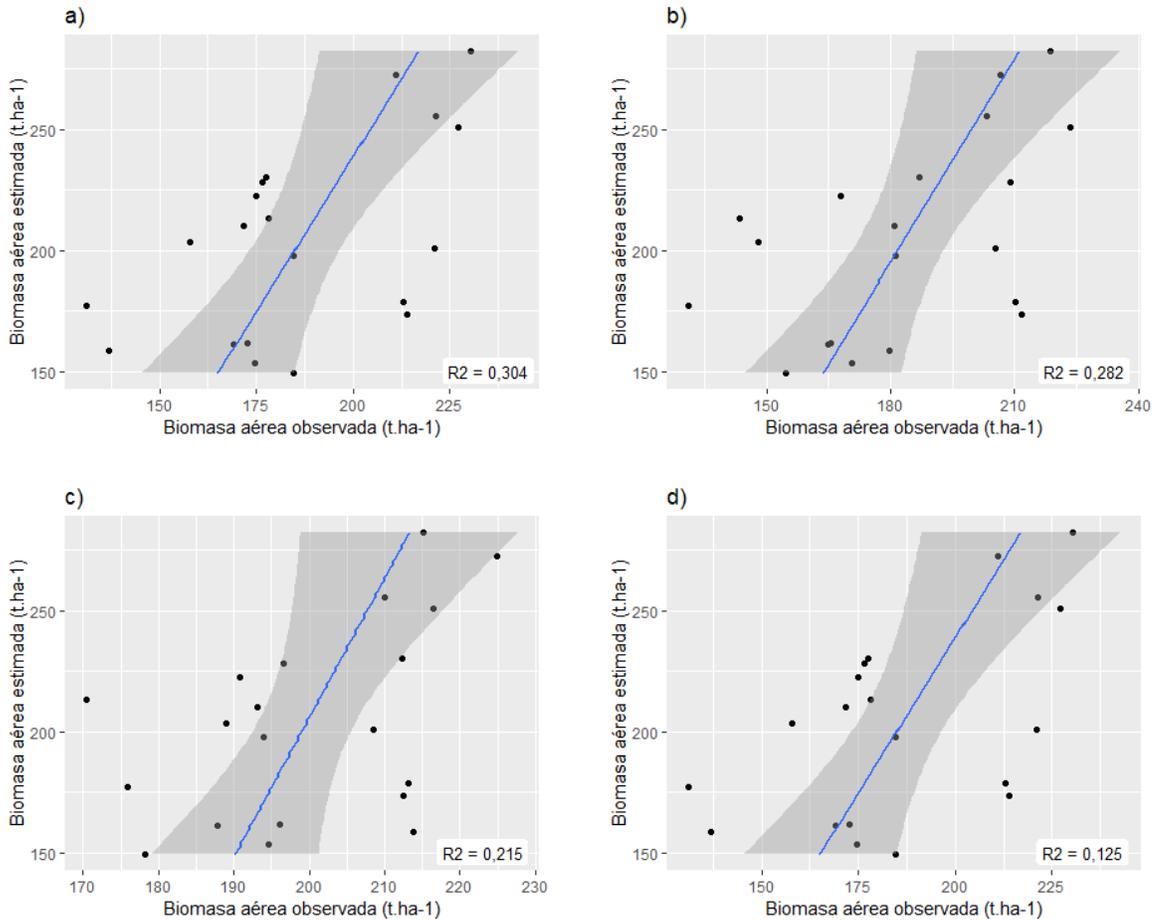
que las variables más influyentes en el comportamiento de AGB de *P. spp* fueron las variables Correlación ( $\sigma^{\circ}$ ),  $\sigma^{\circ}$ (VH),  $\sigma^{\circ}$ (VV) GNDVI y B2 (Figura 12-c). En el Anexo I se encuentran los valores de importancia de las variables para la estimación de AGB de *P. spp*.



**Figura 12.** Reducción de EMC para *P. spp*. a). Datos ópticos; b). Datos SAR; c) Combinación.

## 4.4 Evaluación de los modelos de regresión usados

De acuerdo con la figura 13, se puede observar que existe relación entre los índices espectrales y los datos de AGB de *E. grandis* tomados en campo. La AGB estimada a partir del índice  $GNDVI_{re3n}$  generó un  $R^2 = 30,4\%$  con respecto a la AGB observada en campo. En el Anexo J se encuentran los datos de validación generados para *E. grandis*.



**Figura 13.** Relación entre valores observados y valores estimados de biomasa aérea forestal de *E. grandis* con índices espectrales. a). GNDVI<sub>re3n</sub>; b). GNDVI; c). NDVI y d). SAVI

Se encontró que todos los modelos arrojaron un valor  $p$  mayor al nivel de significancia ( $\alpha = 0,05$ ), lo que indica que cualquier índice tiene la capacidad de estimar la biomasa aérea de *E. grandis*, tanto ópticos como SAR. El rango de EMC oscila entre  $35 \text{ t.ha}^{-1}$  y  $39,8 \text{ t.ha}^{-1}$ , donde GNDVI<sub>re3n</sub> arrojó el menor valor y SAVI el mayor (Tabla 12). No se encontraron diferencias significativas entre los valores medios, medianas y distribuciones de la AGB de *E. grandis* tomados en campo y los estimados con los datos ópticos (prueba  $t$ , prueba Wilcoxon y prueba Kolmogorov-Smirnov); la prueba  $F$  mostró que las varianzas de los datos estimados de AGB de *E. grandis* basados en los índices GNDVI<sub>re3n</sub> y GNDVI no mostraron diferencias significativas con respecto a los datos obtenidos en campo. Además,

se encontró que los índices NDVI y SAVI muestran diferencias significativas entre las varianzas de los datos de AGB estimados y los obtenidos en campo, esto con un nivel de confianza del 95%. En la Tabla 13 se puede observar que la AGB estimada con datos SAR no muestra diferencias significativas con la AGB de *E. grandis* observada en campo, de acuerdo con la prueba t y la prueba Wilcoxon de medianas; sin embargo, se encontró que, de acuerdo con la prueba F, la AGB estimada a partir de la textura Correlación de la polarización VV no muestra diferencias significativas con los datos tomados en campo. Los datos de AGB estimados a partir de la polarización VV y la textura Correlación de esta polarización presentaron una distribución estadísticamente igual a los obtenidos en campo. En la Figura 14 se observa la distribución de AGB estimada a partir de  $GNDVI_{re3n}$  para *E. grandis*.

**Tabla 12.** Pruebas de validación en datos de AGB de *E. grandis* con índices espectrales.

Índice espectral	EMC (t.ha <sup>-1</sup> )	EMCr (%)	Prueba t (Valor p)	Prueba F (Valor p)	Prueba W (Valor p)	Prueba K-S (Valor p)
<b>GNDVI<sub>RE3N</sub></b>	<b>37,87</b>	<b>18,56</b>	<b>0,12</b>	<b>0,14</b>	0,25	0,25
GNDVI	39,81	19,51	0,06	<b>0,08</b>	0,15	0,33
NDVI	<b>35,44</b>	<b>17,37</b>	0,65	0,00	0,86	0,33
SAVI	39,02	19,12	0,20	0,00	0,44	0,03

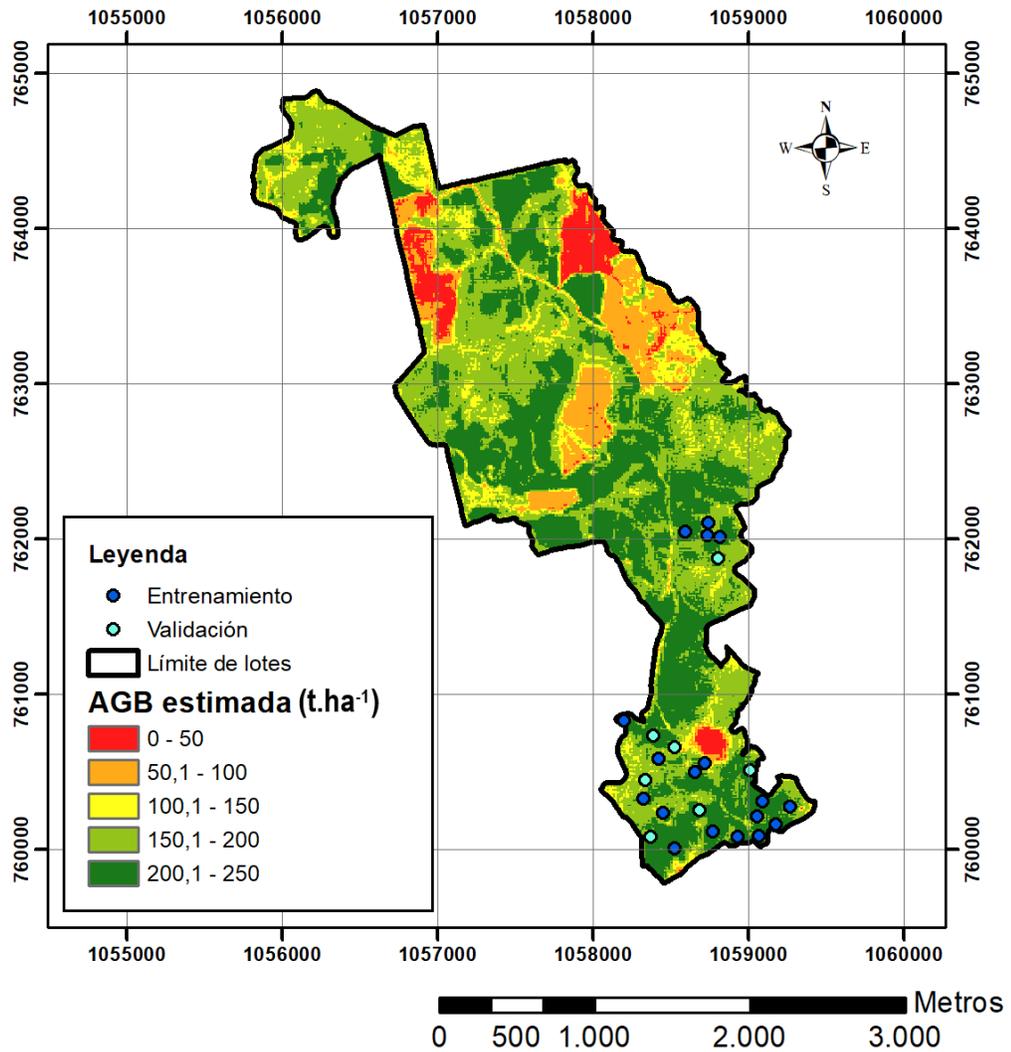
Nivel de significancia de 0,05; W: Wilcoxon; K-S: Kolmogorov-Smirnov

**Tabla 13.** Validación para texturas y AGB de *E. grandis*.

Variable	Emc (t.ha <sup>-1</sup> )	Emcr (%)	Prueba t (Valor p)	Prueba F (Valor p)	Prueba W (Valor p)	Prueba K-S (Valor p)	
$\sigma^\circ$	VH	40,54	19,96	0,65	0,000	0,50	0,07
	VV	39,70	19,54	0,78	0,000	0,52	0,07
VH	ASM	43,89	21,61	0,60	0,000	0,88	0,07
	Contraste	39,98	19,68	0,77	0,000	0,48	0,03
	Disimilitud	39,94	19,67	0,73	0,000	0,45	0,07
	Entropía	39,32	19,36	0,67	0,000	0,48	0,07
	<b>Correlación</b>	<b>32,89</b>	<b>16,19</b>	0,86	0,006	0,54	<b>0,15</b>
	Media	41,82	20,59	0,69	0,000	0,48	0,07
	Varianza	41,15	20,26	0,68	0,000	0,54	0,07
	Homogeneidad	39,82	19,60	0,80	0,000	0,52	0,03
VV	ASM	42,32	20,83	0,95	0,000	0,45	0,07
	Contraste	42,99	21,16	0,75	0,000	0,86	0,30
	Disimilitud	43,87	21,60	0,75	0,000	0,86	0,30
	Entropía	41,32	20,34	0,91	0,000	0,58	0,07

<b>Correlación</b>	<b>30,87</b>	<b>15,20</b>	<b>0,55</b>	<b>0,058</b>	<b>0,54</b>	<b>0,42</b>
Media	41,60	20,48	0,65	0,012	0,48	0,15
Varianza	41,91	20,63	0,69	0,000	0,54	0,07
Homogeneidad	40,98	20,17	0,87	0,000	0,52	0,07

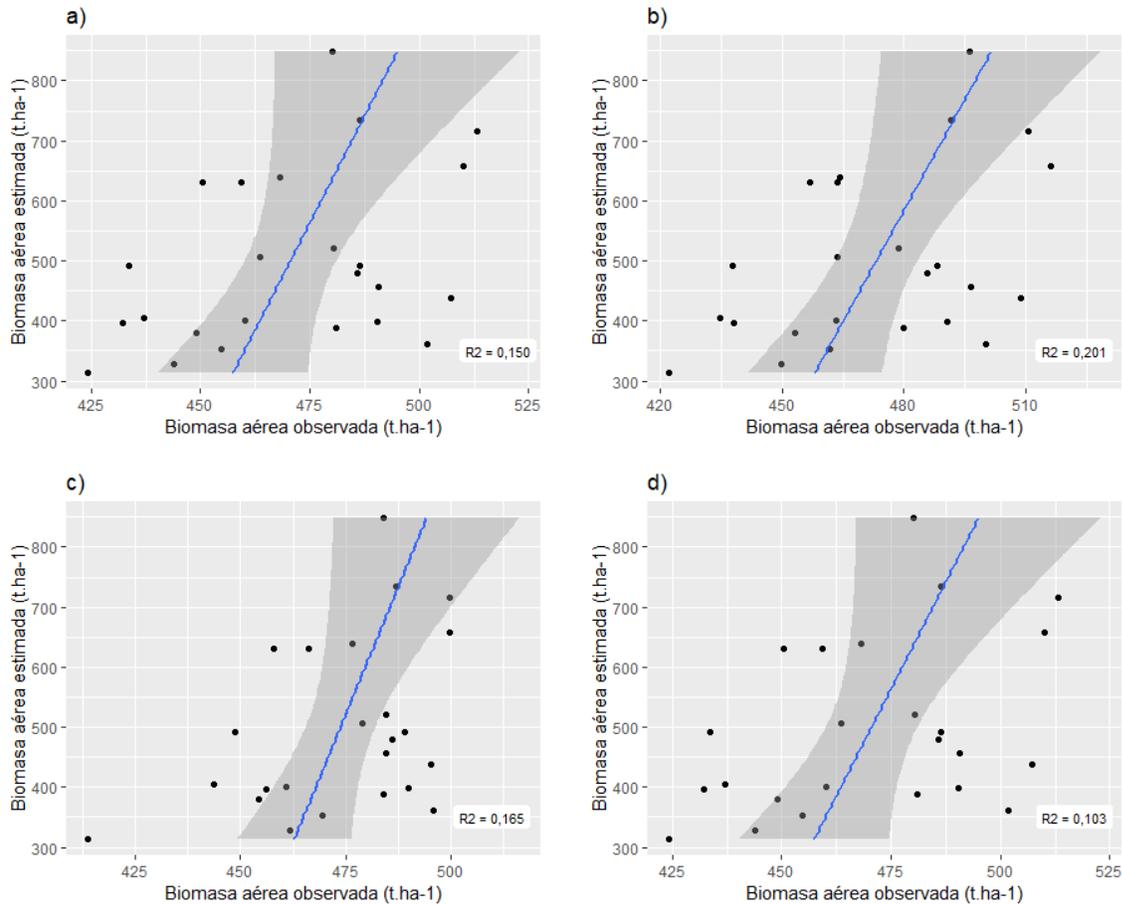
Nivel de significancia de 0,05; W: Wilcoxon; K-S: Kolmogorov-Smirnov



**Figura 14.** AGB de *E. grandis* generada de los modelos de regresión en el área de estudio.

De acuerdo con la figura 15, se puede observar la relación entre la AGB estimada y la observada para *P. spp* y de acuerdo con el coeficiente de determinación, la AGB estimada a partir de GNDVI presentó el poder predictivo más alto ( $R^2 = 0.201$ ). Al validar los modelos generados a partir de índices espectrales, se encontró que

GNDVI alcanzó un EMC = 124,84 t.ha<sup>-1</sup> (Tabla 14). De acuerdo con las pruebas F y Kolmogorov-Smirnov, se encontró que los datos estimados de AGB y los obtenidos en campo tienen varianzas y distribuciones significativamente diferentes, a pesar de tener valores medios y medianas estadísticamente iguales.



**Figura 15.** Relación entre valores observados y valores estimados de biomasa aérea forestal de *P. spp* con índices espectrales. a). GNDVI<sub>re3n</sub>; b). GNDVI; c). NDVI y d). SAVI

**Tabla 14.** Pruebas de validación para índices espectrales en *P. spp*.

Índice espectral	EMC (t.ha <sup>-1</sup> )	EMC <sub>r</sub> (%)	Prueba t (Valor p)	Prueba F (Valor p)	Prueba W (Valor p)	Prueba K-S (Valor p)
GNDVI <sub>RE3N</sub>	127,28	25,52	0,37	6x10 <sup>-12</sup>	0,78	0,03
<b>GNDVI</b>	<b>124,84</b>	25,03	0,41	5,7x10 <sup>-12</sup>	0,67	0,03
NDVI	127,23	25,51	0,41	0	0,78	0,03
SAVI	130,88	26,24	0,34	5,4x10 <sup>-12</sup>	0,80	0,03

Nivel de significancia de 0,05; W: Wilcoxon; K-S: Kolmogorov-Smirnov

De acuerdo con la Tabla 15, no hay evidencia suficiente para afirmar que existe diferencia entre los valores medios y medianas de la AGB estimada en relación a los datos obtenidos en campo para *P. spp.*, (valor  $p > 0,05$ ); sin embargo, se evidencia que los datos de AGB estimados a partir de Sentinel-1 son diferentes a los obtenidos en campo, dado que mostraron varianzas significativamente diferentes. Los datos de AGB para *P. spp.* estimados a partir de las texturas Media y Correlación de las polarizaciones VH y VV, mostraron distribuciones estadísticamente iguales a los obtenidos en campo (prueba Kolmogorov-Smirnov). En la Figura 16 se observa la distribución de AGB generada a partir del GNDVI. En el Anexo K se encuentran los datos de validación generados para *P. spp.*

**Tabla 15.** Pruebas de validación para texturas en *P. spp.*

	Variable	EMC (t.ha <sup>-1</sup> )	EMC <sub>r</sub> (%)	Prueba t (Valor p)	Prueba F (Valor p)	Prueba W (Valor p)	Prueba K-S (Valor p)
$\sigma^\circ$	VH	134,27	26,92	0,28	0,000	0,88	0,03
	VV	135,02	27,07	0,58	0,000	0,48	0,03
VH	ASM	142,04	28,48	0,64	0,000	0,46	0,00
	Contraste	149,62	30,00	0,70	0,000	0,39	0,01
	Disimilitud	147,61	29,60	0,64	0,000	0,45	0,01
	Entropía	143,38	28,75	0,75	0,000	0,39	0,00
	Correlación	140,49	28,17	0,13	0,000	0,80	<b>0,07</b>
	<b>Media</b>	<b>131,01</b>	<b>26,27</b>	0,39	0,000	0,69	<b>0,07</b>
	Varianza	132,59	26,59	0,51	0,000	0,58	0,03
	Homogeneidad	139,51	27,98	0,65	0,000	0,45	0,01
VV	ASM	133,24	26,72	0,93	0,000	0,24	0,01
	Contraste	134,44	26,96	0,70	0,000	0,42	0,03
	Disimilitud	132,26	26,52	0,65	0,000	0,45	0,03
	Entropía	133,97	26,86	0,86	0,000	0,29	0,03
	<b>Correlación</b>	<b>129,35</b>	<b>25,94</b>	0,21	0,000	0,91	<b>0,07</b>
	Media	130,95	26,26	0,44	0,000	0,66	<b>0,07</b>
	Varianza	134,46	26,96	0,52	0,000	0,58	0,01
	Homogeneidad	131,55	26,38	0,85	0,000	0,29	0,03

Nivel de significancia de 0,05; W: Wilcoxon; K-S: Kolmogorov-Smirnov

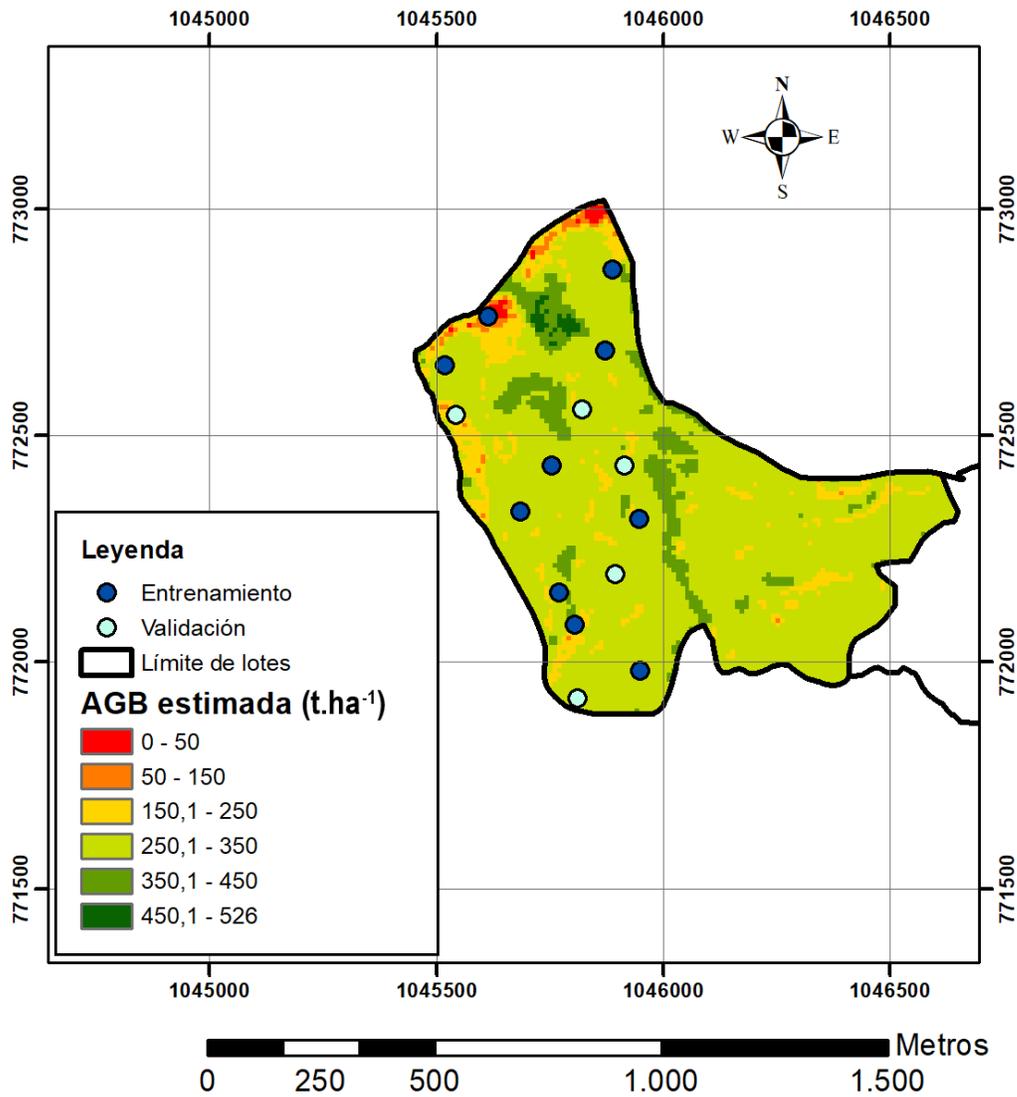


Figura 16. AGB de *P. spp* generada de los modelos de regresión en el área de estudio.

#### 4.5 Modelo final y mapa AGB forestal

Los resultados de la estimación de AGB para *E. grandis*, utilizando el modelo de RF para el conjunto de datos Sentinel-2A, Sentinel-1A y su combinación, se muestran en la Tabla 16. De acuerdo con los  $R^2$  generados para cada grupo de datos, se observó que las imágenes de Sentinel-1 tuvieron una relación muy débil con la estimación de AGB. Sin embargo, al combinar los datos ópticos con los datos SAR se mejoró la capacidad predictiva para la estimación de AGB ( $R^2 = 0.273$ ).

**Tabla 16.** Resultados del modelado de AGB para *E. grandis* usando RF.

Datos	Datos de entrenamiento		Datos de validación	
	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )
Sentinel-2	0,136	461.00	0,134	438.67
Sentinel-1	-0,117	725.37	-0,103	756.08
<b>Sentinel-2 + Sentinel-1</b>	<b>0,273</b>	<b>346.62</b>	<b>0,256</b>	<b>392.23</b>

El modelo generado con el método RF para estimar AGB de *E. grandis* fue:

$$\text{AGB}_{(E. grandis)} = 711,18 - 3.247,65 * B12 - 283,2 * B11 - 428,36 * \text{Media}(VV) + 218,92 * \text{Varianza}(VV) + 120,84 * \text{Correlación}(VV) + 5.784 * \sigma^{\circ}(VV) + 2,03 * \text{Disimilitud}(VV) - 346,81 * B5 - 2.469,49 * B3 - 4,36 * \sigma^{\circ}(VH) + 6.820,57 * B4$$

De acuerdo con la Tabla 17, se encontró que los datos ópticos generaron EMC más bajos que los demás datos (3.102 t.ha<sup>-1</sup>); sin embargo, la combinación de estos datos con SAR aumentó significativamente el coeficiente de determinación del modelo (R<sup>2</sup> = 0,358).

**Tabla 17.** Resultados del modelado de AGB para *P. spp* usando RF.

Datos	Datos de entrenamiento		Datos de validación	
	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )	R <sup>2</sup>	EMC (t.ha <sup>-1</sup> )
Sentinel-2	0,183	3.102,52	0,138	2.803,45
Sentinel-1	-0,724	9.509,21	-0,516	8.930,66
<b>Sentinel-2 + Sentinel-1</b>	<b>0,358</b>	<b>9.025,05</b>	<b>0,281</b>	<b>9.370,30</b>

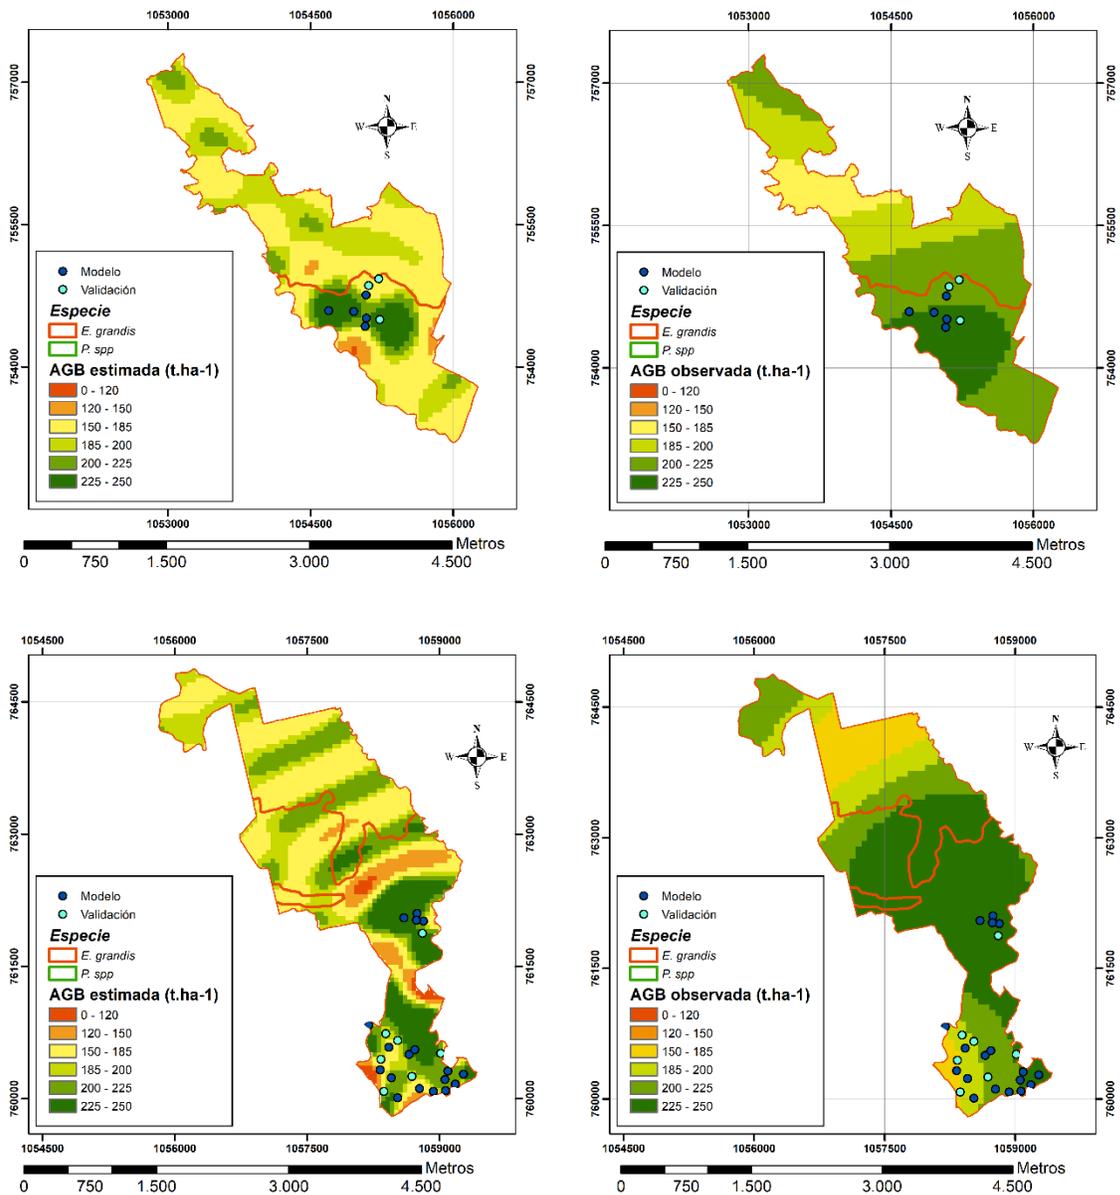
El modelo generado con el método RF para estimar AGB de *P. spp* fue:

$$\text{AGB}_{(P. spp)} = 923,70 - 50,07 * \text{Correlación}(VV) + 3.844,82 * \text{GNDVI} - 21,981 * \sigma^{\circ}(VH) + 6,062 * \sigma^{\circ}VV - 16.530,99 * B2 - 4.830,88 * \text{GNDVI}3 + 2.197,27 * \text{SAVI} + 17,13 * \text{Media}(VH)$$

En la Tabla 18 se presentan los datos de los variogramas para AGB forestal estimada para *E. grandis* y *P. spp*. A partir de los variogramas se generaron los mapas de distribución de AGB para *E. grandis* y *P. spp* (Figuras 17 y 18, respectivamente).

**Tabla 18.** Parámetros de los variogramas de kriging para AGB.

Especie	Estimación	Variograma	Pepita (Co)	Meseta parcial (C)	Rango
<i>E. grandis</i>	Kriging	Wave	50,0	437,87	162,81
<i>P. spp</i>	Kriging	Wave	2.995,8	3.787,73	204,65


**Figura 17.** Distribución de AGB de *E. grandis* estimada vs. AGB obtenida en campo.

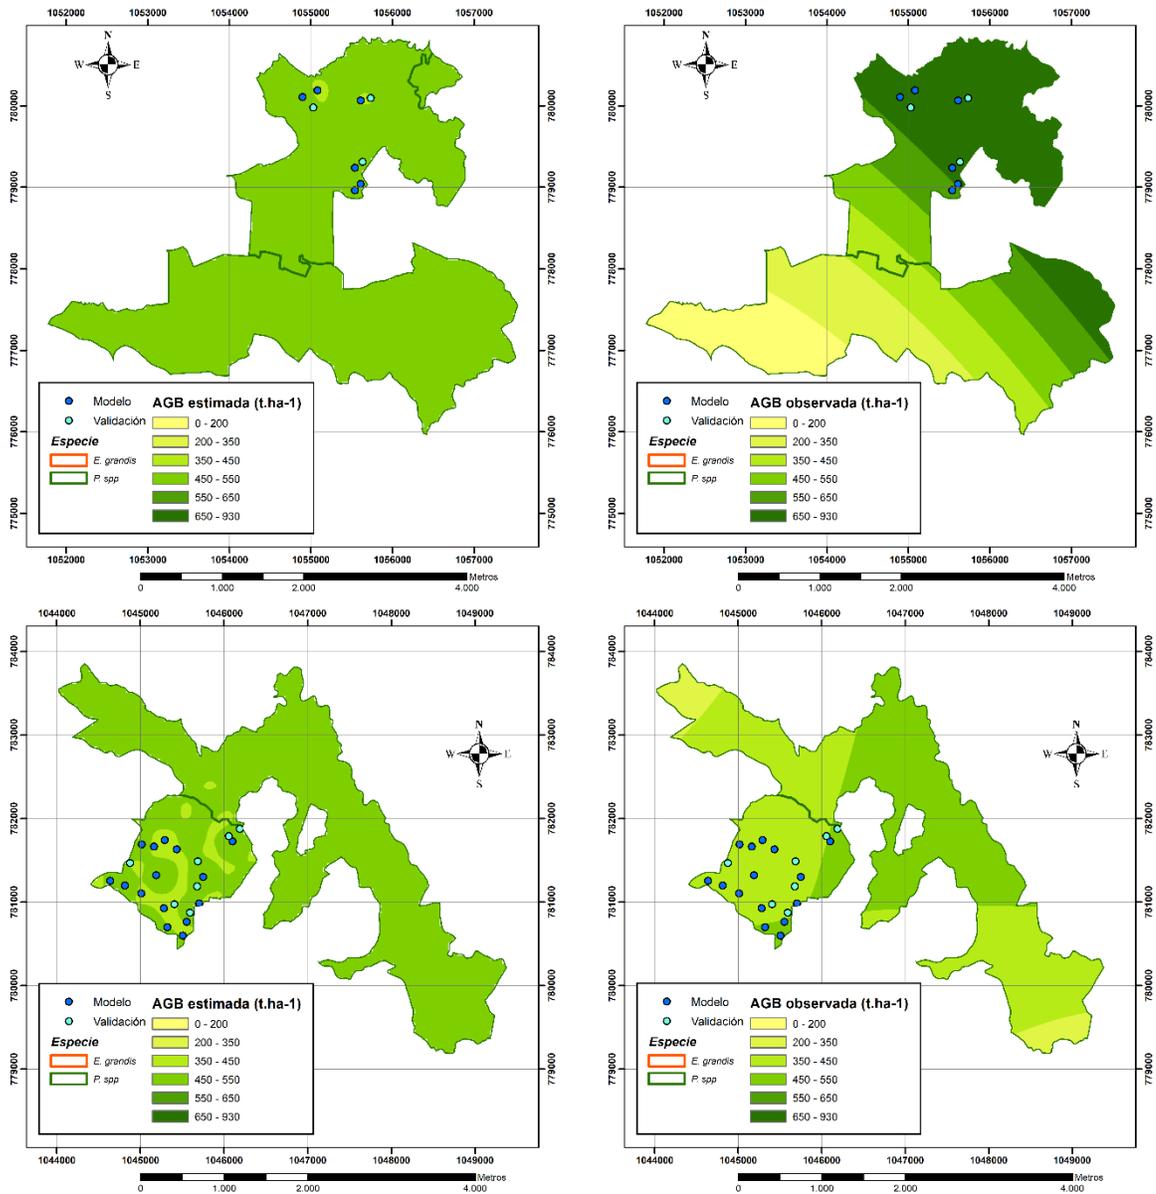


Figura 18. Distribución de AGB de *P. spp.* estimada vs. AGB obtenida en campo.



## 5. Discusión

### 5.1 Índices espectrales y coeficientes de retrodispersión asociados al contenido de biomasa aérea forestal.

En este estudio se encontró una relación lineal entre las bandas espectrales Sentinel-2 MSI y AGB para *E. grandis* y *P. spp*, con unos coeficientes de correlación que varían entre -0,321 y 0,049 para *E. grandis* y entre -0,348 a 0,142 para *P. spp* en las bandas espectrales. En otros estudios se ha establecido que existe una relación entre esta región del espectro con el contenido de biomasa aérea (Lu *et al.*, 2016). La región espectral óptica de los datos Sentinel-2A seleccionada en la presente investigación está relacionada con el contenido de clorofila y, por lo tanto, con la actividad fotosintética y condiciones de salud (Laurin *et al.*, 2018). Las bandas correspondientes al infrarrojo medio SWIR (B11 y B12), dominaron la lista de bandas mayormente correlacionadas debido a las características de la cobertura vegetal, la lignina de las hojas, la celulosa, el almidón y las proteínas, lo que resulta en una menor reflectancia y transmitancia (Asner & Lobell, 2000). Sin embargo, se encontró que hay mayor correlación entre SWIR y la AGB de *E. grandis*, comparada con *P. spp*. Lukeš *et al.* (2013), encontraron que la reflectancia de SWIR en las acículas de las coníferas en los bosques boreales de Finlandia es baja en comparación con las latifoliadas. Estos resultados pueden deberse a que la región SWIR es más sensible a la humedad y a la sombra, componentes inherentes a la estructura del bosque (Gao *et al.*, 2018), y además, se caracteriza por una fuerte absorción de agua que enmascara las características de absorción de otros constituyentes de la hoja (Lukeš *et al.*, 2013). En particular, SWIR tienen mayor poder explicativo para la estimación de AGB que las bandas espectrales de longitud de onda más cortas debido a la amplia variación espectral en la banda del infrarrojo cercano y a que es menos sensible a las firmas espectrales del bosque que en las bandas visibles (Gao *et al.*, 2018). La correlación negativa del infrarrojo medio (B11 y B12) es inversamente proporcional a la densidad forestal, lo cual es factible de

atribuir a la disminución del albedo en zonas con alta densidad (Aguirre *et al.*, 2009). Por lo tanto, un aumento significativo en los valores de SWIR sugiere una mayor cantidad de clorofila y en consecuencia de biomasa aérea.

El índice espectral que presentó una mayor correlación con la AGB de *E. grandis* obtenida en campo fue  $GNDVI_{re3n}$ , y para el caso de la AGB de *P. spp* fue GNDVI. Estos resultados se comparan con otras investigaciones en donde se ha demostrado que este índice (GNDVI) es más sensible a la variación en el contenido de clorofila que el NDVI (Gitelson *et al.*, 1996). La reducción del efecto de saturación en la vegetación más densa puede observarse cuando se reemplaza la banda roja por la banda verde (GNDVI en lugar de NDVI). Se argumentó que GNDVI era al menos cinco veces más sensible a la concentración de clorofila-a que el NDVI y específicamente útil para diferenciar vegetación estresada (Gitelson *et al.*, 1996). Si bien la importancia de las bandas de borde rojo en la estimación de AGB se ha abordado en investigaciones anteriores (Kanke *et al.*, 2016; Dube *et al.*, 2018), 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 especies latifoliadas como *E. grandis*, dada su efectividad para monitorear la información del estado de la vegetación (Ghosh & Behera, 2018).

La retrodispersión VH ( $\sigma^{\circ}_{VH}$ ) derivada de los datos SAR presentó una mayor correlación con la biomasa aérea de *E. grandis* y *P. spp*, comparado con la polarización VV. Estos resultados concuerdan con Behera *et al.* (2016), donde estimaron la AGB en plantaciones de *T. grandis* usando datos ALOS-PALSAR y concluyeron que los datos de polarización VH y HV mostraron una mejor correlación que VV con la biomasa tomada en campo. Esto puede deberse a los valores que surgen de la dispersión del volumen, relacionada directamente con la AGB, y a la influencia de la humedad del suelo y de la vegetación (Collins *et al.*, 2009). Hosseini & McNairn (2017), encontraron que la polarización VH obtuvo las correlaciones más fuertes obteniendo un r de 0.917, mayor en relación con las dos polarizaciones simples (HH y VV) y sugieren que los datos de banda C de doble

polarización se pueden usar para generar estimaciones de biomasa aérea sin necesidad de agregar datos auxiliares.

Por otro lado, las texturas derivadas de SAR mostraron bajas relaciones con los datos de AGB tomados en campo para *E. grandis* y *P. spp*; sin embargo, las texturas  $\text{Correlación}_{\text{VH}}$  y  $\text{Correlación}_{\text{VV}}$  para *E. grandis* y  $\text{Correlación}_{\text{VH}}$  y  $\text{Entropía}_{\text{VV}}$  para *P. spp*, derivadas de la matriz GLCM, arrojaron mejores resultados que los coeficientes de retrodispersión VH y VV. Cutler (2012), encontró que la adición de texturas derivadas de datos SAR JERS-1 a los datos multiespectrales Landsat TM mostró fuertes correlaciones con la biomasa aérea en bosques tropicales ( $r = 0,79$ ,  $0,79$  y  $0,84$  para Tailandia, Malasia y Brasil, respectivamente). 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 (Galidaki *et al.*, 2017)

## 5.2 Estimación de AGB de *E. grandis* y *P. spp* usando datos Sentinel

El índice  $\text{GNDVI}_{\text{re3n}}$ , que relaciona la banda 7 del borde rojo, presentó el mayor coeficiente de determinación en el modelo generado para estimar AGB en *E. grandis* y en el caso de *P. spp* fue el modelo que relacionó el índice GNDVI. Horler *et al.* (1994) señalaron que la posición del borde rojo se ve afectada por el número de capas de hojas, que a su vez pueden relacionarse con el grosor de la cobertura y con la biomasa. (Navarro *et al.*, 2017), por ende, dado que la morfología de estas dos especies es diferente, es claro ver que el borde rojo muestra mayor respuesta en especies latifoliadas como *E. grandis*. Los índices espectrales basados en la reflectancia de las bandas verde, rojo, infrarrojo cercano y medio, describen de manera satisfactoria el comportamiento de la AGB debido a la fuerte absorción de

energía causada por la presencia del vigor de la vegetación sana, la absorción de la clorofila y la humedad presente en la vegetación (Soria & Granados, 2005).

En esta investigación se encontraron bajas correlaciones entre las retrodispersiones VH y VV con la AGB para ambas especies, así mismo, los modelos generados para estimar AGB en *E. grandis* no mostraron significancia; sin embargo, en *P. spp* sí lo hicieron (Tabla 11). Esto puede atribuirse a que los datos de retrodispersión representan la rugosidad del dosel del bosque y la AGB de especies latifoliadas no está directamente relacionado con esta rugosidad, lo que da como resultado un rendimiento deficiente en la estimación de AGB para estas especies pero no para coníferas como *P. spp* (Gao *et al.*, 2018). Los modelos generados a partir de las texturas Correlación<sub>VH</sub>, Correlación<sub>VV</sub>, Media<sub>VV</sub> y Varianza<sub>VV</sub> para *E. grandis* y *P. spp* mostraron la capacidad de estimar AGB, dada la significancia. De acuerdo con Champion *et al.*, (2014), concluyeron que la sensibilidad de estas texturas podrían estar relacionados con la resolución de la imagen y la estructura y arquitectura del rodal (tamaño del dosel, patrones de adelgazamiento, ancho y dirección de la hoja). Esto coincide con los resultados obtenidos por Eckert (2012), donde encontró que estas mismas texturas, derivadas de la banda azul costera, contribuyeron a una estimación de AGB más precisa ( $R^2=81\%$  y  $EMC_r = 11.8\%$ ). En el caso de Kuplich, Curran & Atkinson (2005), se encontró que las texturas Contraste, Entropía y Correlación aumentaron con la AGB debido al aumento de la dispersión del bosque con dosel denso. Además, el  $R^2$  aumentó de 0,74 a 0,82 con la adición de la textura Contraste al modelo para estimar la AGB del bosque tropical de la Amazonia Brasileña.

Se ha demostrado que los datos de la banda C arrojan mejores resultados en zonas de bajo contenido de AGB como claros y sitios de regeneración de bosques debido a su mayor retrodispersión en estas áreas en comparación con las bandas L y P (Sinha *et al.*, 2015). Para los datos de radar de la banda C, las variables derivadas relacionadas (coeficientes de retrodispersión y textura) mostraron no ser lo suficientemente sensibles para estimar AGB. Para desarrollar aún más este enfoque de la estimación, Sivasankar *et al.* (2018) sugieren que los datos SAR

deben utilizarse como datos de series de tiempo, para generar una mejor información sobre el estado de la cobertura forestal. La señal de la banda C se atenúa cuando entra en contacto con doseles más cerrados y con componentes más estructurales, por lo que funciona mejor sólo en la cobertura con una baja cantidad de biomasa (Ghasemi *et al.*, 2011).

### 5.3 Mapeo de AGB de *E. grandis* y *P. spp* usando el método Random Forest

Se encontró que el algoritmo de aprendizaje automático Random Forest condujo a estimaciones de AGB para *E. grandis* y para *P. spp* más precisas que las de regresión lineal. Este resultado es comparable con lo obtenido por Liu *et al.* (2017), donde encontraron que los modelos generados con RF para estimar AGB a partir de datos Landsat-5 y GLAS, generalmente llevaron a un  $R^2$  más alto y un EMC más pequeño ( $R^2_{\text{máx}} = 0,96$ ,  $\text{EMC}_{\text{min}} = 17,73 \text{ t}\cdot\text{ha}^{-1}$ ) comparado con los métodos de regresión por pasos y regresión de vectores de soporte. Estos resultados se esperaban dado que el método RF ha demostrado ser un método adecuado para estimar AGB, por encima de otros métodos de predicción (Wang *et al.*, 2017; Fassnacht *et al.*, 2014; Liu *et al.*, 2017; Ghosh & Behera, 2018), a pesar de que el tiempo para optimizar los parámetros utilizados en el modelo RF fue mucho más largo que el requerido por regresión lineal. Lo contrario fue registrado por Gao *et al.*, (2018), dado que encontraron que la combinación de datos Landsat y ALOS PALSAR proporcionó un rendimiento mejor usando regresión lineal y un rendimiento peor para RF. Sadeghi *et al.*, (2018), encontraron que la relación entre los índices de vegetación y la AGB de un bosque boreal en Canadá, alcanzó un  $R^2$  de 0,62 mediante el uso de Random Forest, pero solo de 0,44 usando regresión lineal.

En este estudio se encontró que, 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), donde evaluaron la capacidad de los datos ALOS2-PALSAR-2 y Sentinel-2A para estimar AGB de un bosque tropical y encontraron que las estimaciones de AGB basadas en datos ópticos en general fueron menos precisas ( $R^2$  cerca de 0.70); sin embargo, cuando se involucraron datos de los sensores activos, la precisión de las estimaciones fue considerablemente mayor ( $R^2 > 0.80$ ), y específicamente encontraron que la combinación de SAR con índices de vegetación mostró la mejor correlación ( $r = 0.71$ ). Este hallazgo sugiere que el uso sinérgico de múltiples sensores ópticos y SAR tiene un mejor potencial que un solo sensor (Sinha *et al.*, 2015). Esta investigación indicó que la combinación de datos ópticos y SAR usando el método Random Forest puede generar mejores resultados que usando los datos por separado y por regresión lineal; sin embargo estos resultados mostraron tener efectos limitados para mejorar la estimación de AGB forestal. La posible razón se puede deber a que la resolución espacial de los datos Sentinel no puede capturar de manera efectiva las estructuras de las plantaciones forestales. En este caso, se sugiere la integración efectiva de los datos de diferentes fuentes para mejorar la estimación de la biomasa aérea (Lu *et al.*, 2016).

## 6. Conclusiones y recomendaciones

### 6.1 Conclusiones

Esta investigación se desarrolló en una plantación forestal comercial de *E. grandis* y *P. spp* para explorar la estimación de AGB a través de un análisis comparativo de dos algoritmos de modelado (Random Forest y Regresión Lineal) basados en Sentinel-2, Sentinel-1, y su combinación. Los resultados indican que:

- Los datos ópticos Sentinel-2 proporcionaron estimaciones más precisas de AGB que los datos SAR Sentinel-1, y la combinación de Sentinel-2 y Sentinel-1 tuvo efectos mínimos para mejorar la estimación de AGB.
- Se pueden usar muchas variables de percepción remota, tales como bandas espectrales, índices espectrales, texturas y transformaciones de la imagen, como predictores potenciales para la estimación de AGB; sin embargo, solo un número limitado de variables de percepción remota son útiles debido a sus altas correlaciones con la vegetación.
- Una sola variable por sí sola no puede capturar de manera efectiva la complejidad de la estructura del rodal forestal y, por lo tanto, no puede proporcionar un desempeño de estimación AGB satisfactorio.
- La incertidumbre de los datos de las parcelas podrían ser el tipo de muestreo, el tamaño y forma de la parcela, las ecuaciones alométricas para el cálculo de AGB, las mediciones de los atributos del árbol durante el trabajo de campo y el registro de coordenadas del centro la parcela.
- Los datos de AGB de *E. grandis* y *P. spp* usados en esta investigación fueron obtenidos a partir de modelos alométricos construidos a partir de datos capturados en campo con el uso de instrumentos que cuentan con diferentes factores de incertidumbre. La alometría es uno de los factores relacionados

con los parámetros forestales más importantes a considerar, probablemente muy por encima de la elaboración del modelo de biomasa aérea (Espinoza-Mendoza, 2018).

- Debido a las influencias derivadas de la heterogeneidad de la superficie terrestre, la precisión de posicionamiento del GPS, la topografía y condiciones climáticas, entre otras, siempre hay problemas de representatividad al hacer coincidir las parcelas de muestra con los píxeles correspondientes de los datos ópticos y SAR, problemas comunes en la teledetección cuantitativa que afectan los resultados obtenidos (Yang *et al.*, 2018).
- Los datos de teledetección pueden contribuir significativamente al monitoreo oportuno de la gestión de cultivos y plantaciones. Uno de los beneficios clave que ofrece el uso de imágenes de Sentinel es que tanto el SAR como las imágenes multiespectrales están disponibles, son gratuitos y pueden procesarse en el software gratuito SNAP. Esta disponibilidad es importante, especialmente en los países en vías de desarrollo en los trópicos, donde los fondos para la adquisición de imágenes y software son limitados y hay alta presencia de nubes, especialmente en temporada de lluvias.
- En comparación con otras imágenes libres, Sentinel-1 y Sentinel-2 también tienen resoluciones espaciales y temporales más altas. Las imágenes de Sentinel tienen un ancho de franja más grande en comparación con las imágenes comerciales, lo que puede ser muy útil en el mapeo de AGB a escalas regionales y nacionales.

## 6.2 Recomendaciones

Más investigaciones deben centrarse en la integración efectiva de diferentes fuentes de datos para desarrollar modelos de estimación AGB bajo la estratificación basada tanto en el tipo de bosque como en el rango de AGB. En esta investigación se encontró necesario eliminar las parcelas de muestra que no tenían una buena representatividad. La topografía y las condiciones climáticas afectan el crecimiento de la vegetación, lo que influye en la estructura del rodal y la acumulación de biomasa, por ende se deben tener en cuenta estas variables al momento de generar modelos para la estimación de AGB forestal.

Esta investigación evidenció la falta de datos y la alta incertidumbre en las estimaciones de AGB a nivel local, donde los datos de inventario no proporcionaron información suficiente con respecto al tamaño de cada lote. Esta escasez de datos de campo es común, dados los recursos necesarios para la recolección de datos de campo. El número de parcelas disponibles representa, por lo tanto, un límite en esta investigación, y los hallazgos reportados aquí deben considerarse como indicaciones preliminares, para expandirse para el uso futuro de los datos Sentinel-2A y Sentinel-1A para propósitos de mapeo de AGB forestal. Por otro lado, los resultados sugieren la disponibilidad de información multitemporal es muy importante para mejorar la caracterización de las plantaciones forestales comerciales dado que la zona de estudio generalmente presenta alta nubosidad, factor limitante al momento de usar datos ópticos.

# Anexos

## A. Anexo: Ecuaciones alométricas alternativas para la estimación de AGB.

Modelo	Ecuación
1	$Y = b_0 \text{ DAP}^{b_1}$
2	$Y = b_0 + b_1 \text{ DAP} + b_2 \text{ DAP}^2$
3	$Y = b_0 + b_1 \text{ DAP}^2 + b_2 \text{ H} + b_3 \text{ DAP}^2 \text{ H}$
4	$Y = b_0 + b_1 \text{ DAP}^2$
5	$Y = b_0 + b_1 \text{ DAP}^2 \text{ H}$
6	$Y = (b_0 + b_1 \text{ DAP})^2$
7	$Y = \text{Exp} (b_0 + b_1 \text{ LnDAP})$
8	$Y = \text{Exp} (b_0 + b_1 \text{ Ln}(\text{DAP}^2 \text{ H}))$
9	$Y = \text{Exp} (b_0 + b_1 \text{ DAP})$

Y = biomasa aérea (kg); DAP = diámetro normal o diámetro a la altura del pecho (cm); H= altura total (m);  $b_0, \dots, b_3$  = parámetros de regresión; Exp = base de los logaritmos neperianos; Ln= logaritmo natural.

**B. Anexo: Datos de inventario para E. grandis.**

Dato	Lote	Parcela	AGB (t.ha <sup>-1</sup> )	Edad	Dato	Lote	Parcela	AGB (t.ha <sup>-1</sup> )	Edad
1	2	458	70,49	5	50	19	574	228,32	6
2	2	464	122,51	6	51	20	470	244,94	6
3	2	474	138,15	6	52	20	478	229,48	6
4	2	537	136,62	6	53	20	479	230,52	6
5	2	562	150,17	7	54	20	482	246,07	6
6	2	564	149,22	5	55	20	561	240,24	7
7	2	617	149,98	5	56	22	462	259,41	6
8	4	457	153,35	6	57	22	468	263,56	6
9	4	486	154,27	6	58	22	471	250,83	6
10	5	476	163,22	6	59	22	473	255,80	6
11	5	480	163,99	6	60	22	567	272,83	6
12	5	539	160,88	6	61	22	585	247,43	7
13	5	580	161,60	6	62	22	587	261,87	7
14	5	614	163,14	5	63	69	475	282,40	6
15	5	616	158,34	5	64	69	483	280,36	6
16	6	465	171,50	6	65	69	572	294,31	6
17	6	481	165,64	6	66	69	573	338,79	7
18	6	523	172,54	6	67	69	586	301,54	7
19	6	563	173,30	5					
20	6	577	166,97	5					
21	7	477	174,22	6					
22	7	522	177,97	6					
23	7	565	177,10	6					
24	8	467	178,05	6					
25	9	405	179,83	6					
26	9	459	184,74	6					
27	9	461	192,49	6					
28	9	466	192,47	6					
29	9	487	184,16	6					
30	9	540	193,63	6					
31	9	568	178,65	6					
32	9	569	187,22	6					
33	9	576	182,66	5					
34	10	460	203,78	6					
35	10	520	200,94	6					
36	10	521	202,41	6					
37	10	570	206,32	6					
38	10	571	203,32	6					
39	10	575	197,81	5					
40	10	613	204,86	5					
41	18	469	222,87	6					
42	18	485	210,39	6					
43	18	536	213,48	6					
44	18	538	218,24	6					
45	18	566	208,63	6					
46	18	578	210,91	5					
47	18	615	219,20	5					
48	19	463	225,60	6					
49	19	484	225,86	6					

### C. Anexo: Datos de inventario para *P. oocarpa*, *P. patula* y *P. tecunumanii*.

Dato	Lote	Parcela	Especie	AGB (t.ha <sup>-1</sup> )	Edad	Dato	Lote	Parcela	Especie	AGB (t.ha <sup>-1</sup> )	Edad
1	2	503	<i>P. oocarpa</i>	281,12	28	32	5	526	<i>P. patula</i>	344,51	27
2	4	504	<i>P. oocarpa</i>	298,40	27	33	8	623	<i>P. patula</i>	353,85	27
3	3	515	<i>P. oocarpa</i>	318,73	12	34	5	528	<i>P. patula</i>	358,11	27
4	3	512	<i>P. oocarpa</i>	348,68	12	35	5	524	<i>P. patula</i>	380,63	27
5	3	557	<i>P. oocarpa</i>	361,45	12	36	5C	535	<i>P. patula</i>	385,08	25
6	3	507	<i>P. oocarpa</i>	362,13	12	37	6	600	<i>P. patula</i>	396,49	27
7	3	509	<i>P. oocarpa</i>	363,90	12	38	5B	531	<i>P. patula</i>	399,31	25
8	3	554	<i>P. oocarpa</i>	374,73	12	39	5C	533	<i>P. patula</i>	400,42	25
9	3	558	<i>P. oocarpa</i>	375,48	12	40	5	529	<i>P. patula</i>	405,36	27
10	3	511	<i>P. oocarpa</i>	399,11	12	41	8	621	<i>P. patula</i>	420,60	27
11	3	555	<i>P. oocarpa</i>	401,29	12	42	6	606	<i>P. patula</i>	444,34	27
12	3	556	<i>P. oocarpa</i>	417,20	12	43	6	601	<i>P. patula</i>	479,01	27
13	3	506	<i>P. oocarpa</i>	437,59	12	44	5B	532	<i>P. patula</i>	490,98	25
14	6	552	<i>P. oocarpa</i>	506,15	28	45	6	605	<i>P. patula</i>	520,14	27
15	2	549	<i>P. oocarpa</i>	608,48	28	46	6	608	<i>P. patula</i>	599,61	27
16	6	553	<i>P. oocarpa</i>	638,24	28	47	8	624	<i>P. patula</i>	627,50	27
17	4	551	<i>P. oocarpa</i>	638,32	27	48	5C	534	<i>P. patula</i>	629,89	25
18	3	508	<i>P. oocarpa</i>	657,12	25	49	6	604	<i>P. patula</i>	631,40	27
19	2	550	<i>P. oocarpa</i>	675,59	28	50	6	603	<i>P. patula</i>	634,90	27
20	3	514	<i>P. oocarpa</i>	703,42	25	51	6	599	<i>P. patula</i>	655,75	27
21	3	510	<i>P. oocarpa</i>	715,03	25	52	6	602	<i>P. patula</i>	676,21	27
22	2	502	<i>P. oocarpa</i>	735,33	28	53	5	596	<i>P. patula</i>	689,02	27
23	6	505	<i>P. oocarpa</i>	861,12	28	54	5	530	<i>P. patula</i>	695,86	27
24	3	513	<i>P. oocarpa</i>	925,40	28	55	5	588	<i>P. patula</i>	707,58	27
25	5	593	<i>P. patula</i>	263,59	27	56	5	594	<i>P. patula</i>	721,09	27
26	8	622	<i>P. patula</i>	281,13	27	57	5	591	<i>P. patula</i>	737,41	27
27	5	595	<i>P. patula</i>	283,46	27	58	6	607	<i>P. patula</i>	847,33	27
28	5	527	<i>P. patula</i>	309,62	27	59	5	592	<i>P. patula</i>	848,54	27
29	5	597	<i>P. patula</i>	313,45	27	60	3	495	<i>P. tecunumanii</i>	308,65	17
30	8	625	<i>P. patula</i>	329,12	27	61	3A	547	<i>P. tecunumanii</i>	317,87	17
31	5	525	<i>P. patula</i>	329,59	27	62	3	546	<i>P. tecunumanii</i>	370,78	17

Continuación

<b>Dato</b>	<b>Lote</b>	<b>Parcela</b>	<b>Especie</b>	<b>AGB (t.ha-1)</b>	<b>Edad</b>
63	2	489	<i>P. tecunumanii</i>	377,32	17
64	3	498	<i>P. tecunumanii</i>	387,20	17
65	3	496	<i>P. tecunumanii</i>	387,87	17
66	3A	499	<i>P. tecunumanii</i>	387,89	17
67	1	542	<i>P. tecunumanii</i>	399,12	17
68	2	491	<i>P. tecunumanii</i>	428,14	17
69	3A	548	<i>P. tecunumanii</i>	451,94	17
70	1	541	<i>P. tecunumanii</i>	457,35	17
71	3	494	<i>P. tecunumanii</i>	479,35	17
72	1	488	<i>P. tecunumanii</i>	489,40	17
73	2	490	<i>P. tecunumanii</i>	492,69	17
74	3	497	<i>P. tecunumanii</i>	498,62	17
75	2	543	<i>P. tecunumanii</i>	500,13	17
76	2	544	<i>P. tecunumanii</i>	504,04	17
77	2	492	<i>P. tecunumanii</i>	506,35	17
78	2	493	<i>P. tecunumanii</i>	521,19	17
79	3A	500	<i>P. tecunumanii</i>	525,23	17
80	3	545	<i>P. tecunumanii</i>	540,30	17

### D. Anexo: Datos de AGB de *E. grandis* tomados en campo vs índices espectrales.

AGB	GNDVI <sub>RE3N</sub>	GNDVI	NDVI	SAVI	AGB	GNDVI <sub>RE3N</sub>	GNDVI	NDVI	SAVI
<b>70,49</b>	0,50	0,50	0,52	0,29	<b>202,41</b>	0,66	0,56	0,76	0,41
<b>122,51</b>	0,55	0,54	0,62	0,30	<b>203,78</b>	0,65	0,65	0,41	0,23
<b>136,62</b>	0,66	0,66	0,77	0,43	<b>204,86</b>	0,69	0,46	0,80	0,43
<b>138,15</b>	0,69	0,69	0,79	0,47	<b>206,32</b>	0,70	0,69	0,80	0,48
<b>149,98</b>	0,65	0,64	0,74	0,41	<b>208,63</b>	0,63	0,70	0,73	0,38
<b>150,17</b>	0,67	0,66	0,78	0,38	<b>210,91</b>	0,72	0,62	0,81	0,46
<b>154,27</b>	0,59	0,58	0,68	0,33	<b>218,24</b>	0,65	0,71	0,75	0,41
<b>163,14</b>	0,65	0,65	0,77	0,37	<b>219,19</b>	0,68	0,64	0,78	0,43
<b>163,22</b>	0,71	0,71	0,81	0,48	<b>222,87</b>	0,70	0,68	0,81	0,45
<b>163,99</b>	0,68	0,67	0,78	0,46	<b>225,60</b>	0,63	0,70	0,72	0,42
<b>165,64</b>	0,64	0,63	0,76	0,37	<b>225,86</b>	0,61	0,61	0,71	0,35
<b>166,97</b>	0,71	0,70	0,79	0,47	<b>229,48</b>	0,69	0,68	0,79	0,40
<b>171,50</b>	0,63	0,62	0,75	0,38	<b>240,24</b>	0,67	0,66	0,78	0,38
<b>172,54</b>	0,65	0,64	0,75	0,40	<b>244,93</b>	0,70	0,70	0,80	0,45
<b>174,22</b>	0,65	0,64	0,75	0,41	<b>246,07</b>	0,70	0,70	0,80	0,47
<b>177,96</b>	0,61	0,60	0,73	0,37	<b>247,43</b>	0,64	0,63	0,76	0,35
<b>178,05</b>	0,71	0,60	0,80	0,49	<b>259,41</b>	0,64	0,64	0,76	0,40
<b>179,83</b>	0,64	0,71	0,77	0,37	<b>261,87</b>	0,65	0,64	0,77	0,36
<b>182,66</b>	0,69	0,64	0,78	0,45	<b>263,56</b>	0,67	0,67	0,78	0,43
<b>184,15</b>	0,58	0,69	0,69	0,31	<b>280,36</b>	0,63	0,62	0,74	0,36
<b>184,74</b>	0,62	0,56	0,70	0,38	<b>294,31</b>	0,67	0,67	0,77	0,42
<b>192,47</b>	0,63	0,61	0,75	0,39	<b>301,54</b>	0,66	0,65	0,77	0,37
<b>192,49</b>	0,59	0,62	0,69	0,37	<b>338,79</b>	0,72	0,72	0,82	0,49
<b>193,63</b>	0,57	0,58	0,69	0,31					

Donde AGB: Biomasa aérea obtenida en campo.

### E. Anexo: Datos de AGB de *E. grandis* tomados en campo vs datos de radar.

AGB	VH	ASM	CON	DIS	ENT	COR	MEA	VAR	HOM
<b>70,49</b>	-15,466	-10,734	20,298	9,956	8,375	-2,311	11,066	21,132	-3,511
<b>136,62</b>	-14,026	-12,424	18,480	9,853	8,643	-0,653	13,208	24,022	-5,024
<b>138,15</b>	-15,804	-11,217	16,634	8,958	8,328	-1,754	10,086	18,409	-3,877
<b>149,22</b>	-11,661	-12,821	21,784	11,584	8,744	-0,640	14,965	27,408	-6,820
<b>150,17</b>	-7,909	-7,075	23,024	11,553	7,481	-0,303	17,255	31,731	-1,801
<b>153,35</b>	-18,607	-8,081	13,477	7,215	7,588	-2,313	7,782	14,308	-2,047
<b>154,27</b>	-16,123	-13,688	23,967	12,577	8,919	-1,992	13,314	25,300	-6,372
<b>158,34</b>	-15,425	-11,154	19,413	9,868	8,312	-2,588	10,328	19,882	-4,099
<b>160,88</b>	-12,878	-13,802	21,519	11,543	8,960	-0,831	14,205	26,100	-7,695
<b>163,14</b>	-11,427	-12,821	23,710	12,330	8,711	-1,173	14,571	26,957	-5,956
<b>163,99</b>	-12,586	-12,022	22,317	11,828	8,687	-1,020	14,169	26,098	-4,925
<b>166,97</b>	-13,348	-11,797	20,708	10,899	8,482	-1,027	13,368	24,463	-4,685
<b>171,50</b>	-18,726	-10,073	18,291	9,638	8,113	-2,364	10,058	19,051	-3,213
<b>173,30</b>	-16,944	-11,123	18,688	9,883	8,334	-2,069	10,682	19,892	-3,373
<b>174,22</b>	-15,150	-11,549	16,839	9,049	8,421	-0,855	11,833	21,308	-3,821
<b>177,97</b>	-9,151	-13,522	26,566	14,088	8,896	-1,564	15,291	28,751	-8,287
<b>178,05</b>	-16,943	-10,539	16,441	8,325	8,181	-1,290	10,531	19,332	-2,250
<b>179,83</b>	-10,317	-13,310	22,412	11,818	8,844	-0,746	14,895	27,423	-6,402
<b>184,16</b>	-14,467	-12,467	25,796	13,547	8,738	-2,295	13,953	26,653	-5,742
<b>184,74</b>	-14,840	-10,999	18,725	9,590	8,332	-1,366	11,629	21,404	-3,992
<b>187,22</b>	-13,575	-13,468	27,718	14,703	8,867	-3,736	13,692	27,097	-10,042
<b>192,49</b>	-18,486	-9,228	15,583	7,901	7,749	-2,919	8,162	15,676	-2,528
<b>193,63</b>	-10,029	-13,920	26,350	13,991	8,970	-1,152	15,903	29,666	-9,116
<b>197,81</b>	-14,018	-13,688	24,712	13,215	8,935	-1,333	14,715	27,481	-9,369
<b>203,32</b>	-13,249	-13,468	24,321	12,711	8,883	-1,747	13,868	26,111	-7,382
<b>204,86</b>	-16,590	-11,347	17,064	9,243	8,428	-1,106	11,282	20,535	-4,327
<b>206,32</b>	-13,113	-13,362	24,593	12,863	8,857	-1,795	13,950	26,287	-6,461
<b>208,63</b>	-19,238	-8,504	11,162	6,232	7,524	-1,332	7,806	13,933	-1,673
<b>210,39</b>	-12,904	-12,915	27,421	14,513	8,791	-2,062	15,110	28,636	-7,685
<b>213,48</b>	-15,829	-10,073	11,563	6,301	8,088	-0,475	10,361	18,399	-1,558

## Continuación polarización VH

<b>AGB</b>	<b>VH</b>	<b>ASM</b>	<b>CON</b>	<b>DIS</b>	<b>ENT</b>	<b>COR</b>	<b>MEA</b>	<b>VAR</b>	<b>HOM</b>
<b>218,24</b>	-12,106	-13,010	21,235	11,217	8,814	-0,694	14,469	26,533	-5,732
<b>219,20</b>	-13,721	-12,915	21,390	11,228	8,771	-2,283	11,761	22,265	-5,258
<b>222,87</b>	-14,580	-10,073	18,340	9,654	8,303	-0,839	12,605	22,881	-3,360
<b>225,60</b>	-16,078	-12,467	22,574	11,523	8,680	-2,774	11,751	22,824	-4,876
<b>225,86</b>	-7,212	-12,962	26,560	14,071	8,804	-1,016	16,301	30,359	-6,728
<b>229,48</b>	-11,847	-13,632	23,069	12,236	8,922	-0,714	15,366	28,254	-7,946
<b>230,52</b>	-10,080	-11,797	23,038	12,236	8,521	-0,375	16,785	30,856	-5,935
<b>240,24</b>	-18,862	-11,481	23,202	11,996	8,463	-5,867	10,368	21,494	-5,643
<b>244,94</b>	-13,264	-13,979	24,907	13,277	8,998	-1,544	14,393	27,137	-11,835
<b>247,43</b>	-14,459	-13,158	19,097	10,374	8,804	-0,968	12,652	23,081	-6,267
<b>250,83</b>	-10,192	-11,314	23,886	12,529	8,493	-0,455	16,762	30,898	-6,316
<b>259,41</b>	-14,884	-9,478	19,287	9,445	7,900	-3,253	9,731	19,058	-2,790
<b>261,87</b>	-12,784	-12,300	28,095	14,852	8,674	-2,792	14,706	28,325	-7,479
<b>263,56</b>	-15,989	-11,481	18,549	9,762	8,463	-2,136	10,374	19,646	-4,576
<b>282,40</b>	-19,082	-9,456	12,648	6,990	7,770	-1,912	7,684	14,122	-2,238
<b>294,31</b>	-13,821	-10,909	18,265	9,574	8,288	-2,322	10,267	19,083	-4,105
<b>338,79</b>	-20,638	-8,679	13,649	7,243	7,662	-3,531	6,736	13,184	-1,863

Donde VH: Polarización VV; ASM: Segundo Momento Angular; CON: Contraste; DIS: Disimilitud; ENT: Entropía; COR: Correlación; MEA: Media; VAR: Varianza; HOM: Homogeneidad.

<b>AGB</b>	<b>VV</b>	<b>ASM</b>	<b>CON</b>	<b>DIS</b>	<b>ENT</b>	<b>COR</b>	<b>MEA</b>	<b>VAR</b>	<b>HOM</b>
<b>70,49</b>	-11,85	-13,36	23,84	12,56	8,86	-0,51	16,48	30,35	-6,09
<b>136,62</b>	-7,39	-9,50	21,24	10,83	8,01	-0,20	17,21	31,60	-3,10
<b>138,15</b>	-12,61	-11,62	23,50	12,00	8,51	-0,55	16,09	29,76	-3,25
<b>149,22</b>	-4,98	1,63	8,98	2,79	2,74	-0,01	17,84	32,69	1,59
<b>150,17</b>	-3,56	1,65	13,51	5,01	2,55	-0,03	17,81	32,64	1,43
<b>153,35</b>	-13,73	-12,96	22,65	12,11	8,80	-0,58	15,59	28,67	-6,42
<b>154,27</b>	-10,93	-9,54	19,65	9,99	7,98	-0,14	17,32	31,76	-3,04
<b>158,34</b>	-12,20	-13,74	25,40	13,48	8,93	-1,28	15,16	28,31	-7,41
<b>160,88</b>	-7,44	-6,95	19,00	9,26	7,25	-0,11	17,52	32,11	-1,38
<b>163,14</b>	-2,96	3,16	-1,98	-1,98	-5,21	0,00	17,90	32,79	2,26
<b>163,99</b>	-7,47	-2,32	15,20	5,64	4,67	-0,04	17,77	32,56	0,46
<b>166,97</b>	-7,77	-5,98	20,40	9,53	7,06	-0,15	17,49	32,12	-1,08
<b>171,50</b>	-15,71	-12,42	25,34	13,46	8,70	-0,90	15,88	29,59	-6,87
<b>173,30</b>	-10,68	-11,87	22,08	11,57	8,53	-0,29	16,86	30,95	-4,70
<b>174,22</b>	-8,62	-9,59	25,07	12,96	8,08	-0,57	16,86	31,18	-4,40
<b>177,97</b>	-5,89	-4,93	25,18	12,24	7,12	-0,50	17,18	31,80	-1,53
<b>178,05</b>	-13,68	-13,11	24,06	12,66	8,83	-0,91	15,24	28,29	-8,67
<b>179,83</b>	-5,23	3,66	-1,15	-2,47	-3,70	0,00	17,90	32,79	2,40
<b>184,16</b>	-9,27	-8,54	23,95	12,18	7,82	-0,40	17,08	31,52	-3,52
<b>184,74</b>	-10,77	-8,21	24,26	12,30	7,80	-0,45	16,97	31,29	-2,88
<b>187,22</b>	-9,89	-10,79	25,58	13,40	8,38	-0,72	16,55	30,71	-4,87
<b>192,49</b>	-13,38	-13,69	22,76	12,10	8,92	-0,57	15,67	28,85	-7,80
<b>193,63</b>	-6,60	0,80	14,96	4,82	2,82	-0,04	17,80	32,64	1,53
<b>197,81</b>	-8,28	-0,19	5,64	2,22	3,30	0,00	17,85	32,70	1,24
<b>203,32</b>	-6,62	-9,01	20,34	10,06	7,85	-0,15	17,39	31,91	-2,27
<b>204,86</b>	-11,05	-8,94	22,87	11,80	7,99	-0,33	16,99	31,26	-2,94
<b>206,32</b>	-7,43	-9,46	23,38	11,93	8,04	-0,35	17,13	31,53	-3,26
<b>208,63</b>	-13,13	-13,69	22,77	11,81	8,92	-0,61	15,54	28,61	-4,95
<b>210,39</b>	-8,15	-5,43	21,81	10,90	7,04	-0,21	17,41	31,98	-2,40
<b>213,48</b>	-13,43	-13,47	23,97	12,68	8,88	-0,89	15,27	28,28	-7,10

## Continuación polarización VV

<b>AGB</b>	<b>VV</b>	<b>VV_ASM</b>	<b>VV_CON</b>	<b>VV_DIS</b>	<b>VV_ENT</b>	<b>VV_COR</b>	<b>VV_MEA</b>	<b>VV_VAR</b>	<b>VV_HOM</b>
<b>218,24</b>	-7,04	-5,71	20,40	9,48	6,89	-0,15	17,48	32,10	-0,89
<b>219,20</b>	-7,64	-11,03	23,71	12,19	8,42	-0,41	16,90	31,16	-4,29
<b>222,87</b>	-10,67	-14,10	26,03	13,82	9,01	-1,45	15,24	28,50	-10,33
<b>225,60</b>	-13,56	-11,98	25,54	13,37	8,65	-1,44	14,89	28,02	-6,20
<b>225,86</b>	-4,39	-0,56	14,41	5,44	4,10	-0,03	17,79	32,60	0,92
<b>229,48</b>	-5,95	3,05	15,40	4,31	-0,01	-0,04	17,83	32,68	1,98
<b>230,52</b>	-6,04	4,51	-5,23	-5,23	0,00	0,00	17,91	32,81	2,67
<b>240,24</b>	-15,29	-13,63	27,53	14,47	8,92	-2,75	14,34	27,80	-10,53
<b>244,94</b>	-7,37	0,71	1,36	0,67	1,41	0,00	17,88	32,74	1,57
<b>247,43</b>	-8,06	-6,75	17,78	8,24	7,16	-0,08	17,58	32,21	-0,99
<b>250,83</b>	-3,64	5,58	-10,00	-10,00	0,00	0,00	17,92	32,83	2,90
<b>259,41</b>	-10,36	-10,94	25,94	13,48	8,39	-0,83	16,43	30,54	-4,39
<b>261,87</b>	-6,86	-7,77	25,49	13,04	7,61	-0,62	16,84	31,21	-2,96
<b>263,56</b>	-12,80	-12,34	23,59	12,54	8,70	-0,62	15,88	29,36	-6,63
<b>282,40</b>	-12,49	-13,86	24,59	13,04	8,96	-1,01	15,31	28,43	-7,31
<b>294,31</b>	-8,75	-13,63	27,11	14,35	8,91	-1,82	15,24	28,75	-8,31
<b>338,79</b>	-14,19	-12,60	26,92	14,03	8,69	-2,72	14,01	27,22	-6,37

Donde VV: Polarización VV; ASM: Segundo Momento Angular; CON: Contraste; DIS: Disimilitud; ENT: Entropía; COR: Correlación; MEA: Media; VAR: Varianza; HOM: Homogeneidad

## F. Anexo: Datos de AGB de *P.spp* tomados en campo vs índices espectrales.

AGB	GNDVI <sub>RE3N</sub>	GNDVI	NDVI	SAVI	AGB	GNDVI <sub>RE3N</sub>	GNDVI	NDVI	SAVI
263,59	0,29	0,26	0,30	0,10	444,34	0,55	0,53	0,68	0,26
281,12	0,52	0,51	0,67	0,28	451,94	0,55	0,53	0,68	0,30
281,13	0,47	0,45	0,62	0,19	479,01	0,47	0,48	0,63	0,21
283,46	0,33	0,32	0,38	0,13	489,40	0,60	0,60	0,74	0,39
298,40	0,54	0,53	0,70	0,30	498,62	0,59	0,58	0,73	0,37
308,65	0,56	0,55	0,71	0,31	500,13	0,56	0,55	0,71	0,32
309,62	0,53	0,52	0,65	0,29	504,04	0,58	0,56	0,72	0,34
317,87	0,56	0,54	0,70	0,31	506,35	0,60	0,59	0,74	0,37
318,73	0,42	0,39	0,44	0,19	520,14	0,53	0,53	0,67	0,26
329,59	0,48	0,47	0,63	0,23	525,23	0,60	0,59	0,74	0,37
344,51	0,54	0,52	0,66	0,29	540,30	0,60	0,59	0,74	0,38
348,68	0,60	0,59	0,74	0,36	599,61	0,55	0,55	0,68	0,28
358,11	0,55	0,54	0,67	0,30	608,48	0,53	0,52	0,69	0,29
362,13	0,57	0,56	0,72	0,32	627,50	0,58	0,59	0,71	0,33
363,90	0,60	0,59	0,74	0,36	634,90	0,49	0,49	0,65	0,21
370,78	0,54	0,53	0,69	0,30	638,24	0,53	0,51	0,69	0,28
374,73	0,60	0,59	0,74	0,36	655,75	0,51	0,52	0,63	0,25
375,48	0,58	0,57	0,72	0,35	675,59	0,55	0,53	0,69	0,31
377,32	0,56	0,54	0,70	0,32	676,21	0,55	0,56	0,65	0,29
385,08	0,54	0,54	0,67	0,31	689,02	0,56	0,56	0,69	0,27
387,20	0,58	0,57	0,72	0,34	695,86	0,57	0,56	0,68	0,34
387,89	0,55	0,53	0,70	0,30	703,42	0,59	0,59	0,74	0,36
399,11	0,54	0,53	0,61	0,33	707,58	0,58	0,58	0,71	0,31
399,31	0,48	0,46	0,62	0,22	721,09	0,55	0,56	0,69	0,28
401,29	0,59	0,58	0,73	0,35	737,41	0,49	0,49	0,64	0,22
417,20	0,59	0,57	0,73	0,34	847,33	0,52	0,52	0,66	0,24
420,60	0,51	0,51	0,66	0,24	861,12	0,61	0,60	0,76	0,39
428,14	0,58	0,56	0,72	0,34	925,40	0,61	0,59	0,73	0,38

Donde AGB: Biomasa aérea obtenida en campo.

**G.Anexo: Datos de AGB de *P. spp* tomados en campo vs datos de radar.**

<b>AGB</b>	<b>VH</b>	<b>VH_ASM</b>	<b>VH_CON</b>	<b>VH_DIS</b>	<b>VH_ENE</b>	<b>VH_ENT</b>	<b>VH_COR</b>	<b>VH_MEA</b>	<b>VH_VAR</b>	<b>VH_HOM</b>
<b>489,40</b>	-11,99	-13,47	20,17	10,72	-6,73	8,90	-0,65	14,07	25,71	-5,77
<b>377,32</b>	-11,40	-13,69	25,16	13,25	-6,84	8,92	-1,33	14,89	27,95	-8,05
<b>492,69</b>	-15,97	-10,30	15,21	7,95	-5,15	8,14	-0,89	10,82	19,51	-2,65
<b>428,14</b>	-16,03	-10,43	14,08	7,73	-5,22	8,11	-0,46	11,78	21,07	-2,75
<b>506,35</b>	-17,63	-10,15	18,61	9,35	-5,07	8,22	-2,16	10,49	19,67	-2,71
<b>521,19</b>	-11,38	-12,64	26,55	14,17	-6,32	8,71	-2,00	14,70	27,87	-7,50
<b>479,35</b>	-13,03	-13,06	22,22	11,87	-6,53	8,81	-0,93	14,35	26,38	-8,24
<b>308,65</b>	-13,78	-13,63	23,71	12,66	-6,82	8,92	-1,78	13,53	25,43	-7,72
<b>387,87</b>	-15,97	-9,98	13,38	7,19	-4,99	8,05	-0,48	11,31	20,14	-2,32
<b>498,62</b>	-13,01	-13,11	21,17	11,11	-6,55	8,79	-0,72	14,31	26,32	-5,78
<b>387,20</b>	-14,19	-12,73	19,56	10,61	-6,37	8,74	-0,75	13,51	24,57	-7,02
<b>387,89</b>	-13,27	-12,26	18,96	9,97	-6,13	8,65	-0,53	13,97	25,38	-4,37
<b>525,23</b>	-16,91	-12,22	22,98	11,86	-6,11	8,64	-1,72	12,93	24,82	-5,02
<b>322,14</b>	-8,01	-12,92	24,59	12,95	-6,46	8,74	-0,58	16,58	30,61	-7,14
<b>735,33</b>	-15,07	-10,40	13,53	7,53	-5,20	8,08	-0,45	11,55	20,59	-2,71
<b>281,12</b>	-12,87	-13,58	24,08	12,59	-6,79	8,89	-2,65	12,78	24,48	-6,26
<b>298,40</b>	-12,92	-11,91	20,93	11,14	-5,95	8,55	-1,42	12,69	23,47	-4,38
<b>861,12</b>	-18,56	-13,36	21,84	11,69	-6,68	8,87	-2,44	11,85	22,50	-7,36
<b>437,59</b>	-11,94	-12,22	17,31	9,29	-6,11	8,61	-0,43	13,60	24,56	-5,10
<b>362,13</b>	-13,00	-12,92	23,07	12,20	-6,46	8,79	-1,17	14,23	26,33	-7,21
<b>657,12</b>	-10,50	-13,58	23,20	12,24	-6,79	8,91	-0,65	15,56	28,75	-6,46
<b>363,90</b>	-13,89	-13,36	22,45	11,98	-6,68	8,87	-1,98	12,67	23,81	-7,57
<b>715,03</b>	-16,49	-10,51	13,44	7,48	-5,26	8,11	-0,71	10,48	18,64	-3,23
<b>399,11</b>	-13,78	-12,73	22,49	11,68	-6,37	8,70	-1,53	13,19	24,76	-5,59
<b>348,68</b>	-14,72	-11,48	18,25	9,65	-5,74	8,45	-1,29	11,59	21,14	-3,70
<b>925,40</b>	-19,10	-5,34	8,13	4,31	-2,67	6,62	-0,91	7,20	12,33	0,02
<b>703,42</b>	-11,03	-13,42	26,86	14,32	-6,71	8,87	-1,65	15,34	28,86	-9,16
<b>318,73</b>	-15,95	-12,30	19,07	9,78	-6,15	8,64	-1,49	11,55	21,43	-4,64
<b>380,63</b>	-11,66	-12,73	25,25	13,22	-6,37	8,72	-1,10	15,49	28,75	-6,25
<b>329,59</b>	-13,54	-10,97	17,38	9,05	-5,49	8,41	-1,08	11,36	20,94	-3,18
<b>344,52</b>	-12,85	-13,36	22,57	11,87	-6,68	8,84	-1,01	14,26	26,40	-7,39
<b>309,62</b>	-9,90	-13,42	24,59	13,00	-6,71	8,87	-0,96	15,42	28,60	-6,44
<b>358,11</b>	-16,00	-11,06	14,94	8,04	-5,53	8,33	-0,75	11,07	19,93	-2,51
<b>405,36</b>	-15,65	-11,15	18,98	9,78	-5,58	8,34	-1,70	11,22	20,86	-3,55

## Continuación polarización VH

<b>AGB</b>	<b>VH</b>	<b>VH_ASM</b>	<b>VH_CON</b>	<b>VH_DIS</b>	<b>VH_ENE</b>	<b>VH_ENT</b>	<b>VH_COR</b>	<b>VH_MEA</b>	<b>VH_VAR</b>	<b>VH_HOM</b>
<b>695,86</b>	-12,27	-13,98	25,87	13,74	-6,99	8,98	-1,37	15,24	28,54	-8,83
<b>399,31</b>	-14,86	-12,87	19,70	10,25	-6,43	8,76	-0,95	13,01	23,75	-5,29
<b>490,98</b>	-13,40	-11,87	20,40	10,66	-5,94	8,56	-0,86	13,56	24,87	-4,87
<b>400,42</b>	-15,73	-10,97	13,86	7,43	-5,49	8,26	-0,43	11,82	21,12	-2,42
<b>629,89</b>	-15,07	-13,69	22,69	12,11	-6,84	8,94	-2,16	12,50	23,76	-8,38
<b>385,08</b>	-13,60	-12,60	19,43	10,49	-6,30	8,70	-0,95	12,87	23,47	-5,65
<b>457,35</b>	-14,33	-11,69	18,50	9,91	-5,85	8,54	-0,78	12,88	23,32	-3,97
<b>399,12</b>	-13,28	-11,58	19,19	9,99	-5,79	8,48	-0,73	13,29	24,27	-3,93
<b>500,13</b>	-13,13	-12,30	20,68	11,14	-6,15	8,64	-1,45	12,53	23,15	-6,29
<b>504,04</b>	-19,85	-12,06	18,98	9,84	-6,03	8,56	-2,08	10,68	20,17	-3,77
<b>540,30</b>	-11,36	-13,31	26,24	13,89	-6,66	8,84	-1,66	15,02	28,21	-8,12
<b>370,79</b>	-12,87	-13,21	21,92	11,73	-6,60	8,84	-0,81	14,51	26,60	-6,69
<b>317,87</b>	-14,07	-11,91	18,82	10,04	-5,95	8,57	-0,97	12,43	22,80	-4,45
<b>451,94</b>	-11,66	-12,60	16,69	8,92	-6,30	8,76	-0,20	14,88	27,23	-3,58
<b>608,48</b>	-17,04	-12,96	20,59	10,92	-6,48	8,80	-1,24	12,74	23,64	-5,71
<b>675,59</b>	-14,67	-11,58	20,79	10,40	-5,79	8,49	-2,00	11,71	22,11	-3,72
<b>638,32</b>	-14,45	-13,75	20,78	11,12	-6,87	8,93	-1,20	13,00	23,95	-6,62
<b>506,15</b>	-13,94	-10,97	15,15	8,33	-5,49	8,32	-0,62	11,66	20,91	-3,68
<b>638,24</b>	-14,10	-13,75	24,70	13,05	-6,87	8,93	-1,73	14,11	26,52	-8,37
<b>374,73</b>	-17,94	-9,93	18,16	9,36	-4,96	8,14	-1,68	10,86	20,10	-3,57
<b>401,29</b>	-17,93	-10,91	22,40	10,72	-5,46	8,25	-4,12	10,66	21,52	-2,90
<b>417,20</b>	-18,23	-9,63	13,82	7,51	-4,82	7,81	-1,13	9,53	17,20	-2,31
<b>361,45</b>	-10,27	-13,80	26,77	14,30	-6,90	8,96	-1,52	15,48	29,04	-11,03
<b>375,48</b>	-15,60	-13,06	23,87	12,65	-6,53	8,81	-2,24	13,06	24,82	-7,16
<b>707,58</b>	-17,13	-12,51	20,77	10,54	-6,26	8,71	-1,67	12,10	22,71	-4,31
<b>737,41</b>	-13,23	-13,42	23,00	11,94	-6,71	8,89	-2,38	12,38	23,73	-5,81
<b>848,54</b>	-17,84	-12,22	19,82	10,29	-6,11	8,60	-2,09	11,10	21,00	-4,61
<b>263,59</b>	-17,44	-9,59	16,18	8,43	-4,79	7,98	-3,32	8,25	15,89	-2,60
<b>721,09</b>	-14,17	-11,98	18,09	9,35	-5,99	8,53	-1,85	10,66	19,68	-3,21
<b>283,46</b>	-12,81	-13,31	22,87	12,27	-6,66	8,83	-1,29	13,82	25,75	-7,75
<b>689,02</b>	-17,00	-11,95	15,91	8,37	-5,97	8,56	-0,85	11,29	20,39	-2,95
<b>313,45</b>	-13,11	-13,01	26,14	13,70	-6,51	8,78	-3,63	13,13	25,60	-8,20
<b>655,74</b>	-19,73	-11,54	19,48	10,42	-5,77	8,41	-3,71	9,61	18,87	-5,45
<b>396,49</b>	-12,02	-13,80	22,07	11,83	-6,90	8,94	-1,08	13,82	25,63	-7,52
<b>479,01</b>	-17,06	-8,27	9,65	5,36	-4,14	7,49	-0,70	8,44	14,90	-0,89
<b>676,21</b>	-16,02	-11,76	20,41	11,06	-5,88	8,50	-3,10	10,60	20,32	-6,38

Continuación											
<b>AGB</b>	<b>VH</b>	<b>VH_ASM</b>	<b>VH_CON</b>	<b>VH_DIS</b>	<b>VH_ENE</b>	<b>VH_ENT</b>	<b>VH_COR</b>	<b>VH_MEA</b>	<b>VH_VAR</b>	<b>VH_HOM</b>	
<b>634,90</b>	-14,91	-11,25	15,17	8,24	-5,63	8,37	-0,99	10,54	19,08	-3,36	
<b>631,40</b>	-13,77	-13,21	22,75	11,98	-6,60	8,82	-2,57	12,08	23,23	-6,17	
<b>520,14</b>	-5,99	-6,23	24,03	11,57	-3,11	7,10	-0,37	17,32	31,93	-1,49	
<b>444,34</b>	-14,75	-7,60	13,10	6,44	-3,80	7,49	-1,70	8,20	14,99	-0,89	
<b>847,33</b>	-13,83	-13,16	26,72	13,97	-6,58	8,80	-2,55	14,24	27,24	-7,58	
<b>599,62</b>	-17,22	-10,85	15,48	8,06	-5,43	8,23	-1,88	9,09	17,02	-2,37	
<b>420,60</b>	-18,59	-11,06	17,24	8,94	-5,53	8,31	-2,41	9,39	17,94	-3,70	
<b>281,13</b>	-13,18	-13,80	25,58	13,35	-6,90	8,96	-2,32	13,91	26,40	-7,79	
<b>353,85</b>	-14,39	-11,83	20,53	10,84	-5,92	8,55	-2,00	11,64	21,86	-5,42	
<b>627,50</b>	-17,84	-10,73	17,46	9,17	-5,37	8,25	-4,12	8,37	16,58	-3,60	
<b>329,12</b>	-10,43	-13,80	23,62	12,41	-6,90	8,96	-1,13	14,45	27,01	-7,39	

<b>AGB</b>	<b>VV</b>	<b>VV_ASM</b>	<b>VV_CON</b>	<b>VV_DIS</b>	<b>VV_ENE</b>	<b>VV_ENT</b>	<b>VV_COR</b>	<b>VV_MEA</b>	<b>VV_VAR</b>	<b>VV_HOM</b>
<b>489,40</b>	-6,34	-5,37	14,30	6,87	-2,68	6,76	-0,03	17,66	32,34	-0,42
<b>377,32</b>	-4,57	1,18	16,05	5,56	0,59	2,92	-0,05	17,79	32,61	1,42
<b>492,69</b>	-12,40	-12,92	21,94	11,65	-6,46	8,79	-0,73	14,69	27,05	-6,50
<b>428,14</b>	-9,84	-12,02	24,05	12,70	-6,01	8,55	-0,44	16,94	31,20	-6,41
<b>506,35</b>	-10,52	-11,19	23,95	12,35	-5,59	8,50	-0,43	16,95	31,21	-4,37
<b>521,19</b>	-5,70	-6,64	25,86	13,12	-3,32	7,34	-0,63	17,05	31,57	-2,31
<b>479,35</b>	-9,50	-10,40	20,33	10,51	-5,20	8,17	-0,17	17,24	31,61	-3,48
<b>308,65</b>	-10,79	-7,03	22,78	11,21	-3,51	7,39	-0,30	17,17	31,60	-1,69
<b>387,87</b>	-11,83	-13,16	21,17	11,18	-6,58	8,87	-0,39	15,73	28,79	-5,48
<b>498,62</b>	-4,81	-2,43	15,29	6,96	-1,22	5,56	-0,04	17,73	32,48	0,04
<b>387,20</b>	-7,69	-9,27	18,17	9,26	-4,63	7,92	-0,09	17,43	31,92	-2,34
<b>387,89</b>	-8,47	-5,02	18,95	8,85	-2,51	6,63	-0,10	17,57	32,22	-0,38
<b>525,23</b>	-10,05	-9,23	23,73	12,45	-4,61	8,13	-0,39	17,04	31,38	-4,41
<b>322,14</b>	-1,69	4,63	9,59	1,14	2,32	9,05	-0,01	17,88	32,76	2,46
<b>735,33</b>	-10,52	-13,26	22,73	12,12	-6,63	8,85	-0,37	16,69	30,65	-7,37
<b>281,12</b>	-11,52	-13,36	26,21	13,92	-6,68	8,86	-0,97	16,23	30,20	-7,95
<b>298,40</b>	-9,97	-12,60	21,75	11,36	-6,30	8,66	-0,32	16,48	30,28	-5,09
<b>861,12</b>	-16,10	-14,10	25,46	13,61	-7,05	9,01	-1,67	14,57	27,41	-9,94
<b>437,59</b>	-8,62	-6,21	16,35	7,61	-3,10	6,89	-0,06	17,57	32,19	-0,84
<b>362,13</b>	-6,70	-4,37	25,71	12,39	-2,19	6,70	-0,56	17,20	31,87	-0,90
<b>657,12</b>	-7,16	-8,04	19,36	9,81	-4,02	7,71	-0,12	17,48	32,04	-2,61
<b>363,90</b>	-7,47	-8,90	23,44	11,63	-4,45	7,85	-0,34	17,16	31,62	-2,57
<b>715,03</b>	-14,27	-14,29	23,45	12,51	-7,15	9,05	-0,85	15,08	27,96	-7,77
<b>399,11</b>	-10,10	-7,65	19,63	9,85	-3,83	7,42	-0,13	17,36	31,81	-1,73
<b>348,68</b>	-10,86	-13,86	23,86	12,63	-6,93	8,96	-0,84	15,32	28,38	-7,71
<b>925,40</b>	-13,94	-13,36	20,09	10,77	-6,68	8,84	-1,29	12,44	22,97	-5,79
<b>703,42</b>	-4,90	-0,14	16,93	6,87	-0,07	4,03	-0,06	17,75	32,53	0,97
<b>318,73</b>	-10,29	-11,38	25,95	13,69	-5,69	8,41	-0,85	16,39	30,43	-5,67
<b>380,63</b>	-7,13	0,02	11,82	3,68	0,01	3,35	-0,02	17,83	32,66	1,33
<b>329,59</b>	-10,44	-12,42	24,12	12,67	-6,21	8,75	-1,07	14,83	27,72	-5,83
<b>344,52</b>	-6,79	-4,35	17,69	7,99	-2,18	6,42	-0,08	17,64	32,34	-0,30
<b>309,62</b>	-8,11	-8,14	21,04	10,61	-4,07	7,79	-0,18	17,35	31,84	-2,26
<b>358,11</b>	-10,70	-13,75	22,70	12,04	-6,87	8,93	-0,47	16,11	29,59	-6,59
<b>405,36</b>	-14,06	-13,06	21,54	11,27	-6,53	8,80	-0,63	14,88	27,24	-6,04
<b>695,86</b>	-7,05	-3,47	19,88	8,77	-1,73	6,02	-0,13	17,60	32,30	0,07
<b>399,31</b>	-10,80	-11,80	26,36	14,07	-5,90	8,60	-1,06	16,09	30,00	-8,42

Continuación										
<b>AGB</b>	<b>VV</b>	<b>VV_ASM</b>	<b>VV_CON</b>	<b>VV_DIS</b>	<b>VV_ENE</b>	<b>VV_ENT</b>	<b>VV_COR</b>	<b>VV_MEA</b>	<b>VV_VAR</b>	<b>VV_HOM</b>
<b>490,98</b>	-6,80	-10,73	21,84	11,30	-5,37	8,28	-0,25	17,05	31,33	-3,81
<b>400,42</b>	-11,39	-13,21	22,30	11,82	-6,60	8,83	-0,33	16,63	30,60	-6,27
<b>629,89</b>	-8,93	-11,41	24,87	12,97	-5,71	8,43	-0,60	16,66	30,78	-4,72
<b>385,08</b>	-8,40	-9,19	20,35	10,18	-4,59	7,99	-0,16	17,33	31,81	-2,76
<b>457,35</b>	-7,93	-6,12	21,46	10,74	-3,06	7,39	-0,20	17,36	31,88	-1,66
<b>399,12</b>	-10,74	-13,21	24,72	13,23	-6,60	8,85	-0,66	16,36	30,22	-9,00
<b>500,13</b>	-10,34	-11,31	24,02	12,41	-5,66	8,47	-0,46	16,81	31,03	-5,16
<b>504,04</b>	-15,83	-13,63	24,78	13,17	-6,82	8,92	-1,17	15,09	28,05	-8,01
<b>540,30</b>	-8,16	-2,40	12,74	5,48	-1,20	5,29	-0,02	17,77	32,54	0,64
<b>370,79</b>	-11,22	-10,40	22,51	11,64	-5,20	8,24	-0,31	16,97	31,18	-4,24
<b>317,87</b>	-11,69	-13,16	22,98	12,30	-6,58	8,82	-0,38	16,71	30,74	-6,98
<b>451,94</b>	-8,62	-3,00	15,79	6,20	-1,50	5,09	-0,05	17,74	32,52	0,40
<b>608,48</b>	-10,43	-12,38	22,40	11,92	-6,19	8,65	-0,33	16,73	30,72	-5,85
<b>675,59</b>	-7,61	-8,50	21,18	10,69	-4,25	7,79	-0,19	17,38	31,91	-3,07
<b>638,32</b>	-10,79	-12,22	22,91	12,29	-6,11	8,62	-0,45	16,34	30,01	-6,77
<b>506,15</b>	-11,47	-13,42	24,07	12,80	-6,71	8,87	-0,72	15,83	29,25	-7,93
<b>638,24</b>	-7,77	-4,86	16,74	7,81	-2,43	6,43	-0,06	17,64	32,33	-1,11
<b>374,73</b>	-13,70	-13,47	22,17	11,87	-6,73	8,87	-0,68	14,99	27,55	-7,40
<b>401,29</b>	-17,13	-12,30	21,67	11,00	-6,15	8,63	-2,47	11,59	22,29	-4,72
<b>417,20</b>	-15,01	-13,69	24,26	12,78	-6,84	8,94	-1,03	15,02	28,00	-7,20
<b>361,45</b>	-7,25	-4,59	17,20	7,88	-2,29	6,10	-0,07	17,63	32,31	-0,26
<b>375,48</b>	-8,93	-7,87	23,74	12,25	-3,94	7,60	-0,38	17,08	31,47	-3,35
<b>707,58</b>	-8,03	-7,19	17,08	7,66	-3,59	7,38	-0,07	17,50	32,08	-0,66
<b>737,41</b>	-11,71	-11,62	27,78	14,55	-5,81	8,60	-1,24	16,46	30,81	-6,43
<b>848,54</b>	-13,28	-12,69	22,82	11,85	-6,34	8,80	-1,15	14,13	26,14	-4,68
<b>263,59</b>	-10,83	-12,78	27,55	14,63	-6,39	8,74	-2,16	15,06	28,60	-8,01
<b>721,09</b>	-15,71	-11,69	16,69	8,87	-5,85	8,47	-0,61	12,43	22,48	-3,46
<b>283,46</b>	-6,28	-8,16	21,02	10,65	-4,08	7,57	-0,18	17,38	31,88	-2,56
<b>689,02</b>	-13,00	-13,11	21,94	11,65	-6,55	8,81	-1,45	13,15	24,41	-6,26
<b>313,45</b>	-9,01	-13,06	25,56	13,46	-6,53	8,80	-0,94	15,91	29,65	-7,33
<b>655,75</b>	-14,27	-13,11	25,68	13,36	-6,55	8,81	-1,88	14,44	27,21	-7,07
<b>396,49</b>	-9,19	-8,13	20,14	10,16	-4,06	7,92	-0,18	16,85	30,95	-1,91
<b>479,01</b>	-16,87	-11,45	20,27	10,66	-5,72	8,48	-1,52	12,20	22,56	-4,76
<b>676,21</b>	-13,29	-12,64	27,90	14,70	-6,32	8,73	-2,67	14,61	28,27	-7,44
<b>634,90</b>	-11,04	-12,22	26,47	14,11	-6,11	8,69	-1,18	15,88	29,68	-7,26
<b>631,40</b>	-12,95	-13,69	24,70	12,97	-6,84	8,92	-0,92	15,50	28,90	-6,82

Continuación

<b>AGB</b>	<b>VV</b>	<b>VV_ASM</b>	<b>VV_CON</b>	<b>VV_DIS</b>	<b>VV_ENE</b>	<b>VV_ENT</b>	<b>VV_COR</b>	<b>VV_MEA</b>	<b>VV_VAR</b>	<b>VV_HOM</b>
<b>520,14</b>	-3,72	2,18	20,25	8,92	1,09	2,51	-0,14	17,64	32,38	1,26
<b>444,34</b>	-11,72	-12,82	21,86	10,77	-6,41	8,74	-1,58	12,73	24,01	-3,38
<b>847,33</b>	-12,51	-13,06	26,07	13,83	-6,53	8,78	-1,03	16,01	29,81	-7,30
<b>599,62</b>	-12,85	-10,76	16,90	8,92	-5,38	8,26	-0,73	12,16	22,02	-3,11
<b>420,60</b>	-13,82	-14,04	23,23	12,13	-7,02	9,00	-0,99	14,57	27,13	-6,46
<b>281,13</b>	-14,57	-13,92	23,76	12,53	-6,96	8,97	-0,90	15,13	28,03	-7,95
<b>353,85</b>	-10,83	-13,69	23,73	12,52	-6,84	8,94	-0,64	15,89	29,37	-7,78
<b>627,50</b>	-13,62	-13,36	22,73	12,29	-6,68	8,87	-1,91	12,90	24,21	-9,47
<b>329,12</b>	-7,35	-9,07	20,30	10,24	-4,54	7,81	-0,15	17,42	31,94	-2,71

## H. Anexo: Importancia de variables de Sentinel-2, Sentinel-1 y combinación para estimación de AGB de *E. grandis*.

Sentinel-2	
Variable	REDUCCIÓN DE EMC
B12	11,17
B11	9,49
B4	5,12
B5	3,32
B3	2,21
GNDVI <sub>RE3N</sub>	0,8
B8A	0,72
GNDVI	0,64
NDVI	0,54
B6	0,06
SAVI	0
B8	-1,18
B2	-1,87

Sentinel-1	
Variable	REDUCCIÓN DE EMC
$\sigma^{\circ}_{(VV)}$	7,10
Entropía <sub>(VH)</sub>	6,63
Correlación <sub>(VV)</sub>	5,47
Disimilitud <sub>(VH)</sub>	5,17
Varianza <sub>(VV)</sub>	4,81
Homogeneidad <sub>(VH)</sub>	4,55
ASM <sub>(VH)</sub>	4,52
Contraste <sub>(VV)</sub>	4,50
Contraste <sub>(VH)</sub>	4,47
Disimilitud <sub>(VV)</sub>	3,85
Media <sub>(VV)</sub>	3,75
$\sigma^{\circ}_{(VH)}$	3,59
ASM <sub>(VV)</sub>	2,89
Media <sub>(VH)</sub>	2,21
Varianza <sub>(VH)</sub>	1,87
Correlación <sub>(VH)</sub>	1,07
Entropía <sub>(VV)</sub>	0,91
Homogeneidad <sub>(VV)</sub>	0,53

**Sentinel-2 + Sentinel-1**

<b>Variable</b>	<b>REDUCCIÓN DE EMC</b>
B12	14,47
Media <sub>(VV)</sub>	9,97
B11	9,30
Varianza <sub>(VV)</sub>	6,29
$\sigma^{\circ}_{(VV)}$	5,03
Correlación <sub>(VV)</sub>	4,88
$\sigma^{\circ}_{(VH)}$	3,76
Entropía <sub>(VH)</sub>	2,91
Entropía <sub>(VV)</sub>	2,59
B4	2,51
Contraste <sub>(VV)</sub>	2,20
Disimilitud <sub>(VV)</sub>	2,10
SAVI	1,94
ASM <sub>(VH)</sub>	1,92
GNDVI <sub>RE3N</sub>	1,92
Disimilitud <sub>(VH)</sub>	1,70
B3	1,54
B5	1,20
Varianza <sub>(VH)</sub>	0,97
Contraste <sub>(VH)</sub>	0,94

## I. Anexo: Importancia de variables de Sentinel-2, Sentinel-1 y combinación para estimación de AGB de *P. spp.*

Sentinel-2	
Variable	REDUCCIÓN DE EMC
GNDVI	9,78
B3	9,69
B8	8,61
NDVI	8,08
B7	7,78
B2	7,34
SAVI	7,14
GNDVI <sub>RE3N</sub>	6,93
B8A	6,74
B6	6,62
B11	4,14
B5	3,79
B12	1,07
B4	1,01

Sentinel-1	
Variable	REDUCCIÓN DE EMC
$\sigma^{\circ}_{(VV)}$	6,20
Correlación <sub>(VV)</sub>	3,26
Media <sub>(VV)</sub>	-0,41
$\sigma^{\circ}_{(VH)}$	4,08
Varianza <sub>(VV)</sub>	5,12
Varianza <sub>(VH)</sub>	-0,94
Media <sub>(VH)</sub>	1,83
Homogeneidad <sub>(VH)</sub>	0,07
ASM <sub>(VV)</sub>	0,43
ASM <sub>(VH)</sub>	2,14
Entropía <sub>(VV)</sub>	1,44
Homogeneidad <sub>(VV)</sub>	0,28
Entropía <sub>(VH)</sub>	-3,18
Contraste <sub>(VH)</sub>	-1,53
Correlación <sub>(VH)</sub>	0,44
Disimilitud <sub>(VV)</sub>	2,84
Disimilitud <sub>(VH)</sub>	1,05
Contraste <sub>(VV)</sub>	0,59
$\sigma^{\circ}_{(VV)}$	0,43
Correlación <sub>(VV)</sub>	0,64

<b>Sentinel-2 + Sentinel-1</b>	
<b>Variable</b>	<b>REDUCCIÓN DE EMC</b>
B2	5,30
Media <sub>(VV)</sub>	4,58
B8A	4,58
$\sigma^\circ$ <sub>(VH)</sub>	4,28
B7	4,07
SAVI	3,79
GNDVI	3,49
Media <sub>(VH)</sub>	3,45
B6	3,41
B8	3,37
B3	3,32
$\sigma^\circ$ <sub>(VV)</sub>	3,29
NDVI	2,82
B5	2,72
Correlación <sub>(VV)</sub>	2,04
ASM <sub>(VV)</sub>	2,04
GNDVI <sub>RE3N</sub>	1,59
Contraste <sub>(VV)</sub>	1,48
B4	1,45
Varianza <sub>(VH)</sub>	0,89
Varianza <sub>(VV)</sub>	5,30

## J. Anexo: Datos de validación para AGB de *E. grandis*.

AGB obtenida en campo (t.ha <sup>-1</sup> )	AGB estimada (t.ha <sup>-1</sup> )			
	GNDVI <sub>re3n</sub>	GNDVI	NDVI	SAVI
149,22	184,49	154,69	178,21	183,53
153,35	174,70	170,72	194,63	192,67
158,34	137,09	179,70	213,81	207,51
160,88	169,09	164,98	187,76	182,23
161,60	172,85	165,50	196,04	178,15
173,30	214,01	211,77	212,52	203,53
177,10	131,25	131,20	175,95	178,44
178,65	212,80	210,10	213,16	196,57
197,81	184,75	181,11	193,93	197,32
200,94	221,04	205,28	208,50	198,37
203,32	157,79	148,17	189,05	175,84
210,39	171,78	180,87	193,16	193,99
213,48	178,31	143,39	170,48	178,80
222,31	174,89	167,95	190,78	185,79
228,32	176,63	209,02	196,60	174,92
230,52	177,40	187,09	212,28	184,63
250,83	227,18	223,59	216,51	208,68
255,80	221,28	203,26	210,07	199,46
272,83	211,10	206,58	224,82	206,54
282,40	230,19	218,63	215,11	208,47

AGB obtenida en campo (t.ha <sup>-1</sup> )	AGB estimada (t.ha <sup>-1</sup> )								
	VH	ASM	CON	DIS	ENT	COR	MEA	VAR	HOM
<b>149,22</b>	196,79	205,33	204,16	203,57	200,85	187,43	193,27	195,99	202,73
<b>153,35</b>	219,36	181,32	209,84	212,40	221,31	215,61	229,63	226,88	208,89
<b>158,34</b>	209,02	196,88	205,78	207,04	208,51	177,65	216,74	213,74	206,24
<b>160,88</b>	200,74	210,29	204,34	203,65	197,03	178,06	197,11	199,08	201,60
<b>161,60</b>	200,98	209,15	204,49	204,79	197,94	181,59	186,33	189,54	205,61
<b>173,30</b>	213,96	196,72	206,27	207,01	208,12	194,67	214,95	213,72	207,18
<b>177,10</b>	224,70	187,44	210,54	213,22	218,82	209,84	230,76	228,02	209,07
<b>178,65</b>	207,46	199,59	203,28	202,60	205,14	236,63	213,03	208,94	204,88
<b>197,81</b>	204,45	209,71	202,15	200,27	197,48	199,11	194,53	195,82	199,43
<b>200,94</b>	212,43	188,72	209,70	212,18	216,43	186,54	212,91	214,28	208,94
<b>203,32</b>	201,95	208,60	202,42	201,29	198,39	206,08	198,82	199,05	202,00
<b>210,39</b>	200,83	205,80	200,30	197,64	200,02	211,39	192,53	193,10	201,61
<b>213,48</b>	210,34	191,41	211,15	214,25	212,47	184,66	216,57	217,24	209,53
<b>228,32</b>	197,57	207,28	203,98	203,59	198,91	186,50	191,59	194,51	203,35
<b>230,52</b>	191,65	200,14	203,30	202,25	204,80	233,50	184,05	187,86	203,87
<b>250,83</b>	192,01	197,69	202,72	201,65	205,30	218,01	184,17	187,76	203,38
<b>255,80</b>	217,59	190,08	207,66	209,74	213,05	220,29	223,67	220,24	209,27
<b>272,83</b>	220,71	187,97	209,45	211,97	214,94	242,86	226,77	224,13	208,96
<b>282,40</b>	220,91	188,29	210,40	212,86	218,09	225,71	230,12	227,32	208,65

Donde VH: Polarización VH; ASM: Segundo Momento Angular; CON: Contraste; DIS: Disimilitud; ENE: Energía; ENT: Entropía; COR: Correlación; MEA: Media; VAR: Varianza; HOM: Homogeneidad.

AGB obtenida en campo (t.ha <sup>-1</sup> )	AGB estimada (t.ha <sup>-1</sup> )								
	VV	ASM	CON	DIS	ENT	COR	MEA	VAR	HOM
<b>149,22</b>	194,04	186,76	190,92	188,86	194,56	188,64	188,27	189,59	188,71
<b>153,35</b>	216,11	214,74	208,28	210,02	210,82	205,62	221,54	223,74	215,28
<b>158,34</b>	212,24	216,24	211,77	213,11	211,16	189,21	227,85	226,82	218,56
<b>160,88</b>	200,24	203,22	203,65	203,54	206,65	191,56	193,11	194,47	198,53
<b>161,60</b>	187,12	180,05	170,66	166,67	187,21	188,37	187,22	188,44	184,72
<b>173,30</b>	208,40	212,65	207,55	208,79	210,08	197,02	202,80	204,35	209,58
<b>177,10</b>	214,61	216,13	204,89	206,80	211,13	199,07	225,24	229,70	212,63
<b>178,65</b>	211,62	216,02	212,42	213,43	211,14	222,16	221,13	218,51	221,17
<b>197,81</b>	202,35	190,26	186,69	187,57	196,06	188,49	188,19	189,53	189,84
<b>200,94</b>	211,61	215,92	207,79	209,22	211,06	199,76	210,77	212,48	212,24
<b>203,32</b>	198,17	207,16	205,35	205,35	208,27	192,95	195,05	196,23	201,50
<b>210,39</b>	202,03	200,31	207,21	207,26	206,09	194,72	194,64	195,58	201,92
<b>213,48</b>	215,36	215,71	209,95	211,30	211,03	214,82	226,25	227,04	217,52
<b>228,32</b>	200,57	187,39	196,22	194,78	196,36	189,10	188,93	190,24	190,11
<b>230,52</b>	196,70	181,25	172,90	170,67	187,21	247,86	187,30	188,54	185,10
<b>250,83</b>	190,64	179,19	166,84	159,84	187,21	268,67	187,16	188,39	184,34
<b>255,80</b>	223,27	216,80	213,58	214,88	211,33	257,25	237,86	232,34	226,56
<b>272,83</b>	213,57	214,65	209,72	211,25	210,90	205,83	213,65	214,51	215,01
<b>282,40</b>	212,98	216,46	210,74	212,12	211,23	248,01	225,68	225,78	218,23

Donde VV: Polarización VV; ASM: Segundo Momento Angular; CON: Contraste; DIS: Disimilitud; ENE: Energía; ENT: Entropía; COR: Correlación; MEA: Media; VAR: Varianza; HOM: Homogeneidad.

## K. Anexo: Datos de validación para AGB de *P. spp.*

Especie	AGB obtenida en campo (t.ha <sup>-1</sup> )	AGB estimada (t.ha <sup>-1</sup> )			
		GNDVI <sub>re3n</sub>	GNDVI	NDVI	SAVI
<i>P. oocarpa</i>	361,45	501,87	500,15	496,08	492,15
<i>P. oocarpa</i>	437,59	507,09	508,86	495,33	497,17
<i>P. oocarpa</i>	506,15	463,49	463,64	479,12	471,85
<i>P. oocarpa</i>	638,32	468,02	464,32	476,53	463,17
<i>P. oocarpa</i>	657,12	509,98	516,17	499,89	501,64
<i>P. oocarpa</i>	715,03	513,31	510,70	499,80	498,29
<i>P. oocarpa</i>	735,33	486,38	491,52	486,92	496,26
<i>P. patula</i>	313,45	424,28	422,21	413,65	418,09
<i>P. patula</i>	329,12	443,91	449,89	461,79	430,94
<i>P. patula</i>	353,85	454,82	461,77	469,54	445,36
<i>P. patula</i>	380,63	448,95	453,25	454,38	456,70
<i>P. patula</i>	396,49	432,22	438,20	456,03	424,97
<i>P. patula</i>	400,42	460,26	463,12	460,96	469,42
<i>P. patula</i>	405,36	436,97	434,84	443,68	445,46
<i>P. patula</i>	490,98	433,58	437,74	448,59	443,53
<i>P. patula</i>	629,89	450,41	456,80	457,99	456,02
<i>P. patula</i>	631,40	459,14	463,53	466,08	440,10
<i>P. patula</i>	848,54	480,08	496,19	483,96	461,03
<i>P. tecunumanii</i>	387,87	481,06	479,86	484,14	478,03
<i>P. tecunumanii</i>	399,12	490,40	490,56	489,99	488,05
<i>P. tecunumanii</i>	457,35	490,62	496,48	484,66	499,59
<i>P. tecunumanii</i>	479,35	485,89	485,55	486,01	483,43
<i>P. tecunumanii</i>	492,69	486,48	488,04	489,09	486,70
<i>P. tecunumanii</i>	521,19	480,41	478,75	484,58	479,06

Especie	AGB obtenida en campo (t.ha <sup>-1</sup> )	AGB estimada (t.ha <sup>-1</sup> )								
		VH	ASM	CON	DIS	ENT	COR	MEA	VAR	HOM
<i>P. oocarpa</i>	313,45	455,32	471,07	489,46	447,63	489,47	456,81	433,96	463,88	462,72
<i>P. oocarpa</i>	329,12	412,23	457,73	515,01	511,21	507,59	416,99	447,44	449,32	469,51
<i>P. oocarpa</i>	353,85	475,85	490,89	492,30	503,57	487,78	396,21	403,70	410,94	486,09
<i>P. oocarpa</i>	361,45	409,62	457,73	538,14	536,84	507,59	480,28	426,91	428,36	439,02
<i>P. oocarpa</i>	380,63	431,97	475,79	526,97	522,15	495,99	455,10	426,79	431,37	479,09
<i>P. oocarpa</i>	387,87	501,22	522,19	439,75	440,73	464,26	419,10	510,00	520,34	512,12
<i>P. oocarpa</i>	396,49	437,82	457,73	503,64	503,41	506,83	454,27	459,94	463,64	468,48
<i>P. patula</i>	399,12	458,04	495,10	482,43	478,52	484,40	433,67	470,48	477,65	498,54
<i>P. patula</i>	400,42	497,34	505,46	443,31	444,00	474,28	415,83	499,85	510,15	511,21
<i>P. patula</i>	405,36	496,02	502,34	480,91	475,71	477,74	490,73	511,73	512,87	501,72
<i>P. patula</i>	437,59	436,47	484,41	468,61	469,18	490,60	415,90	464,35	474,71	488,73
<i>P. patula</i>	457,35	474,87	493,33	477,43	477,53	487,61	436,66	478,76	487,44	498,21
<i>P. patula</i>	479,35	454,02	470,25	504,74	503,92	500,45	445,04	449,38	455,84	462,39
<i>P. patula</i>	490,98	459,99	490,26	491,37	487,59	488,45	440,99	465,24	471,50	490,64
<i>P. patula</i>	492,69	501,29	516,74	453,19	450,99	468,13	443,15	519,70	526,86	509,32
<i>P. patula</i>	506,15	468,53	505,46	452,77	456,09	476,86	426,97	502,94	512,31	500,68
<i>P. patula</i>	521,19	427,49	477,30	536,55	535,07	495,67	508,29	442,42	440,49	468,60
<i>P. patula</i>	629,89	486,84	459,65	508,21	507,26	506,36	517,54	486,36	482,98	461,24
<i>P. tecunumanii</i>	631,40	465,94	467,74	508,62	505,43	500,77	542,04	494,61	488,35	479,80
<i>P. tecunumanii</i>	638,32	476,83	458,70	494,11	493,80	506,21	461,01	476,27	480,97	475,98
<i>P. tecunumanii</i>	657,12	413,29	461,53	511,96	508,92	505,13	429,00	425,38	431,41	477,36
<i>P. tecunumanii</i>	715,03	509,62	513,17	440,19	444,70	466,73	432,43	526,52	535,81	504,42
<i>P. tecunumanii</i>	735,33	486,78	514,97	440,85	445,40	465,53	417,05	505,13	515,62	508,84
<i>P. tecunumanii</i>	848,54	531,29	484,41	487,13	482,68	490,27	513,53	514,15	511,48	492,89

Donde VH: Polarización VH; ASM: Segundo Momento Angular; CON: Contraste; DIS: Disimilitud; ENT: Entropía; COR: Correlación; MEA: Media; VAR: Varianza; HOM: Homogeneidad.

Especie	AGB obtenida en campo (t.ha <sup>-1</sup> )	AGB estimada (t.ha <sup>-1</sup> )								
		VV	ASM	CON	DIS	ENT	COR	MEA	VAR	HOM
<i>P. oocarpa</i>	313,45	488,21	481,72	464,25	486,60	387,10	404,23	472,91	479,89	488,21
<i>P. oocarpa</i>	329,12	488,28	479,98	475,06	486,99	438,83	449,07	452,83	471,79	488,28
<i>P. oocarpa</i>	353,85	489,64	482,84	492,76	515,99	437,51	494,45	492,75	472,70	489,64
<i>P. oocarpa</i>	361,45	457,80	459,32	442,43	442,79	431,23	442,79	447,11	439,64	457,80
<i>P. oocarpa</i>	380,63	426,45	423,46	384,45	371,90	426,74	436,83	441,60	418,82	426,45
<i>P. oocarpa</i>	387,87	516,08	485,81	488,11	514,24	460,71	499,30	501,73	508,02	516,08
<i>P. oocarpa</i>	396,49	481,88	478,89	473,92	489,87	441,78	465,87	468,24	461,29	481,88
<i>P. patula</i>	399,12	516,42	509,48	516,36	513,82	484,99	480,43	479,59	554,23	516,42
<i>P. patula</i>	400,42	516,42	493,35	496,88	513,40	455,40	472,39	473,69	518,44	516,42
<i>P. patula</i>	405,36	515,41	488,26	489,31	512,38	481,96	524,52	525,80	515,45	515,41
<i>P. patula</i>	437,59	468,83	453,67	438,73	463,26	430,28	444,47	448,99	447,25	468,83
<i>P. patula</i>	457,35	468,22	487,70	482,02	476,25	443,38	450,68	453,75	457,98	468,22
<i>P. patula</i>	479,35	497,36	480,19	478,73	496,20	440,04	454,40	457,93	481,89	497,36
<i>P. patula</i>	490,98	499,60	490,28	489,76	498,97	447,89	459,80	462,25	486,20	499,60
<i>P. patula</i>	492,69	514,43	490,91	494,60	512,20	490,97	530,18	528,82	521,49	514,43
<i>P. patula</i>	506,15	517,83	505,13	510,47	514,32	489,92	496,23	494,65	540,21	517,83
<i>P. patula</i>	521,19	471,78	517,07	514,82	474,81	481,94	459,80	458,63	466,57	471,78
<i>P. patula</i>	629,89	504,22	510,43	512,74	502,94	479,04	471,55	470,80	498,06	504,22
<i>P. tecunumanii</i>	631,40	519,69	509,32	512,84	515,58	508,07	505,86	500,04	525,66	519,69
<i>P. tecunumanii</i>	638,32	509,70	497,41	503,35	507,85	465,51	481,08	482,81	525,05	509,70
<i>P. tecunumanii</i>	657,12	481,25	473,75	469,10	484,39	435,89	447,29	451,32	470,44	481,25
<i>P. tecunumanii</i>	715,03	523,79	501,00	506,46	518,85	501,82	518,58	514,67	538,15	523,79
<i>P. tecunumanii</i>	735,33	516,77	496,17	501,07	513,73	458,20	470,76	472,86	532,80	516,77
<i>P. tecunumanii</i>	848,54	512,87	496,77	497,27	512,63	529,19	546,86	542,88	497,53	512,87

Donde VH: Polarización VV; ASM: Segundo Momento Angular; CON: Contraste; DIS: Disimilitud; ENT: Entropía; COR: Correlación; MEA: Media; VAR: Varianza; HOM: Homogeneidad.

## Bibliografía

- Aguirre S., C. A. ., J. R. Valdez L., G. Ángeles P., H. M. de los Santos P., R. Haapanen y A. I. Aguirre S. 2009. Mapeo de carbono arbóreo aéreo en bosques manejados de pino Patula en Hidalgo, México. *Agrociencia* 43: 209-220.
- Ahamed, T., Tian, L., Zhang, Y., & Ting, K. C. (2011). A review of remote sensing methods for biomass feedstock production. *Biomass and Bioenergy*, 35(7), 2455–2469. <http://doi.org/10.1016/j.biombioe.2011.02.028>
- Anaya Acevedo, J. A., Chuvieco Salinero, E., & Palacios Orueta, A. (2008). Estimación de biomasa aérea en Colombia a partir de imágenes MODIS. *Revista de Teledetección. 2008. 30: 5-22.*
- Angarita, A. C. Q., & Gaitán, Y. L. M. (2016). Modelo regresivo para la estimación de biomasa aérea forestal a partir de datos de parcelas permanentes y datos Radar SAR ALOS PALSAR en el Parque Natural Bataclán, Cali. *UD y la geomática*, (11), 66-72.
- Asner, G. P., & Lobell, D. B. (2000). A biogeophysical approach for automated SWIR unmixing of soils and vegetation. *Remote sensing of environment*, 74(1), 99-112.
- Asner, G. P., Clark, J. K., Mascaró, J., Galindo García, G. A., Chadwick, K. D., Navarrete Encinales, D. A., ... & Balaji, A. (2012). High-resolution mapping of forest carbon stocks in the Colombian Amazon. *Biogeosciences*, 9(7), 2683-2696.
- Barrachina, M., Cristóbal, J., & Tulla, A. F. (2015). Estimating above-ground biomass on mountain meadows and pastures through remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 38, 184–192. <http://doi.org/10.1016/j.jag.2014.12.002>
- Behera, M. D., Tripathi, P., Mishra, B., Kumar, S., Chitale, V. S., & 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.

- 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), 303.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Calders, K., Newnham, G., Burt, A., Murphy, S., Raunonen, P., Herold, M., ... & Kaasalainen, M. (2015). Nondestructive estimates of above-ground biomass using terrestrial laser scanning. *Methods in Ecology and Evolution*, 6(2), 198-208.
- Conafor. (2015). Plantaciones forestales comerciales. Ver enlace: <http://www.conafor.gob.mx/web/temas-forestales/plantaciones-forestales/>
- Castañeda-Mendoza, A., Vargas-Hernández, J. J., & Gómez-Guerrero, A. (2012). Components of net aerial primary production in a *Bambusa oldhamii* plantation. *Agrociencia*, 46(1).
- Champion, I., Germain, C., Da Costa, J. P., Alborini, A., & Dubois-Fernandez, P. (2014). Retrieval of forest stand age from SAR image texture for varying distance and orientation values of the gray level co-occurrence matrix. *IEEE Geoscience and Remote Sensing Letters*, 11(1), 5-9.
- Clerici, N., Rubiano, K., Abd-Elrahman, A., Posada Hoestettler, J. M., & Escobedo, F. J. (2016). Estimating aboveground biomass and carbon stocks in periurban Andean secondary forests using very high resolution imagery. *Forests*, 7(7), 138.
- Corvalán, P., & Hernández, J. (2006). Cátedra de dasimetría. Facultad de Ciencias Forestales. Dpto. Manejo de Recursos Forestales.
- Collins, J. N., Hutley, L. B., Williams, R. J., Boggs, G., Bell, D., & Bartolo, R. (2009). Estimating landscape-scale vegetation carbon stocks using airborne multi-frequency polarimetric synthetic aperture radar (SAR) in the savannahs of North Australia. *International Journal of Remote Sensing*, 30(5), 1141-1159.
- Cracknell, M. J., & Reading, A. M. (2014). Geological mapping using remote sensing data: A comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. *Computers & Geosciences*, 63, 22-33.
- Cutler, M. E. J., Boyd, D. S., Foody, G. M., & Vetrivel, A. (2012). Estimating tropical forest biomass with a combination of SAR image texture and Landsat TM data: An

assessment of predictions between regions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70, 66-77.

IDEAM. (2009). Diseño del marco conceptual y metodológico del inventario forestal nacional. Departamento Administrativo Nacional de Estadística - DANE. *Instituto de Hidrología, Meteorología y Estudios Ambientales. Colombia*. 146 p.

de Araujo Barbosa, C. C., Atkinson, P. M., & Dearing, J. A. (2015). Remote sensing of ecosystem services: A systematic review. *Ecological Indicators*, 52, 430–443. <http://doi.org/10.1016/j.ecolind.2015.01.007>

de Miguel, S. M., & Gutiérrez, J. S. (2000). Estimación de biomasa en masas regulares por medio de imágenes de radar. In Ciencia y tecnología de la información geográfica en un mundo globalizado: X Congreso del Grupo de Métodos Cuantitativos, *Sistemas de Información Geográfica y Percepción remota* (p. 47).

Deng, S., Kato, M., Guan, Q., Yin, N., & Li, M. (2014). Estimating forest aboveground biomass by combining ALOS PALSAR and WorldView-2 data: A case study at Purple Mountain National Park, Nanjing, China. *Remote Sensing*, 6(9), 7878–7910. <http://doi.org/10.3390/rs6097878>

Drake, J. B., Knox, R. G., Dubayah, R. O., Clark, D. B., Condit, R., Blair, J. B., & Hofton, M. (2003). Above-ground biomass estimation in closed canopy neotropical forests using lidar remote sensing: factors affecting the generality of relationships. *Global ecology and biogeography*, 12(2), 147-159.

Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., & Meygret, A. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25-36.

Dube, T., Gara, T. W., Mutanga, O., Sibanda, M., Shoko, C., Murwira, A., ... & Hatendi, C. M. (2018). Estimating forest standing biomass in savanna woodlands as an indicator of forest productivity using the new generation WorldView-2 sensor. *Geocarto International*, 33(2), 178-188.

Eckert, S. (2012). Improved forest biomass and carbon estimations using texture measures from worldView-2 satellite data. *Remote Sensing*, 4(4), 810–829. <http://doi.org/10.3390/rs4040810>

- Englhart, S., Keuck, V., & Siegert, F. (2011). Aboveground biomass retrieval in tropical forests — The potential of combined X- and L-band SAR data use. *Remote Sensing of Environment*, 115(5), 1260–1271. <http://doi.org/10.1016/j.rse.2011.01.008>
- ESA. (2015). Sentinel-2 Products Specification Document. *European Space Agency. Thales Alenia Space*. 496 p.
- ESA. (2016). Sentinel-1. Product Definition. European Space Agency. 129 p.
- ESA, “Sen2Cor Configuration and User Manual.” 2016.
- Evans, J. (2009). Planted Forests. Uses, Impacts and Sustainability. Food and Agriculture Organization of the United Nations and CABI. pp.213.
- Fagan, M. E., Morton, D. C., Cook, B. D., Masek, J., Zhao, F., Nelson, R. F., & Huang, C. (2018). Mapping pine plantations in the southeastern US using structural, spectral, and temporal remote sensing data. *Remote sensing of environment*, 216, 415-426.
- FAO, 2010. Global Forest Resource Assessment FRA 2010.58 p.
- Fassnacht, F. E., Hartig, F., Latifi, H., Berger, C., Hernández, J., Corvalán, P., & 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.
- Fernández-Manso, O., Fernández-Manso, A., & Quintano, C. (2014). Estimation of aboveground biomass in Mediterranean forests by statistical modelling of ASTER fraction images. *International Journal of Applied Earth Observation and Geoinformation*, 31, 45–56. <http://doi.org/10.1016/j.jag.2014.03.005>
- Ferrazzoli, P., Guerriero, L., Pierdicca, N., & Rahmoune, R. (2011). Forest biomass monitoring with GNSS-R: Theoretical simulations. *Advances in Space Research*, 47(10), 1823-1832.
- Franklin, S. E., Waring, R. H., McCreight, R. W., Cohen, W. B., & Fiorella, M. (1995). Aerial and satellite sensor detection and classification of western spruce budworm defoliation in a subalpine forest. *Canadian Journal of Remote Sensing*, 21(3), 299-308.

- 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.
- Galindo G.A., Cabrera E., Vargas D.M., Pabón, H.R., Cabrera, K.R., Yepes, A.P., Phillips, J.F., Navarrete, D.A., Duque, A.J., García, M.C., Ordoñez, M.F. 2011. Estimación de la Biomasa Aérea usando Datos de Campo e información De Sensores Remotos. *Instituto de Hidrología, Meteorología, y Estudios Ambientales- IDEAM*. Bogotá D.C., Colombia. 52 p.
- Gao, Y., Lu, D., Li, G., Wang, G., Chen, Q., Liu, L., & Li, D. (2018). Comparative Analysis of Modeling Algorithms for Forest Aboveground Biomass Estimation in a Subtropical Region. *Remote Sensing*, 10(4), 627.
- Gayon, J. (2000). History of the concept of allometry. *Am. Zool.*, 40(5): 748–758.
- Ghasemi, N., Sahebi, M. R., & Mohammadzadeh, A. (2011). A review on biomass estimation methods using synthetic aperture radar data. *International Journal of Geomatics and Geosciences*, 1(4), 776.
- Ghosh, S. M., & 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.
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, 58(3), 289-298.
- Herold, M., Woodcock, C., Cihlar, M., Wulder, M., Arino, O., Achard, F., ... & Di Gregorio, A. (2009). Assessment of the status of the development of the standards for the Terrestrial Essential Climate Variables: T9 Land Cover. *FAO, GTOS report*.
- Grant, K., Wagner, M., Siegmund, R., Hartmann, S., Pol-van Dasselaar, A., Aarts, H. F. M., ... & Verloop, J. (2015). The use of radar images for detecting when grass is harvested and thereby improve grassland yield estimates. In *Grassland and forages in high output dairy farming systems. Proceedings of the 18th Symposium of the European Grassland Federation, Wageningen, The Netherlands, 15-17 June 2015*. (pp. 419-421). Wageningen Academic Publishers.

- Hlatshwayo, S. T., Mutanga, O., Lottering, R. T., Kiala, Z., & Ismail, R. (2019). Mapping forest aboveground biomass in the reforested Buffelsdraai landfill site using texture combinations computed from SPOT-6 pan-sharpened imagery. *International Journal of Applied Earth Observation and Geoinformation*, 74, 65-77.
- Herold, M., Woodcock, C., Cihlar, M., Wulder, M., Arino, O., Achard, F., ... & Di Gregorio, A. (2009). Assessment of the status of the development of the standards for the Terrestrial Essential Climate Variables: T9 Land Cover. FAO, GTOS report.
- Hill, M. J., & Hanan, N. P. (2013). Current approaches to measurement, remote sensing, and modeling in savannas. *Ecosystem Function in Savannas Measurement and Modeling at Landscape to Global Scales*, 515-545.
- Hosseini, M., & 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 observation and geoinformation*, 58, 50-64.
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote sensing of environment*, 83(1), 195-213.
- Indufor, (2012). Forest Stewardship Council (FSC). Strategic Review on the Future of Forest Plantations. ID 11914. October 4, 2012. Helsinki, Finland.
- Izagirre Azkutia, A. (2011). Evaluación de métodos de estimación de biomasa en cultivos de cereal a partir de imágenes de percepción remota radar.
- Johnston, K., Ver Hoef, J.M., Krivoruchko, K., 2001. Using ArcGIS Geostatistical Analyst. ESRI Press, Redlands, CA, 300 pp.
- Karlson, M., & Ostwald, M. (2016). Remote sensing of vegetation in the Sudano-Sahelian zone: A literature review from 1975 to 2014. *Journal of Arid Environments*, 124, 257–269. <http://doi.org/10.1016/j.jaridenv.2015.08.022>
- Kanke, Y., Tubaña, B., Dalen, M., & Harrell, D. (2016). Evaluation of red and red-edge reflectance-based vegetation indices for rice biomass and grain yield prediction models in paddy fields. *Precision agriculture*, 17(5), 507-530.
- Kleinn, C., Bhandari, N., & Fehrmann, L. (2006). Observations and measurements. Knowledge reference for national forest assessments, 41.

- Sinha, S., Jeganathan, C., Sharma, L. K., & Nathawat, M. S. (2015). A review of radar remote sensing for biomass estimation. *International Journal of Environmental Science and Technology*, 12(5), 1779-1792.
- Kuplich, T. M., Curran, P. J., & Atkinson, P. M. (2005). Relating SAR image texture to the biomass of regenerating tropical forests. *International Journal of Remote Sensing*, 26(21), 4829-4854.
- Landa, A. F. (2016). Lidar remote sensing applied to forest resources assessment (Doctoral dissertation, Universidad Politécnica de Madrid).
- Liang, S., Li, X., & Wang, J. (Eds.). (2012). Advanced remote sensing: terrestrial information extraction and applications. Academic Press.
- Liang, X., Kankare, V., Hyyppä, J., Wang, Y., Kukko, A., Haggrén, H., ... Vastaranta, M. (2016). Terrestrial laser scanning in forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*. <http://doi.org/10.1016/j.isprsjprs.2016.01.006>
- Liaw, A., & Wiener, M. (2002). Classification and regression by random Forest. *R news*, 2(3), 18-22.
- Liu, K., Wang, J., Zeng, W., & Song, J. (2017). Comparison and evaluation of three methods for estimating forest above ground biomass using TM and GLAS data. *Remote Sensing*, 9(4), 341.
- Lu, D., Chen, Q., Wang, G., Liu, L., Li, G., & Moran, E. (2016). A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. *International Journal of Digital Earth*, 9(1), 63-105.
- Lukeš, P., Stenberg, P., Rautiainen, M., Mottus, M., & Vanhatalo, K. M. (2013). Optical properties of leaves and needles for boreal tree species in Europe. *Remote Sensing Letters*, 4(7), 667-676.
- McRoberts, R. E., & Tomppo, E. O. (2007). Remote sensing support for national forest inventories. *Remote Sensing of Environment*, 110(4), 412-419.
- Méndez-González, J., Luckie-Navarrete, S. L., Capó-Arteaga, M. Á., & Nájera-Luna, J. A. (2011). Ecuaciones alométricas y estimación de incrementos en biomasa aérea y carbono en una plantación mixta de *Pinus devoniana* Lindl. y *P. pseudostrobus* Lindl., en Guanajuato, México. *Agrociencia*, 45(4), 479-491.

- Montagnini, F., & Jordan, C. F. (2005). Tropical forest ecology: the basis for conservation and management. *Springer Science & Business Media*.
- Muñoz Ferreras, J. M. (2008). Enfocado de imágenes de radar de apertura sintética inversa. Nuevas técnicas y aplicaciones (Doctoral dissertation, Telecomunicacion).
- Navarro, G., Caballero, I., Silva, G., Parra, P. C., Vázquez, Á., & 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.
- Navarro-Cerrillo, R. M., Trujillo, J., de la Orden, M. S., & Hernández-Clemente, R. (2014). Hyperspectral and multispectral satellite sensors for mapping chlorophyll content in a Mediterranean *Pinus sylvestris* L. plantation. *International Journal of Applied Earth Observation and Geoinformation*, 26, 88–96. <http://doi.org/10.1016/j.jag.2013.06.001>
- Olaya, V. (2014). Sistemas de información geográfica. 854.
- Oliver, C., & Quegan, S. (2004). Understanding synthetic aperture radar images. SciTech Publishing.
- Oliver, M. A., & Webster, R. (2014). A tutorial guide to geostatistics: Computing and modelling variograms and kriging. *Catena*, 113, 56-69.
- OROZCO, L., & BRUMER, C. (2009). Diseño del marco conceptual y metodológico del inventario forestal nacional. Bogota, Colombia.
- Ortiz-Reyes, A. D., Valdez-Lazalde, J. R., los Santos-Posadas, D., Héctor, M., Ángeles-Pérez, G., Paz-Pellat, F., & 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.
- Ospina, P., C. M., Restrepo, R. J. H., Peláez, C. A. R., Urrego, J. B., Bautista, J. A. G., Valencia, F. A. A., & Lotero, Ó. I. O. (2006). "Guías silviculturales para el manejo de especies forestales con miras a la producción de madera en la zona andina colombiana. El eucalipto-*Eucalyptus grandis* W. Hill ex Maiden". Federación Nacional de Cafeteros de Colombia-FEDERACAFE; Centro Nacional de Investigaciones del Café-CENICAFE; BANKENGRUPPE; Smurfit Kappa Cartón de Colombia S.A. Colombia. 53 p.

- Owens, J. N., Gyde L., H. & Evans, J. (2009). Forest Plantations. Forests And Forest Plants - Volume I. Encyclophedia of life support systems. United Nations Educational, Scientific and Cultural Organization. 413 p.
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217-222.
- Pandit, S., Tsuyuki, S., & Dube, T. (2018). Estimating above-ground biomass in sub-tropical buffer zone community Forests, Nepal, using Sentinel 2 data. *Remote Sensing*, 10(4), 601.
- Pardé, J., & Bouchon, J. (1994). Forest mensuration. Editorial Paraninfo SA.
- Peregon, A., & Yamagata, Y. (2013). The use of ALOS/PALSAR backscatter to estimate above-ground forest biomass: A case study in Western Siberia. *Remote Sensing of Environment*, 137, 139–146. <http://doi.org/10.1016/j.rse.2013.06.012>
- Periasamy, S. (2018). Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. *Remote Sensing of Environment*, 217, 537-549.
- Picard, N., Saint-André, L., & Henry, M. (2012). Manual de construcción de ecuaciones alométricas para estimar el volumen y la biomasa de los árboles: del trabajo de campo a la predicción.
- Pizaña, J. M. G., Hernández, J. M. N., & Romero, N. C. (2016). Remote Sensing-Based Biomass Estimation. In *Environmental Applications of Remote Sensing*. InTech.
- Prabhakara, K., Hively, W. D., & 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.
- Prodan, M., Peters, R., Cox, F., Real, P. (1997). Mensura forestal. Proyecto IICA/GTZ sobre agricultura, recursos naturales y desarrollo sostenible. Costa Rica. 568 p.
- Roy, P. S., Behera, M. D., & Srivastav, S. K. (2017). Satellite Remote Sensing: Sensors, Applications and Techniques.

- Saadat, H., Adamowski, J., Bonnell, R., Sharifi, F., Namdar, M., & Ale-Ebrahim, S. (2011). Land use and land cover classification over a large area in Iran based on single date analysis of satellite imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(5), 608–619. <http://doi.org/10.1016/j.isprsjprs.2011.04.001>
- Sacristán, V., Sabarain, C. E., & Romero Buitrago, V. (2017). Estimación de Carbono Contenido en la Biomasa de las Coberturas Boscosas Pertenecientes a la Microcuenca La Hermosa del Municipio La Palma Cundinamarca.
- Sadeghi, Y., St-Onge, B., Leblon, B., Prieur, J. F., & Simard, M. (2018). Mapping boreal forest biomass from a SRTM and TanDEM-X based on canopy height model and Landsat spectral indices. *International journal of applied earth observation and geoinformation*, 68, 202-213.
- 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.
- Schlegel, B. (2001). Estimación de la biomasa y carbono en bosques del tipo forestal siempreverde. In Simposio internacional medición y monitoreo de la captura de carbono en ecosistemas forestales (Vol. 18).
- Serrano, L., Filella, I., & Penuelas, J. (2000). Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. *Crop Science*, 40(3), 723-731.
- Sivasankar, T., Lone, J. M., Sarma, K. K., Qadir, A., & Raju, P. L. N (2018). The potential of multi-frequency multi-polarized ALOS-2/PALSAR-2 and Sentinel-1 SAR data for aboveground forest biomass estimation.
- Somers, B., Verbesselt, J., Ampe, E. M., Sims, N., Verstraeten, W. W., & Coppin, P. (2010). Spectral mixture analysis to monitor defoliation in mixed-aged *Eucalyptus globulus* Labill plantations in southern Australia using Landsat 5-TM and EO-1 Hyperion data. *International Journal of Applied Earth Observation and Geoinformation*, 12(4), 270–277. <http://doi.org/10.1016/j.jag.2010.03.005>
- Smurfit-Kappa. (2009). Departamento de Investigación Forestal Smurfit Kappa Colombia, Área : Silvicultura y Productividad.

- Soria R., J. y R. Granados R. 2005. Relación entre los índices de vegetación obtenidos de los sensores AVHRR del satélite NOAA Y TM del *Landsat*. *Ciencia Ergo Sum* 12 (2): 167-174.
- Thenkabail, P. S., Stucky, N., Griscom, B. W., Ashton, M. S., Diels, J., Van Der Meer, B., & Enclona, E. (2004). Biomass estimations and carbon stock calculations in the oil palm plantations of African derived savannas using IKONOS data. *International Journal of Remote Sensing*, 25(23), 5447-5472.
- Tilly, N., Aasen, H., & Bareth, G. (2015). Fusion of plant height and vegetation indices for the estimation of barley biomass. *Remote Sensing*, 7(9), 11449–11480. <http://doi.org/10.3390/rs70911449>
- Tobler, W. (2004). On the first law of geography: A reply. *Annals of the Association of American Geographers*, 94(2), 304-310
- Toth, C., & Józków, G. (2016). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22-36.
- Vafaei, S., Soosani, J., Adeli, K., Fadaei, H., Naghavi, H., Pham, T. D., & Tien Bui, D. (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), 172.
- Laurin, G. V., Puletti, N., Hawthorne, W., Liesenberg, V., Corona, P., Papale, D., ... & Valentini, R. (2016). Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. *Remote Sensing of Environment*, 176, 163-176.
- Wang, L., Zhou, X., Zhu, X., Dong, Z., & Guo, W. (2016). Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. *The Crop Journal*. <http://doi.org/10.1016/j.cj.2016.01.008>
- Winck, R. A., Fassola, H. E., Barth, S. R., Crechi, E. H., Keller, A. E., Videla, D., & Zaderenko, C. (2015). Modelos predictivos de biomasa aérea de *Eucalyptus grandis* para el noreste de Argentina. *Ciência Florestal*, 25(3), 595-606.
- Yepes A.P., Navarrete D.A., Duque A.J., Phillips J.F., Cabrera K.R., Álvarez, E., García, M.C., Ordoñez, M.F. 2011. Protocolo para la estimación nacional y

subnacional de biomasa - carbono en Colombia. Instituto de Hidrología, Meteorología, y Estudios Ambientales-IDEAM-. Bogotá D.C., Colombia. 162 p.

Zhao, P., Lu, D., Wang, G., Liu, L., Li, D., Zhu, J., & Yu, S. (2016). Forest aboveground biomass estimation in Zhejiang Province using the integration of Landsat TM and ALOS PALSAR data. *International Journal of Applied Earth Observation and Geoinformation*, 53, 1–15.

<http://doi.org/10.1016/j.jag.2016.08.007>