

**METODOLOGÍA PARA LA ESTIMACIÓN DE LA BIOMASA AÉREA Y
STOCK DE CARBONO POR MEDIO DE SENSORES REMOTOS.**

DARWIN DAVID PÉREZ GONZÁLEZ



**FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA
INGENIERÍA TOPOGRÁFICA
SANTIAGO DE CALI**

2022

**METODOLOGÍA PARA LA ESTIMACIÓN DE LA BIOMASA AÉREA Y
STOCK DE CARBONO POR MEDIO DE SENSORES REMOTOS.**

DARWIN DAVID PÉREZ GONZÁLEZ

Trabajo de grado para optar por el título de Ingeniero Topográfico

Director

FRANCISCO LUIS HERNÁNDEZ TORRES, MSc.



**FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA
INGENIERÍA TOPOGRÁFICA
SANTIAGO DE CALI**

2022

Nota de aceptación

Director

Jurado

Jurado

DEDICATORIA

A Dios, por darme la fortaleza y el coraje para sobreponerme a momentos de dificultad.

A mi amado e inolvidable padre, por su amor y consejos, estés donde estés. ¡A ti te debo lo que soy!

A mi inteligente y aguerrida madre, por su apoyo y paciencia todo estos años. ¡Que nunca me faltes!

AGRADECIMIENTOS

A mi director Francisco Luis Hernández Torres, por su orientación, tiempo y conocimiento en la realización de este trabajo de grado.

A la Universidad del Valle y sus docentes, por el conocimiento y las vivencias a lo largo de estos años.

A mis demás familiares y amigos, por brindarme su apoyo y ánimo en todo el proceso.

Contenido

Acrónimos.....	9
RESUMEN	1
INTRODUCCIÓN	2
1 PLANTEAMIENTO DEL PROBLEMA.....	3
2 OBJETIVOS	4
2.1 OBJETIVO GENERAL	4
2.2 OBJETIVOS ESPECÍFICOS.....	4
3 JUSTIFICACIÓN	4
4 MARCO CONCEPTUAL.....	5
5 MARCO REFERENCIAL	8
6 MARCO TEORICO.....	10
6.1 Preprocesamiento de imágenes satelitales	10
6.2 Matriz de Co-ocurrencia de nivel de grises (GLCM)	15
6.3 Índices de vegetación	17
6.4 Índices Radar.....	18
6.5 Modelos de regresión	19
7 METODOLOGÍA	25
7.1 Localización	25
7.2 Equipos y Materiales.....	26
7.3 Métodos.....	28
8 RESULTADOS.....	31
9 DISCUSION	41
10 CONCLUSIONES	43
11 BIBLIOGRAFÍA	44

Tabla de tablas

Tabla 1. Características imágenes Sentinel 1	27
Tabla 2. Características imagen Landsat 8.....	27
Tabla 3. Característica DEM.....	27
Tabla 4. Datos de parcelas de campo	28
Tabla 5. Sumario del modelo de regresión radar.....	34
Tabla 6. Sumario del modelo de regresión óptico.....	35
Tabla 7. Sumario del modelo de regresión combinado	35
Tabla 8. Supuesto de independencia.	36
Tabla 9. Supuesto de normalidad.	36
Tabla 10. Supuesto de homocedasticidad	37
Tabla 11. Análisis de varianza (ANOVA) modelo radar.	37

Tabla 12. Análisis de varianza (ANOVA) modelo óptico.	37
Tabla 13. Análisis de varianza (ANOVA) modelo combinado.....	37
Tabla 14. Validación	38

Tabla de figuras

Figura 1. Relación de planos de superficie e imagen SAR	14
Figura 2. Regiones de contraste Durbin Watson	23
Figura 3. Localización SFF Iguaque	26
Figura 4. Diagrama metodológico.....	29
Figura 5. Matriz de co-ocurrencia polarización VV. a) máxima probabilidad, b) varianza, c) media, d) contraste, e) disimilitud, f) correlación, g) energía, h) entropía, i) homogeneidad y j) ASM.....	32
Figura 6. Matriz de co-ocurrencia polarización VH. a) máxima probabilidad, b) varianza, c) media, d) contraste, e) disimilitud, f) correlación, g) energía, h) entropía, i) homogeneidad y j) ASM.....	32
Figura 7. Clasificación a color de los índices de radar obtenidos. a) NL, b) promedio, c) NDI, d) ratio 1, e) ratio 2 y, f) diferencia.	33
Figura 8. Clasificación a color de los índices ópticos obtenidos. a) NDVI y b) SAVI.....	33
Figura 9. Autocorrelación espacial índice Moran.	34
Figura 10. Agrupación valores de Ba con sus vecinos.....	34
Figura 11. Diagrama de dispersión Ba observada y predicha modelo radar.	39
Figura 12. Diagrama de dispersión Ba observada y predicha modelo óptico.	39
Figura 13. Diagrama de dispersión Ba observada y predicha modelo combinado.	40
Figura 14. Estimación Ba observada y predicha por parcela.	40
Figura 15. Distribución espacial de biomasa aérea predicha	41
Figura 16. Distribución espacial del Carbono predicho.	41

Acrónimos

AGB	<i>The Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>
CMNUCC	<i>Convención Marco de las Naciones Unidas Sobre el Cambio Climático</i>
DEM	<i>Digital Elevation Model</i>
ND	<i>Número Digital</i>
FAO	<i>Organización de las Naciones Unidas para la Alimentación y la Agricultura</i>
GEI	<i>Gas de Efecto Invernadero</i>
GLCM	<i>Grey Level Co-Occurrence Matrix</i>
GPS	<i>Global Positioning System</i>
IDEAM	<i>Instituto de Hidrología, Meteorología y Estudios Ambientales de Colombia</i>
IPCC	<i>Intergovernmental Panel on Climate Change</i>
Kg/par	<i>Kilogramo/parcela</i>
LIDAR	<i>Light Detection and Ranging</i>
MDL	<i>Mecanismo de Desarrollo limpio</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
OLI	<i>Operational Land Imager</i>
PNN	<i>Parques Nacionales Naturales de Colombia</i>
PSA	<i>Pagos por Servicios Ambientales</i>
RADAR	<i>Radio Detection and Ranging</i>
REDD	<i>Reducción de Emisiones derivadas de la Deforestación y la Degradación</i>
SAR	<i>Synthetic Aperture Radar</i>
SAVI	<i>Soil Adjusted Vegetation Index</i>
SFFI	<i>Santuario de Fauna y Flora Iguaque</i>
Ton/ha	<i>Tonelada hectárea</i>
TOA	<i>Top of Atmosphere</i>

RESUMEN

Actividades antropogénicas como la deforestación conllevan a la liberación de gases de efecto invernadero causando el aumento del calentamiento global. Por ello, distintas entidades gubernamentales y privadas ven la necesidad de crear mecanismo que permitan reducir el impacto de estas actividades. Por lo anterior, la Teledetección es clave para el monitoreo de los ecosistemas forestales. En este estudio, se estimó el contenido de biomasa aérea (AGB) y Carbono (C) del Santuario de Fauna y Flora Iguaque (SFFI) en Boyacá, Colombia, con técnicas de percepción remota.

A partir de datos derivados de radar de apertura sintética (SAR, por sus siglas en inglés) de Sentinel-1, se calcularon imágenes de texturas para ambas polarizaciones (VV, VH), así como seis índices de vegetación basados en radar. Adicionalmente se calcularon dos índices de vegetación NDVI y SAVI derivados de Landsat 8. Estas variables se correlacionaron con los datos de campo, mediante un modelo de regresión múltiple, donde se obtuvieron tres modelos de regresión que comprenden datos radar, datos ópticos y combinados. Se evaluaron los modelos obtenidos mediante pruebas de hipótesis que comprende normalidad, linealidad y homocedasticidad. El modelo múltiple óptico no paso la prueba de independencia, por ende, se descartó. Los modelos radar y combinado se les aplicó el método de validación cruzada arrojando RMSE 16.91 kg/parcela y 190.37 kg/parcela para cada modelo respectivamente. Por lo anterior, el modelo de radar fue el mejor con un coeficiente de determinación R^2 igual 0.94. Una vez obtenido el mejor modelo, se estimó y mapeo la distribución espacial de AGB y C del Santuario de Fauna y Flora Iguaque.

PALABRAS CLAVE:

GLCM, percepción remota, retrodispersión radar, Sentinel, índices de vegetación,

INTRODUCCIÓN

El cambio climático ha tomado relevancia desde mediados del siglo pasado hasta la actualidad, debido al incremento de las actividades antropogénicas como deforestación y degradación que aportan del 15% al 20% de las emisiones de gases de efecto invernadero (GEI), según cifras del Panel Intergubernamental sobre el Cambio Climático (IPCC, por sus siglas en inglés) (IPCC, 2007). A causa de estas emisiones, se estima que la temperatura global aumentará aproximadamente 2 C° para el año 2100 (IPCC, 2013). En términos locales, en Colombia se emiten 258 millones de toneladas anualmente del principal GEI, dióxido de Carbono (CO₂), según el Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM) (IDEAM et al., 2015).

Para contrarrestar esta situación entidades internacionales de conservación de la naturaleza, gubernamentales y privadas, han contribuido a la creación de estrategias de mitigación del cambio climático aportando incentivos económicos, facilitando el intercambio de tecnología y conocimiento a países o proyectos encaminados en manejo sostenible sobre áreas protegidas, recuperación de zonas afectadas por deforestación o degradación, entre otros. (IPCC, 2007; Garcia et al., 2015)

En Colombia existen 56 áreas protegidas entre las cuales se encuentra el Santuario de Flora y Fauna Iguaque SFFI, ubicado en el departamento de Boyacá (Villarreal et al., 2017); de ahí, que sea un sitio a tener en cuenta en proyectos de mitigación del cambio climático. Con esto, no solo se contribuye a reforzar las medidas de protección y manejo del santuario, también a los incentivos económicos que se pueden obtener de él (FAO, 2008). Por lo anterior, el país tiene el potencial de contribuir a la reducción del cambio climático con el manejo de sus recursos naturales.

La estimación de biomasa aérea (AGB. Por sus siglas en inglés) juega un papel importante en este ámbito, ya que en ella se almacena CO₂ presente en la atmósfera, por medio de la fotosíntesis (Artetxe et al., 2016). Sin embargo, su estimación con métodos directos resulta un trabajo dispendioso, de alto costo y es contraproducente para el equilibrio de ecosistemas como el SFFI, por la presencia de especies endémicas y su importante aporte hídrico (Gibbs et al., 2007; Villarreal et al., 2017). Por ello, se han implementado diversas metodologías para la estimación de AGB de una manera adecuada. Una de las técnicas empleadas es la percepción remota, que permite obtener información de la superficie terrestre sin entrar en contacto con ella (Rosenqvist et al., 2003).

En este trabajo de investigación, se utilizará la percepción remota como herramienta para estimar biomasa aérea y stock de Carbono. También, se estudiará el comportamiento de la relación de datos obtenidos en campo para determinar el AGB relacionados con las mediciones espectrales y de retrodispersión obtenidas de sensores remotos. Se generó un modelo de regresión Múltiple que permitió establecer la exactitud de los contenidos de AGB y C. Finalmente, con el modelo obtenido, se generó cartografía de los contenidos de AGB y C del PNN.

Con los resultados obtenidos en este estudio, se demostró que el uso de datos SAR de Sentinel-1, disponibles de manera gratuita son una alternativa adecuada para estimación de AGB y C, y, por ende, el potencial de aplicación de la metodología aquí planteada es alta. También es un primer acercamiento de lo que podría ser la implementación de técnicas SAR y con esto contribuir a la protección y conservación de los ecosistemas presentes en el Santuario de Fauna y Flora Iguaque.

1 PLANTEAMIENTO DEL PROBLEMA

El cambio climático es uno de los problemas más importantes a escala global. En la actualidad, diversos estudios muestran como de manera directa afecta a la biodiversidad, las fuentes hídricas y en general, a los seres humanos (Arribas et al., 2012; Cevallos & Parrado., 2018). Por ello, la Convención Marco de las Naciones Unidas para el Cambio Climático (CMNUCC) tiene entre sus objetivos la reducción de los seis principales gases de efecto invernadero (GEI), entre ellos el CO₂. Para esto, han desarrollado proyectos forestales como Reducción de Emisiones por Deforestación y Degradación de bosques (REDD), los Mecanismos de Desarrollo Limpio (MDL) y Mercado Voluntario de Carbono, que se basan en el potencial de los ecosistemas forestales y agroforestales para el almacenamiento de Carbono (C) en la biomasa forestal (ramas, tronco, hojas, raíces, necromasa) contribuyendo económicamente a los países en donde se ejecuten este tipo de proyectos (IPCC, 2007).

Sin embargo, a nivel nacional debido a los conflictos de interés entre los lineamientos del gobierno para la preservación de zonas protegidas y las comunidades que las ocupan, no existe un equilibrio entre la conservación y el aprovechamiento de los bienes y servicios ambientales (Cano, 2008). Esto sumado al incremento de más del 100% en la tasa de deforestación en algunas zonas protegidas del país en comparación a otros años, los más de 258 millones de toneladas anuales de CO₂ que según el IDEAM et al., (2015), en Colombia se generan, el asentamiento ilegal de nuevas comunidades desplazadas, el conflicto armado y la falta de recursos técnicos y económicos por parte del gobierno, afectan directamente los planes de conservación y el equilibrio del ecosistema (Clerici et al., 2020; Montoya, 2019).

En el ámbito local, el Santuario de Fauna y Flora Iguaque (SFFI) es una de las áreas protegidas a nivel nacional, y ha tomado relevancia por su biodiversidad de fauna y flora, ser fuente hídrica principal para la zona rural y urbana de varios municipios como Villa de Leyva, Arcabuco, Chíquiza, así como los endemismos de Fauna y Flora (Pava, Mazama, Frailejones, entre otros) que alberga. Sin embargo, no han sido suficientes los esfuerzos de preservación y conservación, pues el santuario afronta diferentes perturbaciones en sus ecosistemas debido a prácticas como tala indiscriminada de árboles, ganadería extensiva, cambio de uso del suelo, ecoturismo e incendios forestales (Legro & Tarazona, 2014; Villarreal et al., 2017). Tan solo los incendios forestales representan la principal perturbación que históricamente no solamente degrada y altera el paisaje, sino que también los ecosistemas tan frágiles como el bosque alto andino o páramo tienden a transformarse y, por ende, su composición florística y variedad de especies se ve disminuida (Fernández et al., 2016).

Por otra parte, dado que la estimación de AGB es un requisito elemental en proyectos forestales, se han desarrollado dos métodos que generalmente se utilizan para tal fin. El primer método directo o destructivo, consiste en cosechar la biomasa aérea de una pequeña área, secarla, pesarla para estimar el contenido de C presente en la planta (Eggleston et al., 2006). Sin embargo, y cuando este método es de baja incertidumbre es una técnica destructiva, que conlleva alto costo, mayor tiempo de ejecución y logística según Gibbs, et al., (2007). El segundo método indirecto, calcula la biomasa del árbol con ecuaciones o modelos matemáticos calculados por medio de análisis de regresión entre variables de los árboles (Rügnitz et al., 2009). Si bien, es un método no destructivo y de menor costo económico, cuenta con sus limitaciones en logística y tiempo que no es conveniente aplicarlo en proyectos a gran escala.

Por lo anterior, dado que la estimación de AGB es un factor importante para los proyectos de mitigación del cambio climático y a su vez, la conservación de áreas protegidas y que, además, los métodos directos e indirectos utilizados en áreas susceptibles como el SFF Iguaque, no son los más propicios, surge la siguiente pregunta: ¿cómo estimar la biomasa aérea y stock de carbono empleando un método que proporcione información confiable, minimice tiempo y costos?

2 OBJETIVOS

2.1 OBJETIVO GENERAL

Estimar el contenido de biomasa aérea y stock de Carbono del Santuario de Fauna y Flora Iguaque, ubicado en Boyacá – Colombia, con técnicas de percepción remota.

2.2 OBJETIVOS ESPECÍFICOS

- Relacionar datos de referencia de biomasa con datos derivados de Radar y Ópticos
- Identificar el modelo matemático que permita estimar la biomasa área.
- Generar mapas de la distribución espacial de la biomasa aérea y Carbono de la zona de estudio.

3 JUSTIFICACIÓN

Los proyectos forestales como REDD o MDL, contribuyen no solo a la regulación de las concentraciones de GEI presentes en la atmosfera, sino que también al intercambio de tecnología y conocimiento entre países, además, de incentivos económicos por medio de los Mercados de Carbono (Salgado, 2004; Tamiotti, et al., 2009). Para su desarrollo es primordial hacer una estimación de AGB, sin embargo, los métodos convencionales resultan ser de alto costo, lentos y dispendiosos, en otras palabras, se encuentran condicionados espacial y temporalmente. Por lo tanto, es importante implementar un método que se ajuste a las dimensiones de los proyectos y que genere incertidumbres aceptables a un coste y tiempo mínimos.

según IDEAM et al., (2015), el 52% del territorio de Colombia pertenece a bosque y que estos juegan un papel importante en el almacenamiento de C, actividades de deforestación y degradación estos stocks pueden ser liberados, lo que representaría una amenaza para la estabilización del cambio climático. Por ende, cualquier medida o investigación que gire en torno a estos ecosistemas tienen un valor agregado. Ahora bien, el Santuario de Flora y Fauna Iguaque (SFFI), es una de las áreas protegidas de Colombia, está localizada en el departamento de Boyacá, cuenta con una extensión de 6.750 ha, posee Fauna endémica (Oso de antejo, Pavas, Lora aliamarilla, ente otros) y ecosistemas naturales andinos como bosques y paramos, importantes en el sistema de Parques Nacionales Naturales, además de ser el principal proveedor hídrico para poblaciones rurales y urbanas (Villarreal et al., 2017). Dadas estas características, el SFFI, podría optar por incentivos económicos a través de los PSA, fortaleciendo los planes de conservación y manejo, de las autoridades y comunidades encargadas (Gómez, 2018; Miranda, 2014). Con base a lo anterior, la estimación de AGB en SFFI es un variable clave para la toma de decisiones en pro de la conservación y manejo.

Además, contribuye en estrategias para abordar el cambio climático y optar por mecanismo de financiamientos externos como Bonos de Carbón, Pagos por Servicios Ambientales, entre otros.

Sin embargo, la cuantificación de AGB tradicionalmente se basa en métodos directos o indirectos que conllevan a grandes costos y tiempos. En la actualidad, nuevos métodos contribuyen en la solución de estas limitaciones, haciendo uso combinado de datos de campo con imágenes de satélite obtenidas con técnicas de percepción remota de fácil adquisición y bajo costo. Para obtener dichas imágenes se han utilizado sensores de diversos tipos como el activo: Radar de Apertura Sintética (SAR, por sus siglas en inglés) de banda L (Hamdan et al., 2011) que permiten capturar la señal (retrodispersión) que resulta de la interacción entre el sensor y las ramas o tronco; para el SAR de banda C (Argamosa et al., 2018), la retrodispersión interactúa desde la parte alta del dosel y hojas. También el uso de sensores tipo pasivos de plataformas como Landsat (Perea, 2018) que por medio de reflectancia de la vegetación permiten correlacionar los datos de inventarios forestales y el uso combinado entre ambos tipos de sensores como Sentinel-1 y Sentinel-2 para estimación de AGB (Chang & Shoshany, 2016). Por lo anterior que el uso de las imágenes resulta ser más eficientes debido a las escalas temporales y espaciales que maneja, la reducción de tiempos de ejecución, además de no ser un método destructivo. Por ello, en esta investigación se ha optado por estos nuevos métodos como herramienta en la captura de información para la estimación de biomasa aérea.

4 MARCO CONCEPTUAL

En esta sección se encuentran todos aquellos términos, definiciones o palabras que hacen parte de este proceso de investigación:

- **Cambio climático:**

Para la Convención Marco de las Naciones Unidas Sobre el Cambio Climático (CMNUCC) en su artículo 1, lo define como un cambio de clima atribuido directa o indirectamente a la actividad humana que altera la composición de la atmósfera mundial y que se suma a la variabilidad natural del clima observada durante periodos de tiempo comparables. (Unidas, 1992). También, cabe mencionar que el cambio climático no sólo conlleva un aumento de las temperaturas, sino también fenómenos meteorológicos extremos, la elevación del nivel del mar y cambios en las poblaciones, entre otros efectos (IPCC, 2007).

- **Gases de efecto invernadero (GEI):**

Son los componentes gaseosos presentes en la atmósfera. Dichos gases provienen de fuentes naturales o causados por procesos antropogénicos. tienen la capacidad de retener y emitir radiación en forma de calor, aportando al aumento de la temperatura global. En la atmósfera existen diferentes composiciones de gases presentes, pero los primarios son el vapor de agua (H₂O), dióxido de carbono (CO₂), ozono (O₃), metano (CH₄) y óxido nitroso (N₂O) (IPCC, 2013).

- **Dióxido de carbono:**

Es un gas de origen natural, que puede ser producido por la combustión de combustibles fósiles, la quema de biomasa, cambios en el uso del suelo y de diversos procesos industriales. Es el principal de GEI, además, se utiliza como referencia para medir otros gases de efecto invernadero (IPCC, 2013).

- **Proyectos forestales:**

Este tipo de proyecto va ligado a la conservación o recuperación de los bosques. También se relacionan a una gran variedad de actividades económicas: agricultura, industria, pastoreo, energía y conservación del agua (Gregersen et al., 1995).

- **Pagos por servicio ambiental:**

Hace referencia a los incentivos económicos que reciben las entidades que se encargan de la conservación, manejo y control de áreas de alto valor ambiental. Ciertamente, el proveedor de dichos servicios debe cumplir con diferentes requisitos por parte del comprador para hacer la negociación, además, requiere de monitoreo para determinar niveles de cumplimiento.

- **Áreas protegidas:**

Las Áreas Protegidas son áreas definidas geográficamente que han sido designadas, reguladas y administradas para alcanzar objetivos específicos de conservación. Estas Áreas protegidas pueden ser de diferentes tipos y corresponden a una categoría de manejo dependiendo el tipo de fauna y flora, escala de gestión (nacional, regional o local), estado de conservación y actividades que en estas se permitan (Parques Nacionales Naturales de Colombia, 2013).

- **Inventario forestal:**

El inventario forestal es un proceso sistemático mediante el cual se obtienen datos cualitativos y cuantitativos de manera fiable y específica del ecosistema de bosque, para posteriormente ser utilizada en la planeación, ordenación, conservación, reforestación, con un nivel de precisión, exactitud y detalle requeridos. Un inventario forestal, además, se compone de variables como: área, ubicación, tipos de bosque presentes, estructura, calidad, condiciones, volumen, tamaño, composición, etc. (FAO, 2004).

- **Biomasa:**

Es la cantidad total de materia viva presente en un ecosistema de bosque. Se pueden distinguir de dos tipos vegetal y animal. En el caso de la biomasa vegetal, resulta de la interacción química de las plantas con la radiación solar (fotosíntesis). Además, se clasifica en varios tipos según en donde se almacena que son biomasa aérea, detritos o madera muerta, biomasa subterránea o sistema radical y suelos de acuerdo con la Orientación de las buenas prácticas del IPCC, (2013).

- **Stock de carbono:**

Es el contenido de carbono presente en un tipo de bosque o vegetación. Existen tres tipos de compartimientos donde se aloja, que son la biomasa aérea, biomasa subterránea y biomasa muerta o necromasa. Cuando se estima la cantidad de biomasa presente en un ecosistema se

aplica un factor de conversión que permite conocer el contenido de carbono. Según Eggleston et al., (2006) ese factor es de 0,5.

- **Modelo Digital de Elevación (MDE):**

Los MDE Son representaciones matriciales tipo ráster que poseen información de coordenadas asociadas a una altura de manera que se evidencie tanto visual como matemáticamente y permita conocer el relieve de determinada zona. La resolución de estos modelos depende de los datos con los que se fabrique y está en función del tamaño del píxel.

- **Sensores remotos:**

Técnica conocida también como teledetección o detección remota, con la que se captura la información a diversas escalas de objetos o fenómenos por medio de instrumentos de medición llamados sensores, sin que el sensor y el objeto entre en contacto directo. En detección remota existen dos categorías: pasivos y activos. Los sensores pasivos miden la luz solar reflejada por los objetos, por lo cual, no puede detectar interacciones durante la noche. Por otro lado, los sensores activos, emiten su propia señal y no depende de la radiación solar para funcionar (Chuvieco, 1990).

- **Resolución espacial:**

La resolución espacial hace referencia al tamaño real del píxel en una imagen, permitiendo conocer el nivel de detalle de la superficie terrestre, es decir, un tamaño de píxel más reducido simboliza un mayor número de características de un lugar, al aumentar se comienza a generalizar todo lo que hay comprendido en el píxel en un solo valor digital, provocando en la mayoría de los casos pérdidas de información espacial y espectral (Chuvieco, 1990).

- **Polarización:**

En sensores activos la polarización hace referencia en la forma de como el sensor envía y captura la energía. Es un parámetro del sensor para emitir y recibir una longitud de onda en una dirección o en otra. Existen varios tipos de polarizaciones como lo son HH, HV, VV, VH que la primera letra hace referencia a como se transmitió y la segunda como se recibe la señal. Dependiendo de la capacidad del sensor puede medir dos o cuatro polarizaciones .(Podest et al., 2018).

- **Retrodispersión radar:**

La retrodispersión en imágenes de radar es la fracción entre la energía que transmitió y la que es reflejada de nuevo hacia el sensor. Existen diversos factores que influyen en esta medida como lo son la densidad del objeto, el tamaño en relación con la longitud de onda, la constante dieléctrica y, por último, el tamaño y orientación.(Podest et al., 2018)

- **Speckle:**

Las imágenes de radar presentan ruido debido al dispersión de la señal con los diferentes objetos o superficies con los que interviene. El speckle dificulta la interpretación de las

imágenes corrompiendo la información obtenida de la superficie. Se utilizan diversos métodos estadísticos para reducir este efecto (Podest et al., 2018).

- **Modelo matemático:**

Un modelo matemático es una representación simple de un fenómeno real, representado en forma de ecuación o fórmula matemática. Dicho modelo es utilizado para analizar la relación entre dos o más variables.

5 MARCO REFERENCIAL

La detección remota cada vez es utilizada para la estimación de AGB y, por ende, el stock de Carbono. Existen diversas metodologías que permiten realizar dicha estimación con una incertidumbre asociada, la cual dependerá de diversos factores como el tipo de sensor y sus características, la escala de trabajo, la estructura de la vegetación, topografía y los datos de inventario de campo; Además, estos métodos reconocen lo fundamental que son los datos de campo, así como los modelos que permiten relacionarlos con las variables obtenidas por técnicas de sensores remotos (Lu, 2006; Sinha et al., 2015).

Entre los sensores utilizados para la estimación de biomasa aérea y stock de carbono están los sensores ópticos. Por ejemplo, Perea (2018), empleo dos imágenes ópticas Landsat 8 de la época seca y lluviosa para obtener tres índices de vegetación (NDVI, EVI y SAVI) correlacionados a datos de inventarios de campos en modelos de regresión lineal simple, reportando que el modelo lineal de NDVI época seca alcanzo un R^2 de 0.82 y un RMSE de 17.1 Ton/ha. De la misma manera, Acosta et al., (2017) empleó imágenes ópticas para calcular tres índices de vegetación (NDVI, GDVI, DVI), así como las bandas de las imágenes y correlacionarlos con los datos obtenidos de campo, obteniendo el mejor modelo de regresión lineal con R^2 de 0.66 con la banda de infrarrojo medio. Por su parte Reyes et al., (2017) a partir de 55 parcelas inventariadas, el NDVI derivado de imágenes Landsat y modelos de regresión lineal, polinomial y exponencial selecciono el mejor modelo (exponencial, R^2 de 0.66) para estimar AGB.

De otra lado, Englhart et al., (2011) relaciono únicamente datos derivados de SAR. Utilizaron datos de radar de diferentes longitudes de onda, bandas L y X, 140 datos inventariados de bosques de turbera y datos derivados de LIDAR. Primero se relacionaron los datos de campo con los de LIDAR, para proporcionar 3970 nuevos datos de referencia a la zona de estudio y, por ende, al modelo. Luego, la información de radar fue calibrada geométricamente, radiométricamente y se aplicó un filtro de Lee Sigma para la reducción de speckle. Finalmente, el modelo de regresión multivariado, que comprende información de retrodispersión de la Banda X y Banda L, obtuvo mejores predicciones (R^2 igual a 0.78) que los modelos mono banda. Por otra parte, se estimó el nivel de saturación de las imágenes de radar, ya que el análisis de AGB que utilizan imágenes de radar está limitado por la saturación de la señal del radar a valores altos de AGB, en este caso hasta 307 Ton/ha.

De igual manera, (Hamdan et al., 2011), analizaron la relación entre los datos derivados de un único sensor, en este caso SAR con AGB de los bosques tropicales. Se inventariaron 30 parcelas de tamaños 50 x 50 metros, suficiente para hacer correspondencia a la resolución espacial de ALOS PALSAR. Dado que los pixeles que abarcan cada parcela es una ventana de

4x4, se tomó el valor medio de esta ventana. Por último, determinaron el mejor modelo de regresión exponencial con un R^2 de 0.78 y una significancia del $p < 0.0001$ en donde, la polarización cruzada HV fue la variable explicativa.

Existen metodologías que utilizan los datos SAR y ópticos para la estimación de AGB. Por ejemplo, autores como Akhtar et al., (2020), estudiaron modelos de regresión para mapear AGB de un bosque subtropical montañoso, utilizando los datos de un sensor óptico de alta resolución Pleiades y un sensor activo SAR de ALOS-1 PALSAR. Obtuvieron datos de 33 parcelas circulares inventariadas que cubren lo largo de la zona de estudio, con radios de 10.50m que se correlacionaron con datos de retrodispersión e índices de vegetación como NDVI y SAVI. Los modelos de regresión lineales, lineales múltiples y no lineales fueron estudiados para relacionar los datos, arrojando que el modelo lineal de índices de vegetación óptico obtuvo un R^2 de 0.86, mientras que el modelo lineal radar obtuvo un valor bajo de R^2 igual a 0.39, por su parte el modelo lineal múltiple exhibe más variabilidad en comparación al modelo de índices de vegetación.

Asimismo, investigadores como Joshi et al., (2015), concuerdan que para mapear AGB, la resolución espacial debe ser considerada para obtener un modelo apropiado. Por ende, el tamaño de la parcela de campo debería ser similar a la resolución espacial del sensor. Su metodología se basó en la utilización de la retrodispersión de radar junto con datos de inventario y datos derivados de LIDAR como variables para obtener sus modelos de predicción. De igual modo, Chang & Shoshany, (2016), utilizaron la retrodispersión de radar de Sentinel-1 y añadieron otras variables como la relación de intensidad (Intensity Ratio) para su modelado. Esto debido a que la relación de intensidad es menos afectada a la topografía a comparación de la retrodispersión. Evaluaron tres modelos de regresión; los primeros dos relacionaban los datos de Sentinel 1 y Sentinel 2 con el AGB por separado, por último, el modelo determinado de fusión incluía ambas fuentes de datos. Este último, fue superior a los modelos en donde solo se utilizaron datos de una única fuente. Encontraron que la dispersión cruzada HV del radar estaba fuertemente correlacionada con el AGB.

Además, del uso de diversas relaciones de retrodispersión o índices de radar, autores como Sarker et al.,(2013), proponen el uso de imágenes de textura propuesto por Haralick et al., (1973) para imágenes de radar de banda C. Estas texturas son capaces de discriminar mejor la información espacial en la estructura de la masa forestal haciendo uso de la retrodispersión de radar en cualquier polarización. Los autores calcularon las mediciones de textura, basados en la matriz de co-ocurrencia de nivel de gris (GLCM) que son: promedio (ME), homogeneidad (HO), contraste (CO), desviación estándar (Std), Disimilitud (DI), Entropía (EN), segundo momento angular (ASM), correlación (COR), entre otras. Este estudio se enfocó en un modelo de regresión lineal múltiple por pasos para establecer la relación entre las medidas de textura y los datos de campo, seleccionando el mejor modelo de acuerdo con diversos parámetros estadísticos como los son: el coeficiente de determinación (R^2), coeficiente de determinación ajustado (Adj R^2), error cuadrático medio (RMSE).

Tovar et al., (2020) también calcularon los parámetros GLCM anteriormente mencionados, derivados de imágenes de Sentinel 1. Utilizaron un modelo de regresión Random Forest, para relacionar las variables. Las variables de entrada fueron: las medidas de texturas, índices de vegetación derivados de Sentinel 2 y un total de 23 parcelas de campo. En los modelos obtenidos, la retrodispersión VV, textura CORvv, GNDVI, SWIR fueron las variables más

relevantes. Los modelos combinados de datos ópticos y SAR mostraron los mejores resultados, Sin embargo, los coeficientes de determinación de los modelos no fueron los esperados, R^2 de 0.27 y R^2 de 0.36.

También, Hernández et al., (2020), en su modelo de bosque aleatorio, además de la imágenes de textura, proporcionaron datos climáticos, datos LIDAR, utilizaron la diferencia normalizada del índice de retrodispersión (NDBI), como variable que podría ayudar a diferenciar los tipos de vegetación y 232 parcela inventariadas. El 70% de las parcelas se utilizó para ajustar el modelo y el 30% para evaluarlo. Al final se determinó que, aunque las medidas LIDAR no ayudaron a mejorar el R^2 , la inclusión de las imágenes de textura y datos climáticos aportaron para disminuir el nivel de saturación. Argamosa et al., (2018), proponen diversos modelos de estimación de AGB que combinan el uso de parámetros como textura de imágenes GLCM, la relación cruzada de la polarizaciones (Ratio), la diferencia entre las polarizaciones (Diferencia), el promedio de polarizaciones, así como la inclusión de un análisis de componente principales (PCA) en su modelo de regresión de bosque aleatorio.

La revisión de los investigadores anteriores deja ver que utilización de datos de radar y ópticos en sus diferentes longitudes tiene su ventaja para la estimación de AGB. Como se ha evidenciado, cada autor considera un diverso número de parámetros en su modelo, que son introducidos según el interés del investigador para conocer su relación con la estimación de AGB. Las variables potenciales en cada modelo son derivadas de índices de vegetación, transformación de imágenes, textura de imágenes. Por ejemplo, Sarzynski et al., (2020) recoge en su estudio, la mayoría de las variables derivadas de información de retrodispersión de radar, aquí expuesta. Por ende, es relevante tener en cuenta los parámetros como texturas de imágenes e índices derivados de radar y óptico para la estimación de la biomasa aérea, además, de tener presente la cantidad de datos de campo para la escogencia de una metodología apropiada.

6 MARCO TEORICO

En este capítulo se presentan cinco secciones que de manera integrada abarcan el tema de la investigación, que a partir de las teorías, modelos y enfoques permiten generar la solución al problema planteado. En la primera sección se describe el preprocesamiento de las imágenes de radar y ópticas que son la base para alcanzar los productos de las secciones siguientes. La segunda sección abarca las características de textura GLCM. La tercera y cuarta sección describen los índices de vegetación derivados de imágenes ópticas y de radar empleados. Por último, se describe la construcción del modelo de regresión múltiple.

6.1 Preprocesamiento de imágenes satelitales

6.1.1 Corrección radiométrica óptico.

La corrección radiométrica consiste en tratar los valores crudos de pixeles de la imagen de satélite y así obtener valores de intensidad homogéneos, corrigiendo imperfecciones que exista en los pixeles. Existen diversas causas que influyen en estas distorsiones como son fallos propios del sensor, alteraciones en el movimiento del sensor o interferencia de la atmosfera. Para realizar esta corrección se emplea la ecuación (1) (U.S. Geological Survey, 2019).

$$L_{\lambda} = M_L * Q_{cal} + A_L \quad (1)$$

Donde:

- L_{λ} corresponde a la radiancia espectral del sensor
- M_L factor multiplicativo de reescalamiento de radiancia específico de la banda
- Q_{cal} valor del píxel discretizados y calibrados del producto estándar
- A_L factor aditivo de reescalamiento de radiancia específico de la banda

6.1.2 Corrección reflectancia a tope de la atmosfera (TOA).

Esta corrección es una fase que se utiliza en las imágenes satelitales, con la intención de eliminar el efecto de los aerosoles y la radiancia intrínseca que se produce en el sensor y se ve reflejado en la imagen, como producto de la interacción del sensor con la atmósfera. Con el paso de corrección atmosférica se consigue mejorar la calidad sensorial de la imagen; así como, eliminar el componente intrusivo de la atmósfera. Para realizar esta corrección se emplea la ecuación (3) (U.S. Geological Survey, 2019).

$$P_{\lambda}' = M_p * Q_{cal} + A_p \quad (2)$$

$$P_{\lambda} = \frac{P_{\lambda}'}{\text{Sen}(\theta_{SE})} \quad \text{ó} \quad P_{\lambda} = \frac{P_{\lambda}'}{\text{Cos}(\theta_{ZE})} \quad (3)$$

Donde:

- P_{λ} corresponde al valor de reflectancia o TOA, con corrección angular solar
- M_p factor de cambio de escala multiplicativo de reflectancia
- Q_{cal} valores del píxel discretizados y calibrados del producto estándar
- A_p factor aditivo de reescalamiento de radiancia específico de la banda
- θ_{SE} ángulo de elevación del sol local
- θ_{ZE} ángulo cenital solar en grados

6.1.3 Corrección atmosférica DOS1.

El Dark Object Subtraction (DOS) o substracción de objeto oscuro es una familia de correcciones atmosféricas basadas en imagen. Chávez, (1996) explica que “la suposición básica es que en la imagen algunos píxeles están completamente en sombra, y sus radiancias recibidas en el satélite se deben a la dispersión atmosférica (efecto bruma). Esta suposición es combinada con el hecho de que muy pocos elementos en la superficie de la Tierra tienen un color negro absoluto, por lo tanto, una reflectancia asumida de uno por ciento es mejor que un cero por ciento”. La reflectancia de la superficie (ρ), tal como lo describe Moran et al, (1992), está dada por la ecuación (4):

$$\rho = \frac{\pi * (L_{\lambda} - L_p) * d^2}{ESUN_{\lambda} * \text{Sen}(\theta_{SE})} \quad (4)$$

Donde:

- L_{λ} radiancia espectral de entrada en el sensor

- L_p es el efecto bruma
- d es la distancia del sol a la tierra
- $ESUN_\lambda$ irradiancia espectral solar exoatmosférica
- θ_{SE} ángulo de elevación del sol local

El efecto bruma es dado por Sobrino et al., (2004) presentado en la ecuación (5):

$$L_p = M_L * ND_{min} + A_L - 0.01 * \frac{ESUN_\lambda * Sen(\theta_{SE})}{\pi * d^2} \quad (5)$$

Donde:

- M_L factor multiplicativo denominado ganancia
- ND_{min} valor digital mínimo
- A_L constante adictiva denominada sesgo
- d es la distancia del sol a la tierra
- $ESUN_\lambda$ irradiancia espectral solar exoatmosférica
- θ_{SE} ángulo de elevación del sol local

6.1.2 Corrección Topográfica óptico.

Según (Chuvieco, 2010), se debe considerar la topografía del terreno, debido a que la reflectividad es afectada a causa de dos variables como lo son la pendiente y orientación, pudiendo ocurrir que no reciban energía solar directa aquellas laderas opuestas al sol, todo esto conlleva a tener distintos valores de reflectividad en zonas con coberturas similares; para corregir este efecto es necesario contar con un Modelo Digital de Elevación (DEM, por sus siglas en inglés), pudiendo de esta forma conocer para cada píxel la pendiente y la orientación del terreno.

Por lo anterior, Minnaert propuso en 1941 que las superficies observadas no reflejan la energía solar incidente uniformemente en todas las direcciones, sino más bien el formuló un modelo no lambertiano el cual supone la reflexión parcialmente dependiente del ángulo de visión, formado por el eje visual y la normal a la superficie. En este caso, las funciones de reflectancia adoptan formas diferentes, dependientes de los ángulos i , e y de un coeficiente k cuyo valor está comprendido entre cero y la unidad (Woodham y Lee, 1985) presentada en la ecuación (6).

$$L_h = L_t * \left(\frac{\cos(\theta)}{\cos(i)} \right)^k \quad (6)$$

Donde:

- L_h iluminación topográfica corregida
- L_t iluminación topográfica no corregida
- θ ángulo solar zenith (grados)

- i ángulo de incidencia (grados)
- k constante de corrección minnaert

6.1.3 Calibración radiométrica radar

Este proceso se realiza con el propósito de crear una nueva imagen donde el valor de cada píxel esté relacionado directamente con la retro dispersión de la escena. En otras palabras, consiste en la transformación de los niveles digitales (ND) de la imagen a valores de retrodispersión en decibeles (dB). Existen tres niveles de corrección: Sigma 0, Gamma 0 y Beta 0. Comúnmente se llevan los ND a valores de Sigma 0 para análisis cuantitativos representado por la ecuación (7) (Miranda & Meadows, 2015).

$$\sigma^0 = \frac{DN^2}{A_{dn}^2 \cdot K} \cdot \frac{1}{G_{eap}^2} \cdot \left(\frac{R}{R_{ref}} \right)^3 \cdot \sin(\alpha) \quad (7)$$

Donde:

- $\frac{1}{G_{eap}^2}$ es la corrección del patrón de antena de elevación (EAP) (bidireccional)
- $\left(\frac{R}{R_{ref}} \right)^3$ es la corrección de pérdida de dispersión de rango (RSL)
- A_{dn} es el escalado final del producto de SLC interno a SLC o GRD final
- α es el ángulo de incidencia local

En el caso de Sentinel-1, las correcciones EAP y RSL son aplicadas por defecto por el S-1 IPF de modo que la fórmula anterior se simplifica a:

$$\sigma^0 = \frac{DN^2}{A_{dn}^2 \cdot K} \sin(\alpha) \quad (8)$$

Donde DN es el numero digital del píxel, A_{dn} es el escalado final del producto de SLC interno a SLC o GRD final, K la constante de calibración y α es el ángulo de incidencia local

En consecuencia, la sección transversal del (A_σ) se define como:

$$A_\sigma = \sqrt{\frac{A_{dn}^2 \cdot K}{\sin(\alpha)}} \quad (9)$$

Sin embargo, debido a las especificaciones del producto, es posible calibrar los datos utilizando directamente las LUT de calibración utilizando la ecuación (10)

$$\sigma^0 = \frac{DN^2}{A_\sigma^2} \quad (10)$$

Donde DN es el número digital del píxel que para el caso de las imágenes GRD equivale a la amplitud.

Dado que σ^0 esta en valores naturales, es posible acceder a dB de la siguiente manera:

$$\sigma_{db}^0 = 10 \cdot \log_{10} \sigma^0 \quad (11)$$

6.1.4 Calibración geométrica radar

La corrección geométrica de terreno o geocodificación consiste en la reproyección de coordenadas en un grupo de imágenes asociadas (Wegmuller, 1999). En SAR se menciona la transformación de coordenadas de rango Doppler a coordenadas de mapa ortogonal asociado, en la geocodificación es necesario el uso de datos tomados en campo o de otros sensores, como producto de reproyección. Para llevar a cabo esta corrección se utiliza la descripción de la geometría y proyección de los productos SAR, para así asociar los puntos de control extraídos del DEM que se usará como producto de reproyección. La ecuación (12) permite el cálculo de la posición real del píxel (Wegmuller, 1999)

$$A_\sigma = \frac{az \cdot r}{\cos \psi} \quad (12)$$

Donde, az es el azimut del píxel espaciado, r es la inclinación del píxel espaciado y ψ ángulo de proyección definido como el ángulo entre la normal de la superficie y la normal del plano de la imagen. Ver figura 1.




Figura 1. Relación de planos de superficie e imagen SAR

Fuente: Wegmuller, 1999

En la Figura 1: se presenta la geometría de imágenes SAR con vectores: x azimut, z vertical, r vector de observación del radar, R centro de la Tierra a píxel, S centro de la Tierra a SAR, n superficie y m normal del plano de la imagen y ángulos: θ (ángulo de incidencia local), ψ (ángulo de proyección) y u, v (ángulos esféricos de n).

6.1.5 Reducción de speckle

El ruido Speckle es un efecto de distorsión en la señal del radar, lo cual hace presentar un efecto de sal y pimienta en las imágenes (Lee, 1981). Es necesario la corrección de dicho ruido para realizar análisis de manera óptima, para lo cual Lee, 1981 propone la aplicación de un filtro con el fin de, reducir ruidos radiométricos basándose en la aplicación de medidas estadísticas; a partir de la ecuación (13):

$$z_{ij} = x_{ij} u_{ij} \quad (13)$$

Donde, Z_{ij} equivale al valor del píxel, x_{ij} es la señal y u_{ij} equivale al ruido, con media igual a 1 y varianza σ^2 ; ij hacen referencia a la posición (fila y columna). Considerando la media y varianza locales de la imagen con speckle, se puede utilizar el primer orden de la serie de Taylor, lo que posteriormente obtiene el filtro minimizando el error cuadrático medio por medio de la estimación de mínimos cuadrados ponderados, como se indica en la ecuación (14) (Lee, 1981).

$$\hat{x}_{ij} = \bar{x}_{ij} + \bar{k}_{ij}(z_{ij} - \bar{x}_{ij}) \quad (14)$$

Donde, k es el coeficiente adaptativo del filtro Lee. Y se expresa de la siguiente manera:

$$k = \frac{var(x)}{\bar{x}^2\sigma^2 + var(x)} \quad (15)$$

Donde, $var(x)$ es la influencia de la varianza entre la convolución de la media de la ventana de los píxeles analizados.

6.2 Matriz de Co-ocurrencia de nivel de grises (GLCM)

La matriz de co-ocurrencia (GLCM, por sus siglas en inglés) puede revelar propiedades y patrones en una imagen sobre la espacialización de los niveles de gris (Hall-Beyer, 2017). Este mismo, reunió en varios grupos estas medidas de textura:

6.2.1 Grupo de contraste

Este grupo está formado por rasgos que utilizan ponderaciones relativas a la distancia de la diagonal principal de la GLCM. Sean i y j , las filas y columnas de la GLCM, y $P_{i,j}$, la probabilidad normalizada de ocurrencia de un valor de gris (Hall-Beyer, 2017).

- Contraste

Determina la variaciones locales de grises presente en la imagen, por ende, cuanto mayor sea la variación de tono gris, mayor será el contraste (Hall-Beyer, 2017).

$$\sum_{i,j=0}^{N-1} P_{i,j}(i - j)^2 \quad (16)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz

- Disimilitud (Diss)

En esta matriz los pesos en lugar de aumentar exponencialmente (0, 1, 4, 9, etc.) a medida que uno se aleja de la diagonal, estos pesos aumentan linealmente (0, 1, 2, 3, etc.) (Hall-Beyer, 2017).

$$\sum_{i,j=0}^{N-1} P_{i,j} |i - j| \quad (17)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz

- Homogeneidad

También conocido como momento de diferencia inversa (ISM). La homogeneidad aumenta cuando el contraste entre las parejas de píxeles desciende (Hall-Beyer, 2017).

$$\sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i-j)^2} \quad (18)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz

6.2.2 Grupo de orden y estadística

- Segundo Momento Angular (ASM)

Conocido también como uniformidad. entre mayor sea el ASM, mayor será la uniformidad (menos variación en niveles de grises). Si ASM es 1, la imagen es completamente uniforme. (Hall-Beyer, 2017).

$$\sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (19)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz

- Energía (E)

La raíz cuadrada del ASM a veces se usa como medida de textura y se llama energía. (Hall-Beyer, 2017).

$$\sqrt{ASM} \quad (20)$$

- Máxima Probabilidad (Max)

El mayor valor $P_{i,j}$ encontrado dentro del GLCM (Hall-Beyer, 2017).

$$Max (P_{i,j}) \quad (21)$$

-Entropía

Es una medida de la complejidad de la imagen. A mayor entropía mayor complejidad (Hall-Beyer, 2017).

$$\sum_{i,j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad (22)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz

- Correlación (CR)

Correlación es la dependencia lineal de los tonos de gris en la imagen, Si la correlación es 0, no existe correlación lineal entre los niveles de gris (Hall-Beyer, 2017).

$$\sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (23)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz μ, σ representan la Media y Desviación Estándar de la matriz.

- Media (ME)

No es simplemente el promedio de todos los valores de píxeles originales en la ventana de la imagen, calcula la media en función de los píxeles de referencia (Hall-Beyer, 2017).

$$\sum_{i,j=0}^{N-1} i(P_{i,j}) \quad (24)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz

- Desviación estándar (STD)

La varianza es una medida de la dispersión de los valores alrededor de la media. Es similar a contraste o disimilitud (Hall-Beyer, 2017).

$$STD = \sqrt{va} \quad (25)$$

Donde va es

$$\sum_{i,j=0}^{N-1} i P_{i,j} (i - ME)^2 \quad (26)$$

Donde, $P_{i,j}$ representa la matriz de co-ocurrencia, i, j representa las posiciones en la matriz

6.3 Índices de vegetación

Las imágenes de satélite a diferentes escalas temporales permiten evaluar y monitorear el estado de la vegetación a nivel global, regional, nacional y local (Cabrera et al., 2011). Estas imágenes compuestas de varias bandas permiten discriminar diferentes tipos de cobertura, para lograrlo un camino es mediante la elaboración de índices de vegetación (Muñoz, 2013). Según Chang & Shoshany, (2016) incluir datos de índices de vegetación (VI) derivados de sensores ópticos, contribuye a mejorar los resultados en los modelos de regresión. En la actualidad, existe gran variedad de VI, como el índices de vegetación de diferencia normalizada (NDVI, por sus siglas en inglés) usado para estimar la cantidad, calidad y desarrollo de la vegetación (Rouse et al., 1974) y el índices de Vegetación de suelo ajustado (SAVI, por sus siglas en

inglés) siendo una mejora del NDVI que contrarresta la influencia del brillo del suelo (Huete, 1988). Las ecuaciones (27) y (28), muestran los índices NDVI y SAVI respectivamente.

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (27)$$

Donde, NIR y RED corresponden a la banda de reflectancia infrarrojo cercano y rojo respectivamente.

$$SAVI = \frac{NIR-RED}{NIR+RED+L} * (1 + L) \quad (28)$$

Donde, NIR y RED corresponden a la banda de reflectancia infrarrojo cercano y rojo respectivamente, y L, el factor de ajuste al suelo.

6.4 Índices Radar

Dado que la retrodispersión del radar se ve afectada por la estructura del bosque, diversos autores han planteado el uso de diversos índices que les permita atenuar o resaltar características de la vegetación. Empleando estos índices como parámetro en sus modelos de regresión (Chang & Shoshany, 2016; Hernández-Stefanoni et al., 2020; Argamosa et al., 2018; Sarzynski et al., 2020).

- Promedio (AVE)

$$\frac{HH+HV}{2} \quad (29)$$

Donde, *HH* y *HV* corresponden al coeficiente de retrodispersión de radar en su polarización correspondiente.

- Diferencia (DIF)

$$HH - HV \quad (30)$$

Donde, *HH* y *HV* corresponden al coeficiente de retrodispersión de radar en su polarización correspondiente.

- Ratio 1 (RAT1)

$$\frac{HH}{HV} \quad (31)$$

Donde, *HH* y *HV* corresponden al coeficiente de retrodispersión de radar en su polarización correspondiente.

- Ratio 2 (RAT2)

$$\frac{HV}{HH} \quad (32)$$

Donde, *HH* y *HV* corresponden al coeficiente de retrodispersión de radar en su polarización correspondiente.

- Índice de diferencia normalizada (NDBI)

$$\frac{HH-HV}{HH+HV} \quad (33)$$

Donde, HH y HV corresponden al coeficiente de retrodispersión de radar en su polarización correspondiente.

- Índice Numero de Miradas (NL)

$$\frac{HH*HV}{HH+HV} \quad (34)$$

Donde, HH y HV corresponden al coeficiente de retrodispersión de radar en su polarización correspondiente

6.5 Modelos de regresión

Las potenciales variables para la estimación de biomasa aérea en sensores remotos incluyen índices de vegetación, transformación de imágenes, textura de imágenes. Dichas variables deben tener una fuerte correlación con la biomasa aérea, pero débil correlación entre ellas. Para identificar las posibles variables los métodos más utilizados son análisis de regresión por etapas, análisis de correlación, red neuronal, entre otros, como lo indica Lu, (2006). Por lo anterior, se presenta un modelo generalizado de regresión lineal múltiple, métodos para la selección de variables y los criterios para selección del mejor modelo.

6.5.1 Regresión lineal múltiple

Se utiliza un modelo de regresión lineal múltiple que permite estudiar la relación que tiene las diversas variables explicativas o regresoras (textura de imágenes, índices de radar) con la variable de interés (AGB). Este modelo (ecuación 35) es una extensión del modelo de regresión lineal simple y puede acomodar directamente múltiples predictores (Hastie et al., 2006).

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon \quad (35)$$

Donde, X_j representa el j -ésimo predictor y β_j cuantifica la asociación entre esa variable y la respuesta. Se interpreta β_j como el efecto promedio sobre Y de un aumento de una unidad en X_j , manteniendo todos los demás predictores fijos.

6.5.2 Métodos de selección de variables

Se consideran algunos de los métodos para seleccionar un subconjunto de variables predictoras. La selección de un método u otro permite especificar como se introduce o elimina cada variable.

- Regresión por pasos hacia adelante (Forward Stepwise)

La selección paso a paso hacia adelante comienza con un modelo que no contiene predictores y luego agrega predictores al modelo, uno a la vez, hasta que todos los predictores se han tenido en cuenta en el modelo. En particular, en cada paso se añade al modelo la variable que aporta

la mayor mejora adicional al ajuste elegido (Hastie et al., 2006). Se describe su algoritmo a continuación:

1. Sea M_0 el modelo nulo, que no contiene predictores.
2. Para $k = 0, \dots, p - 1$:
 - (a) Considere todos los modelos $p - k$ que aumenten los predictores en M_k con un predictor adicional.
 - (b) Elegir el mejor entre estos $p - k$ modelos, y llamarlo M_{k+1} . En este caso, el mejor se define como el que tiene el menor suma de los residuales cuadrados (RSS) o el mayor R^2 .
3. Seleccione el mejor modelo entre $M_0, \dots, M_p$ utilizando el error de predicción validado de forma cruzada, C_p (AIC), BIC o R^2 ajustado.

- Regresión por pasos hacia atrás (Backward Stepwise)

De la misma forma que selección por pasos hacia delante, la selección por pasos hacia atrás ofrece una alternativa eficaz a la selección del mejor subconjunto. Sin embargo, a diferencia de la selección hacia adelante, comienza con el modelo completo de mínimos cuadrados que contiene todos los predictores p , y luego elimina iterativamente el predictor menos útil, de uno en uno (Hastie et al., 2006). Se describe su algoritmo a continuación:

1. Sea M_0 el modelo completo, que contiene todos los predictores p .
2. Para $k = p, p - 1, \dots, 1$:
 - (a) Considere todos los k modelos que contienen todos los predictores menos uno en M_k , par aun total de $k - 1$ predictores.
 - (b) Elige el mejor entre estos k modelos, y llamarlo M_{k-1} . En este caso, el mejor se define como el que tiene el menor RSS o el mayor R^2 .
3. Seleccione el mejor modelo entre $M_0, \dots, M_p$ utilizando el error de predicción validado de forma cruzada, C_p (AIC), BIC o R^2 ajustado.

.

- Mixto o híbrido

Otra alternativa es la versión híbrida a las dos anteriores, en donde después de añadir cada nueva variable, el método puede eliminar también las variables que ya no proporcionan una mejora en el ajuste del modelo. Este enfoque trata de imitar más de cerca la selección del mejor subconjunto al tiempo que conserva las ventajas computacionales de la selección progresiva hacia delante y hacia atrás.

6.5.3 Criterio de selección del modelo

Estos criterios pueden utilizarse para seleccionar entre un conjunto de modelos con diferentes números de variables. A continuación, consideramos cuatro de estos enfoques: C_p de Mallows,

criterio de información de Akaike (AIC), criterio de información bayesiano (BIC) y R^2 ajustado.

- CP de Mallows

Permite llegar a un equilibrio con el número de predictores que se ingresan al modelo. CP de Mallows compara la precisión y el sesgo del modelo completo con modelos que incluyen un subconjunto de los predictores. En consecuencia, el estadístico C_p tiende a tomar un valor pequeño para los modelos con un error de prueba bajo, por lo que al determinar cuál de un conjunto de modelos es el mejor, se elige el modelo con el valor C_p más bajo (Hastie et al., 2006).

$$C_p = \frac{1}{n} (RSS + 2d\hat{\sigma}^2) \quad (36)$$

Donde, $\hat{\sigma}^2$ es una estimación de la varianza del error ϵ asociado a cada medida de respuesta del modelo de regresión múltiple. RSS es la suma residual de cuadrados en un conjunto de entrenamiento, n tamaño de la muestra y d , el número de predictores.

- Criterio de Información Akaike (AIC)

El criterio AIC se define para una gran clase de modelos ajustados por máxima verosimilitud. En el caso del modelo de regresión lineal múltiple con errores gaussianos, la máxima verosimilitud y los mínimos cuadrados son lo mismo (Hastie et al., 2006). En este caso, el AIC viene dado por:

$$AIC = \frac{1}{n\hat{\sigma}^2} (RSS + 2d\hat{\sigma}^2) \quad (37)$$

Donde, $\hat{\sigma}^2$ es una estimación de la varianza del error ϵ asociado a cada medida de respuesta del modelo de regresión múltiple. RSS es la suma residual de cuadrados en un conjunto de entrenamiento, n tamaño de la muestra y d , el número de predictores.

- Criterio de Información Bayesiano (BIC)

Al igual que C_p , el BIC tenderá a tomar un valor pequeño para un modelo con un error de prueba bajo, por lo que generalmente seleccionamos el modelo que tiene el valor BIC más bajo (Hastie et al., 2006).

$$BIC = \frac{1}{n\hat{\sigma}^2} (RSS + \log(n)d\hat{\sigma}^2) \quad (38)$$

Donde, $\hat{\sigma}^2$ es una estimación de la varianza del error ϵ asociado a cada medida de respuesta del modelo de regresión múltiple. RSS es la suma residual de cuadrados en un conjunto de entrenamiento, n tamaño de la muestra y d , el número de predictores.

- Coeficiente de determinación (R^2)

Indica el porcentaje de variación de la variable dependiente explicada por la variable independiente. Su rango de valores oscila entre 0 y 1, cuando el valor es cercano a 1 mayor es la asociación entre ambas variables. Caso contrario ocurre cuando el valor es cercano a cero, ya que esto representa que la relación entre estas es poca o nula. En la ecuación (18) se muestra el cálculo del coeficiente (Laguna, 2014).

$$R^2 = \frac{\sigma^2_{XY}}{\sigma^2_X \sigma^2_Y} \quad (39)$$

Donde,

R^2 = Coeficiente de determinación

σ^2_{XY} = Covarianza de X, Y

σ^2_X = Varianza de la variable X

σ^2_Y = Varianza de la variable Y

- Coeficiente de determinación ajustado (R^2_{adj})

A diferencia de Cp, AIC y BIC, para los que un valor pequeño indica un modelo con un error de prueba bajo, un valor grande de R^2_{adj} indica un modelo con un error de prueba pequeño (Hastie et al., 2006). Viene dado por:

$$R^2_{adj} = 1 - \frac{RSS/(n-d-1)}{TSS/(n-1)} \quad (40)$$

6.5.4 Diagnóstico del Modelo

El modelo de regresión lineal múltiple ha de cumplir con una serie de supuestos o condiciones para garantizar su confiabilidad (Ximénez & San Martín, 2013). Entre los que se van a estudiar están Independencia, Normalidad y Homocedasticidad.

- Independencia

Los residuos se comportan como una variable aleatoria por lo cual son independientes entre sí de las variables independientes y de los pronósticos. Si no se cumpliera este supuesto se produce el problema de la autocorrelación.

La prueba de Durbin-Watson permite conocer el grado de independencia entre los residuos. En donde la prueba se especifica del siguiente modo (Arranz & Zamora, 2015):

1. Formulación de hipótesis:

$$\begin{cases} H_0: & \text{No existe autocorrelación} \\ H_1: & \text{Existe autocorrelación} \end{cases}$$

2. Se obtiene el valor d calculado con los residuales

$$d = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (41)$$

Donde, n es el numero de observaciones y e_t es el residual asociado a la observación en el tiempo t .

3. Se calculan los límites inferior y superior de variación del estadístico d , de acuerdo con la ecuación (42)

$$\hat{\rho} = \frac{\sum_{t=2}^n e_t e_{t-1}}{\sum_{t=1}^n e_t^2} \quad (42)$$

Que se resume en

$$d \approx 2(1 - \hat{\rho}) \quad (43)$$

4. Teniendo en cuenta los límites de variación del coeficiente de correlación empírico, $-1 \leq \hat{\rho} \leq 1$, se puede deducir el rango de variación del estadístico de Durbin-Watson y el signo de la autocorrelación.

$$\begin{aligned} \hat{\rho} = -1 &\rightarrow d \approx 4 \text{ se considera existe correlación negativa} \\ \hat{\rho} = 0 &\rightarrow d \approx 2 \text{ indica ausencia de autocorrelación} \\ \hat{\rho} = 1 &\rightarrow d \approx 0 \text{ se considera existe correlación positiva} \end{aligned}$$

No obstante, estos valores (0, 2 y 4) son límites extremos que deben matizarse estableciendo regiones más amplias en las que pueda considerarse si existe o no autocorrelación y, en caso de detectarse, si ésta es positiva o negativa. Para solucionar esta dificultad Durbin y Watson hallaron unos límites superior (d_u) e inferior (d_L) que permiten tomar decisiones acerca de la presencia o ausencia de autocorrelación

5. Regla de rechazo. El rango aproximado para d es $[0,4]$. La figura 2 muestra la regiones del contraste:




Figura 2. Regiones de contraste Durbin Watson

Esto es,

$0 < d < d_L$	se rechaza H_0 , existe autocorrelación
$4 - d_L < d < 4$	se rechaza H_0 , test no concluyente
$d_u < d < 4 - d_u$	no se rechaza H_0 , existe autocorrelación
$d_L < d < d_u$	el contraste no es concluyente
$4 - d_u < d < d_L$	el contraste no es concluyente

- Normalidad

Para el supuesto de normalidad, se utiliza la prueba de Lilliefors. Permite medir que tanto se parecen o coinciden una distribución teórica específica y una variable. Viene dada por (Vicente, 2017):

$$KSL_C = |D_{m\acute{a}x}| = |F_{teo} - F_{obs}| \quad (44)$$

Donde,

KSL_C = estadístico de prueba Kolmogorov-Smirnov-Lilliefors

$|D_{m\acute{a}x}|$ = valor absoluto de la diferencia entre la probabilidad acumulada teórica y la observada

F_{teo} = es la probabilidad acumulada teórica

F_{obs} = es la probabilidad acumulada real u observada

- Homocedasticidad

Para este supuesto, se hace la prueba de Breusch-Pagan, que consiste en una prueba de heterocedasticidad, que estudia las varianzas del error son o no iguales. La ecuación de heterocedasticidad viene dada por (Quesada, 2011) :

$$\sigma_i^2 = h(\alpha_1 + \alpha_2 Z_{2i} + \dots + \alpha_p Z_{pi}) \quad (45)$$

donde h es una función no especificada.

Las hipótesis para contrastar son:

$$\begin{cases} H_0: \alpha_2 = \alpha_3 = \dots = \alpha_p, & (\text{homocedasticidad}) \\ H_1: \alpha_2 \neq 0 \text{ para algún } i = 2, \dots, p, & (\text{heterocedasticidad}) \end{cases}$$

Los pasos para realizar el contraste son los siguientes:

1. Estimar por mínimo cuadrados la ecuación de regresión de interés obtener los residuos $\hat{u}_j$, y calcular:

$$\hat{\sigma}_i^2 = \sum_{i=1}^n \frac{\hat{u}_i^2}{n} \quad (46)$$

2. Estimar por mínimos cuadrados la ecuación de regresión auxiliar

$$\left(\frac{\hat{u}_i}{\hat{\sigma}_u}\right) = \alpha_1 + \alpha_2 Z_{2i} + \dots + \alpha_p Z_{pi} + e_i \quad (47)$$

y calcular la suma de cuadros explicada, SCE.

3. Calcular el estadístico de contraste $SCE/2$, que sigue bajo H_0 (y suponiendo normalidad) una distribución Chi-cuadrado con $p - 1$ grados de libertad.
4. La hipótesis H_0 se rechaza al nivel de significación α , si $SCE/2 > c$, donde c es el valor crítico para el cual

$$Prob(X_{p-1}^2 > c) = \alpha$$

7 METODOLOGÍA

El capítulo de metodología se compone de tres subcapítulos. El primero presenta la zona de estudio del Santuario de Fauna y Flora Iguaque, el cual alberga diferentes ecosistemas terrestres y está ubicado en el departamento de Boyacá, Colombia. El segundo, se compone de los materiales, aquí se presentan todos aquellos insumos que se utilizaron para el desarrollo del proceso metodológico. Por último, el capítulo tres, lo componen los métodos que se aplicaron y se presenta el flujograma que comprenden de manera esquemática la metodología desarrollada.

7.1 Localización

El Santuario de Fauna y Flora Iguaque SFFI, ubicado en Colombia; Departamento de Boyacá, entre los municipios de Villa de Leiva, Chíquiza, Sáchica y Arcabuco, sobre la cordillera central de los andes nororiente Colombiano, está localizado entre las coordenadas geográficas $05^{\circ}44'29.90''$ y $05^{\circ}35'52.69''$ en latitud Norte y $73^{\circ}31'8.18''$ y $73^{\circ}22'43.38''$ de longitud Oeste, comprende una superficie de 6.750 hectáreas y presenta elevaciones entre los 2.400 y 3.890 msnm, se caracteriza por una temperatura promedio de $16,3^{\circ}$ y $18,8^{\circ}\text{C}$, los ecosistemas de Bosque Húmedo, Paramo, Bosques Andinos y Altoandinos comprende su composición vegetal (Villarreal et al., 2017). La figura 1 muestra la ubicación de la zona de estudio.




Figura 3. Localización SFF Iguaque

Fuente: Villareal et al., 2017

7.2 Equipos y Materiales

Para el presente estudio se utilizaron 5 insumos principales que se dividen en el uso de 2 imágenes de radar, 1 imagen óptica, 1 DEM e información de campo correspondientes a las parcelas.

Debido a la ubicación del SFFI con respecto a las imágenes de radar fue necesario emplear 2 imágenes del satélite radar Sentinel-1 con fecha del 16 y 21 de diciembre del 2016 (Sentinel-

1A IW GRD), proporcionadas por la Agencia Espacial Europea (ESA). Asociadas de manera aproximada a las fechas de los datos de campo. Estas imágenes son de uso libre y se obtuvieron a través del centro de acceso abierto de Copernicus (<https://scihub.copernicus.eu/dhus/>). La tabla 1 muestra características generales de las imágenes Sentinel-1.

Tabla 1. Características imágenes Sentinel 1

ID	S1B_IW_GRDH_1SDV_20161216T230518_20161216T230543_003428_005DB7_EB47	S1B_IW_GRDH_1SDV_20161221T231316_20161221T231341_003501_005FC5_3404
Fecha	16/12/2016	21/12/2016
Tipo de proceso	L-1 GRD	L-1 GRD
Modo adquisición	IW	IW
Polarización	VH, VV	VH, VV
Resolución espacial	10 m	10 m

La imagen óptica corresponde a la plataforma de Landsat 8, capturada por el sensor OLI TIRS, con fecha del 02 de enero del 2017, imagen es proporcionadas en conjunto por la NASA y el Servicio Geológico de los Estados Unidos (USGS), a través de su página oficial (<https://earthexplorer.usgs.gov/>). Por el mismo medio, se obtuvo el DEM, con una resolución espacial de 30 metros. Las tablas 2 y 3, muestran las características de las imágenes Landsat 8 y el DEM respectivamente. Cabe mencionar que la selección de las imágenes Sentinel-1 y Landsat, obedeció a factores como fechas cercanas a la toma de los datos de campo, cobertura de la zona de estudio, y la cobertura nubosa en la escena óptica.

Tabla 2. Características imagen Landsat 8

ID	LC08_L1TP_007056_20170102_20200905_02_T1
Fecha	2/01/2017
Tipo de proceso	L1TP
Sensor	OLI_TIRS
Path/Row	007/056
Resolución espacial	30 m

Tabla 3. Característica DEM

ID	SRTM1N05W074V3
Fecha	11/02/2000
Misión	SRTM
Datum Horizontal	WGS84
Resolución espacial	30 m

Los datos de referencias comprenden un inventario forestal a finales del 2016, de 23 parcelas de campo temporales en donde se midieron variables dendrométricas para estimar AGB. Estas parcelas son de forma rectangular de 25 x 10 metros para un área cuadrada de 250 m², georreferenciadas por dispositivo GPS con el que se tomó el punto medio de la parcela como referencia. Estos datos son tomados del estudio de Perea, (2018). Los datos de coordenadas y valores de AGB fueron organizados en una tabla de Excel y espacializados como puntos en formato .shp, con el software ArcGis. La tabla 4 evidencia estos datos.

Tabla 4. Datos de parcelas de campo

N° Parcela	N° árboles	DAP promedio	Biomasa		Carbono
			Kg/Parcela	T/ha	T/ha
1	13	19,27	1.453,06	58,12	29,06
2	32	13,18	1.234,04	49,36	24,68
3	30	13,75	1.322,02	52,88	26,44
4	25	14,82	1.423,00	56,92	28,46
5	33	16,31	2.147,16	85,89	42,95
6	47	17,35	4.000,72	160,03	80,02
7	36	14,21	1.632,87	65,31	32,66
8	19	12,16	616,5	24,66	12,33
9	47	15,61	2.720,84	108,83	54,42
10	20	16,89	1.609,00	64,36	32,18
11	34	20,8	4.198,87	167,95	83,98
12	44	13,08	3.591,46	143,66	71,83
13	33	18,7	3.067,37	122,69	61,35
14	17	13,30	673,55	26,94	13,47
15	18	14,85	970,93	38,84	19,42
16	9	11,97	280,48	11,22	5,61
17	19	15,68	1.292,45	51,7	25,85
18	19	19,01	2001,16	80,05	40,03
19	14	16,37	1409,06	56,36	28,18
20	12	11,25	333,75	13,35	6,68
21	25	19,24	2548,98	101,96	50,98
22	17	17,76	1339,21	53,57	26,79
23	39	15,14	2184,98	87,4	43,7
Total	602	347,4	42051,45	1682,05	841,025
		Min	280,48	11,22	5,61
		Max	4198,87	167,95	83,98
		Promedio	1828,32	73,13	36,56

Fuente: Perea, (2018)

7.3 Métodos

La metodología se basa en la revisión de la literatura sobre el tema, la figura 4, comprende el flujograma que dará respuesta a la pregunta de investigación; Una vez obtenidas la imágenes de satélite, se preprocesan para luego hallar los valores de píxel de los índices de radar, índices del óptico y de textura, por último, se correlación los valores de píxel con los datos de biomasa tomados de Perea (2018).




Figura 4. Diagrama metodológico

1. Imagen óptica

La imagen obtenida de Landsat 8 que cubre la zona de estudio se procedió a realizarle las correcciones correspondientes.

2. Corrección radiométrica óptico

La corrección o calibración radiométrica permite corregir los efectos de dispersión y/o absorción causados por las partículas suspendidas presentes en la atmósfera, mejorando la precisión de las medidas de reflectancia (Chuvieco, 2010). La imagen Landsat8 se convirtió sus valores ND a magnitudes físicas de radiancia (ecuación 1). Con esto, la imagen puede ser utilizada para calcular sus valores en reflectancia.

2.1 Corrección reflectancia (TOA)

Una vez obtenidos los valores de la imagen en radiancia, se procede a calcular los valores de reflectancia a TOA con corrección del ángulo solar (ecuación 3).

2.2 Corrección DOS1

Se le realizó la corrección de sustracción de objeto oscuro, mediante la ecuación (4). La aplicación de esta ecuación permite corregir los efectos atmosféricos en la imagen.

2.3 Corrección topográfica óptico

Se empleó la ecuación (6) para realizar el ajuste topográfico de la imagen. Con esto, se pretende reducir el efecto sombreado producido por montañas o zonas escarpadas.

3. Imágenes de radar.

Debido a que la zona de estudio está comprendida por dos imágenes de radar es necesario realizar un mosaico.

3.1 Corrección radiométrica radar

Si bien las imágenes de radar pueden brindar un análisis cualitativo de la escena, es necesario realizar una calibración para relacionar directamente los valores de retrodispersión del radar para un uso cuantitativo ecuación (10) y (11).

3.2 Corrección geométrica radar

La corrección geométrica es otro paso necesario en este tipo de imágenes. Dado que las imágenes iniciales presentan una distorsión espacial e incluso una rotación es necesario ajustarlas a una dirección y un sistema adecuado (ecuación 12)

3.3 Reducción de speckle

Para minimizar el efecto “sal y pimienta” presente en las imágenes, se procedió a aplicar una reducción de speckle por medio de un filtro refinado de Lee 3x3, empleando las ecuaciones (13) a (15).

Una vez terminado las correcciones y la reducción de speckle, se realizó un recorte del mosaico a la zona comprendida por el SFF Iguaque en formato .shp y empleando el software ArcGis.

4. Imágenes de textura

Se calcularon diferentes imágenes de texturas como los son: contraste (ecuación 16), disimilitud (ecuación 17), homogeneidad (ecuación 18), ASM (ecuación 19), energía (ecuación 20), Max (ecuación 21), entropía (ecuación 22), correlación (ecuación 23), media (ecuación 24), varianza (ecuación 26), para ambas polarizaciones (VH, VV). Se empleo el software SNAP para este procedimiento, utilizando un kernel de 3x3, un ángulo en todas las direcciones y un cuantificador probabilístico. Para un total de 20 imágenes obtenidas. Al igual que con los índices, se extrajeron los valores de píxel de estas texturas y se organizaron en una tabla en formato .txt con todos los demás datos obtenidos.

5. Cálculo de índices

Haciendo uso de matemática de bandas de SNAP se procedió a calcular los índices de óptico y radar propuestos: NDVI (ecuación 27), SAVI (ecuación 28) Promedio (ecuación 29), Diferencia (ecuación 30), Ratio 1 (ecuación 31), Ratio 2 (ecuación 32), NDBI (ecuación 33), NL (ecuación 34). Todas estas nuevas imágenes se agruparon como una composición de bandas y se les extrajo el valor de píxel utilizando los puntos georreferenciados de campo. El valor promedio debido: primero, la georreferenciación de los puntos de parcelas no recae sobre el centro del píxel; segundo, el tamaño de la parcela no es cuadrada (10x25m) y, por último, el tamaño del píxel del sensor que puede contener una mezcla de valores, si un solo píxel no cubre el área de la parcela. Por ello, la obtención de un valor único no garantiza la correcta relación del valor del píxel con la parcela de campo (Perea, 2018). Estos datos se guardaron como tabla en formato de .txt junto con los datos de AGB de campo.

6. Extracción de Coordenadas en Puntos de Muestreo

Siguiendo la metodología planteada, los productos obtenidos de textura e índices se les extrajeron los valores promedio de píxel en un kernel de 3x3, en los lugares en los que se encuentran georreferenciadas las parcelas de campo. Los datos de coordenadas y valores de biomasa aérea fueron organizados en una tabla de Excel y espacializados como puntos en formato .shp, con el software ArcGis.

7. Selección de la Muestra

Antes de iniciar con la construcción de los modelos de biomasa aérea, se estudia la dependencia espacial de los datos de parcelas mediante el índice de Moran y con ello un criterio de selección. Este índice analiza los valores de vecinos más cercanos para clasificarlos como autocorrelación positiva, negativa y sin autocorrelación. Para ello se utilizó el software GeoDa y ArcGis, y determinar si los datos están agrupados, dispersos o es aleatoria su distribución. También, se tomó como referencia el criterio de selección de Perea, (2018) para parcelas inventariadas con un mínimo de 30 árboles y del mismo tipo de vegetación.

8. Modelo de regresión

Para obtener el modelo de regresión lineal múltiple, se utilizó el entorno de desarrollo integrado (IDE) Rstudio bajo el lenguaje de programación R. Primero se cargaron las librerías pertinentes y los datos (texturas, índices y biomasa). Se utilizó el método Forward Stepwise para analizar el comportamiento de cada variable en el modelo. De acuerdo con los estadísticos CP (ecuación 36), AIC (ecuación 37), BIC (ecuación 38), R^2 (ecuación 39) y R^2 adj (ecuación 40) se escogieron las variables más significativas. Luego se construyó el modelo y se evaluaron los supuestos de independencia (ecuación 41), normalidad (ecuación 44) y homocedasticidad (ecuación 45).

9. Estimación de biomasa y stock de carbono

Una vez obtenido el mejor modelo de estimación de acuerdo con las variables más representativas, se procede a mapear la distribución de biomasa y almacenamiento de carbono de la zona del santuario. Se estimó el valor en cada píxel el contenido de biomasa aérea y stock de Carbono de acuerdo con el modelo obtenido, para luego generar la cartografía correspondiente. Para convertir los valores de Kg/parcela a Ton/ha se multiplica por un factor 0.04 debido a que cada parcela corresponde a 250 m² (1/4 de hectárea) (Perea, 2018). Para determinar el contenido de Carbono se multiplica el AGB determinada por un factor de 0.5 ya que (Brown, 1997) afirma que aproximadamente el 50% de la biomasa de la vegetación es carbono.

8 RESULTADOS

Textura GLCM

Las imágenes de textura proporcionan información de las variaciones de intensidad en nuestra zona de estudio y añade datos a nuestro modelo de estimación. Por lo anterior, se obtuvo 10 imágenes basados en GLCM para cada polarización (VV, VH) de radar. En total se obtuvieron

20 texturas correspondientes al área de estudio; se presentan los resultados obtenidos se muestran en la figura 5 y figura 6.




Figura 5. Matriz de co-ocurrencia polarización VV. a) máxima probabilidad, b) varianza, c) media, d) contraste, e) disimilitud, f) correlación, g) energía, h) entropía, i) homogeneidad y j) ASM




Figura 6. Matriz de co-ocurrencia polarización VH. a) máxima probabilidad, b) varianza, c) media, d) contraste, e) disimilitud, f) correlación, g) energía, h) entropía, i) homogeneidad y j) ASM

Índices óptico y radar

Se obtuvo dos índices de vegetación NDVI y SAVI (figura 8) derivados de la imagen Landsat 8, también, se obtuvieron 6 índices de radar (figura 7) a partir de los datos de Sentinel 1 del área de estudio; se presentan los resultados obtenidos en la figura 7 y 8.




Figura 7. Clasificación a color de los índices de radar obtenidos. a) NL, b) promedio, c) NDI, d) ratio 1, e) ratio 2 y, f) diferencia.




Figura 8. Clasificación a color de los índices ópticos obtenidos. a) NDVI y b) SAVI

Con los productos obtenidos de textura e índices se relacionó cada imagen con la parcelas de campo georreferenciadas. Como se indica en el capítulo de metodología apartado once.

Modelo de Regresión

Partiendo de la hipótesis nula que establece que los valores de las parcela en la tabla 4, se distribuyen de manera aleatoria, la figura 9, muestra los valores obtenidos del índice de moran

igual a 0.0000720 , los valores de Z igual a 0.283 y P igual a 0.776. Por lo anterior, dado el puntaje de Z, el patrón no parece ser significativamente diferente al aleatorio.




Figura 9. Autocorrelación espacial índice Moran.

Adicionalmente, la figura 10, evidencia como los valores altos de AGB se agrupan a valores altos de sus vecinos (cuadrante II) y del mismo modo, como valores bajos de AGB se agrupan a valores bajos de sus vecinos (cuadrante III). También, se observa como existen valores altos de AGB se asocian a valores bajo y viceversa (cuadrantes I y IV, respectivamente). El resultado de este análisis fue la identificación de las parcelas homogéneas de acuerdo con el criterio de autocorrelación espacial. Ya que existen parcelas con diferente número de árboles inventariados y la parcela 23 que corresponde a otro tipo de vegetación. De aquí, se seleccionaron 9 parcelas que cumplen con dicho criterio y con ellos proceder a la construcción del modelo de estimación.




Figura 10. Agrupación valores de Ba con sus vecinos.

Las tablas 5, 6 y 7, presente el resumen de los modelos de regresión lineal múltiple obtenidos por cada conjunto de variables. Dichas tablas incluyen los coeficientes estimados de cada variable, la desviación estándar, el valor t y p-value.

Tabla 5. Sumario del modelo de regresión radar

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	3260.50	256.16	12.728	0.04991

IN_NL	-865.51	132.80	-6.517	0.09693
VH_MAX	1959.12	41.35	47.381	0.01343
VH_Entropy	534.12	14.40	37.101	0.01715
VH_Correlation	10817.70	139.15	77.739	0.00819
VV_Dissimilarity	1358.48	14.73	92.214	0.00690
VV_ASM	115.02	12.81	8.980	0.07060
VV_Correlation	-16341.90	376.14	-43.447	0.01465

Tabla 6. Sumario del modelo de regresión óptico

	Estimate	Std. Error	t value	Pr(> t)
(Intercepto)	10772	3360	3.206	0.0185
NDVI	-49197683	63587756	-0.774	0.4685
SAVI	32791147	42398365	0.773	0.4686

Tabla 7. Sumario del modelo de regresión combinado

	Estimate	Std. Error	t value	Pr(> t)
(Intercepto)	-696.443	134.823	-5.166	0.12174
Ratio 1	299.316	1.184	252.716	0.00252
VH Mean	-69.739	1.677	-41.59	0.0153
VV Contraste	342.48	1.054	325.003	0.00196
VV ASM	2523.218	37.691	66.945	0.00951
VV MAX	-4109.654	76.212	-53.924	0.0118
VV Correlación	13096.113	68.569	190.993	0.00333
NDVI	-24244.73	182.227	-133.047	0.00478

La primera columna muestra las variables con las que se ajustaron los modelos. Estas son el intercepto y las demás variables sean índices o imágenes de textura. La segunda y tercera columna, muestra los coeficientes estimados y el error estándar respectivamente. El valor t, en la cuarta columna, corresponde a un estadístico de divergencia entre el coeficiente que produce el modelo y un coeficiente estimado hipotético con valor 0. Cuanto mayor es el valor t mayor será la divergencia entre los coeficientes del modelo y el hipotético. Por último, el valor p, de la prueba de hipótesis del estadístico t, indica la probabilidad de obtener un estimado como el que obtuvimos si el coeficiente real fuera 0.

Como se puede evidenciar en las tablas 5 a 7, anteriores, las pruebas t y sus niveles de significancia sirven para identificar las variables representativas que contribuyen con la explicación de AGB. En este caso y para un nivel de significancia del 5% permite saber si las variables aceptan o rechazan la hipótesis nula, la cual indica si dicha variable es explicativa.

Por lo anterior, el modelo de regresión lineal múltiple del conjunto de radar comprende todas las variables de texturas y los índices derivados de los valores de retrodispersión en las polarizaciones VV y VH. Las variables que comprendieron este modelo fueron 3 texturas de la polarización VH que fueron máxima probabilidad, entropía y correlación. Para la polarización VV, 3 texturas que son disimilitud, Segundo Momento Angular (ASM) y correlación, también se escogió el índice NL.

Para el modelo de regresión múltiple óptico, se tomaron ambos índices (NDVI, SAVI). Por último, el modelo de regresión lineal múltiple combinado donde involucran el índice de radar Ratio 1, el índice óptico NDVI, la textura VH promedio y las texturas VV contraste, ASM, Max y correlación. 3 texturas de la polarización VH que fueron máxima probabilidad, entropía y correlación.

Como se mencionó anteriormente, los modelos de regresión lineal múltiple han de cumplir una serie de condiciones o supuestos que garanticen su correcta aplicación. Por ende, una vez obtenido los modelos se evaluaron los supuestos de independencia, normalidad y homocedasticidad. Para comprobar el supuesto de independencia, se verifica mediante el estadístico de Durbin Watson presentado en la tabla 8.

Tabla 8. Supuesto de independencia.

Durbin-Watson test		
Modelo	Dw	P-value
Radar	1.3304	0.1781
Óptico	0.432	0.0013
Combinado	1.3294	0.1354

Como lo evidencio en la tabla 8, el valor del estadístico DW para el modelo radar igual a 1.3304 y el modelo combinado igual a 1.3294, además, del valor p correspondiente superior a 0.05, se acepta la hipótesis nula y, por ende, los residuos de estos modelos de regresión no están correlacionados. Sin embargo, el modelo óptico no pasa la prueba de independencia puesto que DW igual a 0.432 y un valor p 0.0013 inferior al nivel de significancia rechazan la hipótesis nula, aceptando la hipótesis alterna donde los residuos están correlacionados.

Para el supuesto de normalidad, se aplicó la prueba de normalidad de Lilliefors. En la que, se conviene aceptar la hipótesis nula que menciona que los datos proceden de una distribución normal, por ende, el valor p de la prueba de normalidad deberá ser mayor al valor de significancia estadística > 0.05 .

Tabla 9. Supuesto de normalidad.

Lilliefors (Kolmogorov-Smirnov) normality test		
Modelo	D	P-value
Radar	0.2269	0.1996
Óptico	0.12663	0.9461
Combinado	0.2341	0.1658

Como lo evidencia la tabla 9, el valor p de los tres modelos es mayor al nivel de significancia, por lo que no hay evidencia estadística para rechazar la hipótesis nula, y se puede afirmar que los datos tienen una distribución normal.

Por último, se procedió con el supuesto de homocedasticidad (varianza constante). La prueba de Breusch- Pagan se utilizó para determinar si la heteroscedasticidad está presente en el modelo de regresión. La hipótesis nula indica que los errores tienen varianza constante y, por ende, el valor p de la prueba deberá ser mayor al valor de significancia estadística > 0.05 .

Tabla 10. Supuesto de homocedasticidad

Studentized Breusch-Pagan test			
Modelo	BP	df	P-value
Radar	3.958	7	0.7846
Óptico	1.6347	2	0.4416
Combinado	6.433	7	0.4902

Como lo evidencia la tabla 10, se observa que el valor p del modelo radar igual a 0.7846, mayor que el nivel de significancia, lo que indica que hay evidencia para aceptar la hipótesis nula. También, los modelos óptico y combinado pasan la prueba de homocedasticidad. Los valores p de los modelos óptico y combinado, superior al 5%, cumple la homocedasticidad y se acepta la hipótesis nula, y se afirma que los errores tienen varianza constante. Por lo anterior, se cumple el supuesto de homocedasticidad solo para los tres modelos.

La tabla 11, 12 y 13, proporciona los resultados de varianza de los modelos. Es una prueba de análisis de varianza que indica si la varianza explicada por la regresión es significativamente distinta a la varianza no explicada. Por ende, el valor del estadístico de probabilidad F inferior a una significancia del 0.05 permite concluir la dependencia lineal de la variable.

Tabla 11. Análisis de varianza (ANOVA) modelo radar.

	Sum Sq	Mean Sq	F value	Pr(>F)
IN NL	3502822	3502822	26876.838	0.003883
VH MAX	296424	296424	2274.437	0.013347
VH Entropy	4605	4605	35.334	0.106105
VH Correlation	3529511	3529511	27081.619	0.003868
VV Dissimilarity	2752436	2752436	21119.192	0.004381
VV ASM	12470	12470	95.684	0.064857
VV Correlation	246008	246008	1887.601	0.014650

Tabla 12. Análisis de varianza (ANOVA) modelo óptico.

	Sum Sq	Mean Sq	F value	Pr(>F)
NDVI	5042442	5042442	6.2752	0.04621
SAVI	480650	480650	0.5982	0.46865

Tabla 13. Análisis de varianza (ANOVA) modelo combinado.

	Sum Sq	Mean Sq	F value	Pr(>F)
Ratio 1	4464065	4464065	405385	0.0009999
VH mean	648370	648370	58879	0.0026236
VV Contrast	1298273	1298273	117897.1	0.0018541
VV ASM	825523	825523	74966.3	0.0023251
VV MAX	105713	105713	9599.9	0.0064973
VV Correlation	2807523	2807523	254953.2	0.0012608
NDVI	194928	194928	17701.6	0.0047848

La tabla ANOVA, indicó que la variable de poca significancia es el índice SAVI, no contribuye en gran medida a predecir la biomasa aérea. en las variables VH Entropía y VV ASM, la dependencia línea es estadísticamente poco significativa. Por su parte, igual que en la prueba t, la VH correlación y VV disimilitud tienen un valor del estadístico de prueba $F = 27081.619$ y 21119.192 , con valor p igual a 0.003868 y 0.004381 , respectivamente, que representan un valor menor que 0.05 .

A partir de los coeficientes presentados en la tabla 5 a 7, se obtuvieron los modelos de regresión lineal múltiple ajustados para la estimación de biomasa aérea. Las ecuación (48), (49) y (50), representan los modelos empleando las característica derivadas de las imágenes de radar, las ópticas y una combinación entre ellas respectivamente. Estos coeficiente representan el cambio en la variable de respuesta por cada unidad de cambio en la variable predictora mientras se mantienen constantes los otros predictores presentes en cada modelo. Por ejemplo, al aumentar en una unidad el índice NL, el AGB disminuye 865.51 kg/parcela, manteniendo las demás variables constantes. Se interpreta de manera similar cada variable con su respectivo coeficiente.

$$\widehat{AGB}_{Radar} = 3260.50 - 865.51(IN_{NL}) + 1959.12(VH_{Max}) + 534.12(VH_{Entropy}) + 10817.70(VH_{corre}) + 1358.48(VV_{Diss}) + 13096.113(VV_{Corr}) - 16341.90(VV_{Corre}) \quad (48)$$

$$\widehat{AGB}_{\acute{O}ptico} = 10772 - 49197683(IN_{NDVI}) + 32791147(IN_{SAVI}) \quad (49)$$

$$\widehat{AGB}_{Combinado} = -696.443 - 299.316(IN_{Ratio1}) - 69.739(VH_{Mean}) + 342.48(VV_{Contra}) + 2523.218(VV_{ASM}) - 4109.654(VV_{Max}) + 115.02(VV_{ASM}) - 24244.73(IN_{NDVI}) \quad (50)$$

Una vez obtenidos y evaluados las pruebas de hipótesis de los tres modelos, se tiene que comprobar la capacidad de estos para predecir nuevas observaciones, de este manera se verifica si determinado modelo se puede generalizar. Para esto, se emplea el método de validación cruzada K-Fold.

Tabla 14. Validación

Parcela	Ton/ha (observados)	Ton/ha (predicho radar)	Ton/ha (predicho óptico)	Ton/ha (predicho combinado)
2	49.36	49.34	48.72	76.55
3	52.88	50.12	47.92	53.48
5	85.89	112.39	100.16	113.98
6	160.03	176.06	131.84	158.63
7	65.31	53.61	123.60	23.26
9	108.83	120.68	131.68	72.73
11	167.95	179.21	121.52	20.94
12	143.66	180.33	121.44	76.88

13	122.69	155.92	125.76	112.57
Promedio	106.29	119.74	105.85	78.78
MSE		424.43	844.67	3419.52
RMSE		20.60	29.06	58.48

De acuerdo con los valores de la tabla 14, el RMSE final para cada modelo es 20.60 Ton/ha para el modelo de radar, 29.06 Ton/ha para el modelo óptico y 58.48 Ton/ha para el modelo combinado. De aquí, se seleccionó el modelo de radar, pues es el de mejor desempeño entre los tres, ya que tiene el MSE menor comparado a los otros. Por su parte, el modelo de regresión múltiple combinado obtuvo el mayor MSE de los tres. Cabe mencionar que el modelo óptico, aun cuando tuviera el mejor MSE, no debería contemplarse ya que no cumple con el supuesto de independencia de los errores en regresión lineal.




Figura 11. Diagrama de dispersión Ba observada y predicha modelo radar.




Figura 12. Diagrama de dispersión Ba observada y predicha modelo óptico.




Figura 13. Diagrama de dispersión Ba observada y predicha modelo combinado.

Además, la figura 11, 12 y 13 de manera gráfica, evidencia como los valores predichos de AGB por los modelos de regresión múltiple de radar, óptico y combinado, se ajustan a la tendencia de AGB observada de muestra. El valor de r cuadrado igual a 0.945 obtenido, indica una proporción de una variación explicada del 94.5%, para el modelo radar. La figura 14 muestra el grafico de barras de estos valores predichos y observados. Según los datos observados los valores inferiores a 80 ton/ha el modelo radar tiende a subestimar el valor predicho y para valores superiores tiende a sobreestimar.




Figura 14. Estimación Ba observada y predicha por parcela.

Distribución biomasa aérea y carbono

Se obtuvo la distribución espacial de biomasa aérea de SFF Iguaque, que a modo de visualización se parte en cuatro clases que comprenden intervalos: inferior a 49, entre 49 a 100, entre 100 a 150 y entre 150 a 180 Ton/ha, como se evidencia en la figura 15. De la misma manera, en la figura 16, la estimación de Carbono se establecieron cuatro clases que comprenden los intervalos: inferior a 24, entre 24 a 50, entre 50 a 70 y entre 70 a 90 Ton/ha.




Figura 15. Distribución espacial de biomasa aérea predicha




Figura 16. Distribución espacial del Carbono predicho.

9 DISCUSION

A partir de los resultados obtenidos en esta investigación, se evidencia que la estimación de AGB puede ser predicha con datos obtenidos de sensores remotos y a bajo coste (Sinha et al., 2015). Los resultados muestran que existe correlación entre los datos de inventarios forestales

con datos derivados de radar y óptico, y, por lo tanto, se puede construir un modelo de regresión que permita estimar y mapear la biomasa aérea y C en SFFI.

Se obtuvo tres modelos de regresión lineal múltiple, donde la construcción de cada modelo de regresión tuvo un rigor estadístico adecuado, pasando por diversos criterios y supuestos. Se identifica que el modelo de radar fue el de mejor desempeño con un coeficiente de determinación R^2 de 0.94. Que, de acuerdo con Rodríguez, (2015), el ajuste del modelo es bueno, pues el coeficiente de determinación es cercano a uno y es adecuado para describir la relación que existe entre las variables. En una metodología similar, Tovar et al., (2020) obtuvieron resultados que contrastan con lo que se obtuvo en este trabajo, los modelos multivariados combinados obtenidos por estos autores fueron los de mayor desempeño, alcanzado el mejor coeficiente R^2 de 0.28. También, cabe mencionar que el valor de este coeficiente varía de acuerdo con la cantidad de variables presente en cada modelo, por ejemplo, en el modelo combinado de Tovar et al., (2020), se emplearon 6 variables predictoras y para el caso de este estudio, se emplearon siete variables en el modelo SAR. Lo anterior, puede deberse a varias limitaciones entre las cuales se asocian los datos de campo, las características del sensor, la estructura y tipo de vegetación, la topografía entre otras como lo afirman Rodríguez et al., (2017).

Los datos de campo fueron proporcionados de un estudio previo realizado por Perea, (2018), para construcción del modelo. Enghart et al., (2011) y Joshi et al., (2015), al contar con un número reducido de parcelas de campo, se puede implantar métricas de otros sensores como LIDAR para producir mayor número de muestras de referencia a lo largo de la zona de estudio y con estas, construir los modelos. Sin embargo, aun cuando es una alternativa eficiente, no aplicaría en diversas metodologías como esta, debido principalmente al alto coste que representa. Una alternativa es la implementación de datos auxiliares como imágenes de libre acceso en los modelos, como lo realizaron Chang & Shoshany, (2016), los cuales determinaron que el modelo obtenido por datos de un único sensor como Sentinel 1 ($R^2 < 0.6$), no era más representativo que el modelo de fusión de datos derivados de Sentinel 1 y Sentinel 2 ($R^2 = 0.86$). De igual forma, como los mencionan Enghart et al., (2011) este tipo de combinaciones tiende a subestimar la biomasa. Sin embargo, como se evidencia en este caso, introducir imágenes ópticas al modelo de regresión múltiple no mejora ($R^2 = 0.54$) la respuesta del modelo.

Por otra parte, los resultados pueden verse afectados por la distribución espacial de los datos de muestra para la construcción del modelo, así como el tamaño del pixel en comparación al tamaño de la parcela, tal como lo reporta Joshi et al., (2015). Lo anterior sumado a que la distribución de las parcelas de muestra no contiene valores representativos de biomasa aérea observada a lo largo del SFF Iguaque y que tan solo el 21 % aproximadamente de la vegetación en el santuario lo ocupa Bosque Denso Andino, el resto se distribuye en vegetación de bajo volumen como pastos, arbustos y similares (IDEAM, 2010). Si bien la resolución espacial de Sentinel 1 se ajusta al Tamaño rectangular (25mx10m) de la parcela, la localización de esta, en un píxel intermedio puede introducir valores de píxel mixtos que una ventana de 3x3 no pueda atenuar adecuadamente (Hamdan et al., 2011).

Se ha evidenciado por revisiones anteriores (Rodríguez et al., 2017), que los datos de retrodispersión de radar banda C interactúan mejor con hojas y la parte alta del dosel, en

comparación con longitudes de onda más larga como L o P que interactúan mejor con ramas y troncos en donde se almacena mayor cantidad AGB. Además, estas longitudes de onda más larga se saturan a niveles de AGB más altos que los de longitud corta. En este estudio no se desconoció este hecho, por ello diversos estudios emplean datos derivados de banda L (Englhart et al., 2011; Joshi et al., 2015; Saatchi et al., 2007). Sin embargo, para Colombia el sensor ALOS 2 con polarización dual de banda L, cuenta con acceso limitado en sus datos, ya que ofrece productos promedios anuales y en algunas casos, se pueden solicitar imágenes para trabajos investigativos como lo evidencia su página oficial (<https://earth.jaxa.jp/en/>). En algunos años solo cuenta con una sola polarización o sus datos disponibles corresponde a mosaicos promedio anuales. Por ende, se optó obtener variables que reforzaran el modelo de único sensor de radar como lo son índices y texturas de imágenes y datos de sensor óptico, que contrastan la vegetación y atenúan efectos como topografía (Chang & Shoshany, 2016; Hernández-Stefanoni et al., 2020; Argamosa et al., 2018; Sarker et al., 2013).

Las variables texturales derivadas de SAR mostraron altas relaciones con los datos de AGB para la construcción del modelo como lo muestra la tabla 5. También, la correlación VH y la disimilitud VV, derivadas de la matriz GLCM arrojaron mejores resultados que los coeficientes de retrodispersión VH y VV, variables contempladas en otros modelos de regresión para la estimación de AGB (Argamosa et al., 2018; Tovar et al., 2020). Por otra parte, entre los índices de radar obtenidos y evaluados para la construcción del modelo, el índice NL se destaca más.

10 CONCLUSIONES

En esta investigación, se evidenció que existe una relación entre los datos de parcelas de campo con las respuestas de los sensores remotos óptico y radar, y por ende, se logró estimar el contenido de AGB y stock de C de la zona de estudio.

Se emplearon un total de 30 variables derivadas de Sentinel-1 y Landsat 8, que se relacionaron con los datos de referencia de campo. De las variables derivadas de SAR, se obtuvieron imágenes de textura e índices, en donde, los más representativas fueron la correlación VH y disimilitud VV; y en cuanto a índices SAR, el NL fue el que más se destacó para un nivel de significación del 0,05 para la selección de variables.

Se contruyeron tres modelos de regresión lineal múltiple que comprendieron datos derivados de SAR, óptico y combinado. Con los resultados obtenidos se identifica que el modelo derivado de SAR se ajustó mejor con un $R^2 = 0.94$ con respecto a los otros dos. Para este caso, la inclusión de variables como NDVI y SAVI a los modelos óptico y combinado no representaron mayor significancia para mejorar los modelos. Por último, con el modelo SAR, se generó la cartografía de la distribución de AGB y C del SFFI.

La disponibilidad y cantidad de datos de campo fue una limitante que influye para aportar resultados a medidas encaminadas en la protección y conservación de zonas protegidas. Sin embargo, se entiende que esta limitación de datos de campo es común debido a factores como la disponibilidad de recursos económicos y el acceso o restricciones a determinadas zonas. Por lo tanto, estos resultados se deben considerar como indicaciones preliminares para ampliar el uso futuro de datos Sentinel-1 para el monitoreo de estas zonas protegidas.

La metodología empleada es un primer acercamiento a estimación de AGB Y C en el SFFI con datos SAR, por lo que se recomienda considerar sensores de banda más larga como L o P, así como otras técnicas SAR que lo permitan. También, introducir otro tipo de índices de vegetación derivados de sensores ópticos a los aquí expuestos. Por último, se puede considerar ampliar la cantidad y/o la distribución de los datos de campo a lo largo de la zona de estudio.

11 BIBLIOGRAFÍA

Acosta, M.M., Pérez, M.R., Romero, S.M. E., González, H.A., & Martínez, A.L. (2017). Estimación de la densidad forestal mediante imágenes Landsat ETM+ en la región sur del Estado de México. *Revista mexicana de ciencias forestales*, 8(41), 30-55.

Akhtar, A. M., Qazi, W. A., Ahmad, S. R., Gilani, H., Mahmood, S. A., & Rasool, A. (2020). Integration of high-resolution optical and SAR satellite remote sensing datasets for aboveground biomass estimation in subtropical pine forest, Pakistan. *Environmental Monitoring and Assessment*, 192(9), 1–17. <https://doi.org/10.1007/s10661-020-08546-1>

Arranz, J. M., & Zamora, M. M. (2015). Análisis de Autocorrelación. 62. [http://ciberconta.unizar.es/Leccion/autocorrelacion/analisis de autocorrelacion.PDF](http://ciberconta.unizar.es/Leccion/autocorrelacion/analisis%20de%20autocorrelacion.PDF)

Artetxe, A., Del Hierro, O., Gartzia, N., Pinto, M., & Arias, A. (2016). Sumideros de carbono de la comunidad autónoma del País Vasco (Issue June). <https://doi.org/10.13140/2.1.3379.9367>

Argamosa, R. J. L., Blanco, A. C., Baloloy, A. B., Candido, C. G., Dumalag, J. B. L. C., DImapilis, L. L. C., & Paringit, E. C. (2018). Modelling above ground biomass of mangrove forest using sentinel-1 imagery. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 4(3).

Arribas, P., Abellán, P., Velasco, J., Bilton, D. T., Lobo, J. M., Millán, A., & Sánchez-Fernández, D. (2012). La vulnerabilidad de las especies frente al cambio climático, un reto urgente para la conservación de la biodiversidad. *Ecosistemas*, 21(3), 79–84. <https://doi.org/10.7818/ecos.2012.21-3.10>

Brown, S. (1997). *Estimating Biomass and Biomass Change of Tropical Forests: A Primer*. FAO Forest Paper 134. Roma, Italia.

Cabrera, E., G. Galindo & D.M. Vargas. 2011. *Protocolo de Procesamiento Digital de Imágenes para la Cuantificación de la Deforestación en Colombia, Nivel Nacional Escala Gruesa y Fina*. Instituto de Hidrología, Meteorología, y Estudios Ambientales IDEAM-. Bogotá D.C., Colombia. 44 p.

Cano, M. D. (2008). Occupation conflict in protected areas: Conservation vs Community rights. *Flora*, 7(14), 53–69.

Cevallos, A.A., & Parrado Rodríguez, C. (2018). Vulnerabilidad al cambio climático en Pedernales, Ecuador: retos desde el agua/ Vulnerability to climate change in Pedernales, Ecuador: challenges from the water. *Letras Verdes. Revista Latinoamericana de Estudios Socio ambientales*, 24, 83–104. <https://doi.org/10.17141/letrasverdes.24.2018.3326>

Chávez, P. S. 1996. Image-Based Atmospheric Corrections - Revisited and Improved Photogrammetric Engineering and Remote Sensing, [Falls Church, Va.] American Society of Photogrammetry, 62, 1025-1036

Chang, J., & Shoshany, M. (2016). Mediterranean shrublands biomass estimation using Sentinel-1 and Sentinel-2. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2016-Novem(July), 5300–5303. <https://doi.org/10.1109/IGARSS.2016.7730380>

Chuvieco, E. (1990): *Fundamentos de Teledetección Espacial*. M. Ediciones Rialp. Madrid.

Chuvieco, E. (2010). *Teledetección Ambiental (Tercera Ed)*. Barcelona, España: Ariel Editorial.

Clerici, N., Armenteras, D., Kareiva, P., Botero, R., Ramírez-Delgado, J. P., Forero-Medina, G., ... Biggs, D. (2020). Deforestation in Colombian protected areas increased during post-conflict periods. *Scientific Reports*, 10(1), 1–10. <https://doi.org/10.1038/s41598-020-61861>

Eggleston, H. S., Buendia, L., Miwa, K., Ngara, T., & Tanabe, K. (2006). IPCC guidelines for national greenhouse gas inventories.

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. <https://doi.org/10.1016/j.rse.2011.01.008>

FAO. (2004). *Inventario forestal nacional. Manual de campo. Programa de Evaluación de Los Recursos Forestales. Documento de Trabajo 94/S*, 89.

FAO. (2008). *Pago por Servicios Ambientales en Áreas Protegidas en América Latina*. In Programa FAO/OAPN: Fortalecimiento del Manejo Sostenible de los Recursos Naturales en las Áreas Protegidas de América Latina. <http://www.fao.org/3/a-i0822s.pdf>

Fernández, M.F., Velasco, S.V.M., Guerrero, C.J., Galvis, M., & Neri, A. V. (2016). Recuperación ecológica de áreas afectadas por un incendio forestal en la microcuenca Tintales (Boyacá, Colombia). *Colombia forestal*, 19(2), 143-160.

García, A.C., Barrera, X., Gómez, R., & Suárez, C.R. (2015). *El ABC de los compromisos de Colombia para la Cop 21*. Bogotá: WWF-Colombia.

Gibbs, H. K., Brown, S., Niles, J. O., & Foley, J. A. (2007). Monitoring and estimating tropical forest carbon stocks: Making REDD a reality. *Environmental Research Letters*, 2(4). <https://doi.org/10.1088/1748-9326/2/4/045023>

Gómez, H.S. (2018). LatinAmerican Post. [online] Latinamericanpost.com. Available at: <https://latinamericanpost.com/20725-voluntary-carbon-market--an-opportunity-for-colombia>

Gregersen, H., Arnold, J., Contreras H., A., et al (1995). Análisis de impactos de proyectos forestales: problemas y estrategias. Roma, Italia: FAO.

Hall-Beyer Mryka, P. D. (2017). GLCM Texture: A Tutorial. 17th International Symposium on Ballistics, 2(March), 18–19.

Hamdan, O., Khali Aziz, H., & Abd Rahman, K. (2011). Remotely sensed L-band sar data for tropical forest biomass estimation. *Journal of Tropical Forest Science*, 23(3), 318–327.

Haralick, R.M.; Shanmugam, K.; Dinstein, I. Textural Features for Image Classification. *IEEE Trans. Syst. Man Cybern.* 1973, 3, 610–621.

Hernández-Stefanoni, J. L., Castillo-Santiago, M. Á., Mas, J. F., Wheeler, C. E., Andres-Mauricio, J., Tun-Dzul, F., George-Chacón, S. P., Reyes-Palomeque, G., Castellanos-Basto, B., Vaca, R., & Dupuy, J. M. (2020). Improving aboveground biomass maps of tropical dry forests by integrating LiDAR, ALOS PALSAR, climate and field data. *Carbon Balance and Management*, 15(1), 1–18. <https://doi.org/10.1186/s13021-020-00151-6>

Hastie, T., Tibshirani, R., James, G., & Witten, D. (2006). An Introduction to Statistical Learning. In *Springer Texts* (Vol. 102).

Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309.

IDEAM. (2010). Leyenda Nacional de Coberturas de la Tierra. Metodología CORINE Land Cover adaptada para Colombia Escala 1:100.000. Bogotá D.C.: Instituto de Hidrología, Meteorología y Estudios Ambientales.

IDEAM, PNUD, MADS, DNP, CANCELLERÍA. 2015. Inventario Nacional de Gases de Efecto Invernadero (GEI) de Colombia. Tercera Comunicación Nacional de Cambio Climático de Colombia. IDEAM, PNUD, MADS, DNP, CANCELLERÍA, FMAM. Bogotá, Colombia.

Intergovernmental Panel on Climate Change (IPCC). 2007. Climate change: the physical science basis. Cambridge University Press, Cambridge, UK

Intergovernmental Panel on Climate Change (IPCC). 2013. Climate change 2013: The physical science basis. Working Group I contribution to the IPCC Fifth Assessment Report. Cambridge, United Kingdom: Cambridge University Press.www.ipcc.ch/report/ar5/wg1

Joshi, N. P., Mitchard, E. T. A., Schumacher, J., Johannsen, V. K., Saatchi, S., & Fensholt, R. (2015). L-Band SAR Backscatter Related to Forest Cover, Height and Aboveground Biomass at Multiple Spatial Scales across Denmark. *Remote Sensing*, 7(4), 4442–4472. <https://doi.org/10.3390/rs70404442>

Laguna, C. (2014). Correlación y regresión lineal. Instituto Aragonés de Ciencias de la Salud, 4, 1-18.

Lee, J.-S. (1981). Speckle analysis and smoothing of synthetic aperture radar images. *Computer graphics and image processing*, 17(1), 24-32.

Legro, C., & Tarazona, B.K. L. Determinación de la conectividad ecológica e identificación de los valores objeto de conservación del santuario de flora y fauna Iguaque. Facultad de Ingeniería Ambiental, Universidad Santo Tomás.

Lu, D. (2006). The potential and challenge of remote sensing-based biomass estimation. *International Journal of Remote Sensing*, 27(7), 1297–1328. <https://doi.org/10.1080/01431160500486732>.

Minnaert, M. (1941). The reciprocity principle in lunar photometry. *The Astrophysical Journal*, 93(3), 403–410. Tomado de: <http://ci.nii.ac.jp/naid/10025320718/en/>

Miranda, C. (2014). Los bonos de carbono, una oportunidad para Colombia. [online] Twenergy.com. Available at: <https://twenergy.com/co/a/los-bonos-de-carbono-una-oportunidad-para-colombia-1534>

Miranda, N., & Meadows, P. J. (2015). Radiometric Calibration of S-1 Level-1 Products Generated by the S-1 IPF. Technical Note, 1, 1–13. <https://sentinel.esa.int/documents/247904/685163/S1-Radiometric-Calibration-V1.0.pdf/66e69a62-11ae-4160-916b-f2b97cb8a350?t=1432307754000>

Montoya, A. (2019). Las conflictividades por el uso, ocupación y tenencia de la tierra entre las comunidades campesinas y Parques Nacionales Naturales de Colombia: el caso del Corregimiento de Pance, ubicado en el Parque Nacional Natural Farallones de Cali., 1–60.

Muñoz A.P. (2013). Apuntes de teledetección: índices de vegetación.

Moran, M.S., R.D. Jackson, P.N. Slater, and P.M. Teillet, 1992. Evaluation of simplified procedures for retrieval of land surface reflectance factors from satellite sensor output, *Remote Sensing of Environment*, 41:169-184.

Naciones Unidas. (1992). 21 Conferencia de las Partes de la Convención Marco de las Naciones Unidas sobre el Cambio Climático. Aprobación Del Acuerdo de París, 20489, 4.

Parques Nacionales Naturales de Colombia. (2013). ABC del Sistema Nacional de Áreas Protegidas SINAP 1-Antecedentes normativos y de política. 20, 1–11. www.parquesnacionales.gov.co

Perea, M. (2018). Estimación de biomasa aérea y carbono con teledetección en bosques Alto-Andinos de Boyacá, Colombia. Estudio de caso: Santuario de Fauna y Flora “Iguaque”. Departamento de Geomática, Universidad de Salzburg.

Podest, E.; McCartney, S.; McNair, H.; Jiao, X.; Banks, S.; Behnamian, A. (2019). SAR y sus Aplicaciones para la Cobertura Terrestre. NASA Applied Remote Sensing Training Program (ARSET). <https://appliedsciences.nasa.gov/join-mission/training/spanish/arset-sar-y-sus-aplicaciones-para-la-cobertura-terrestre>

Quesada, M. (2011). Análisis de Series. Modelos Heterocedásticos (Doctoral dissertation, Tesis de Maestría, Universidad de Granada, Granada). Recuperado a partir de <http://masteres.ugr.es/moea/pages/tfm1011/analisisdeseriesmodelosheterocedasticos>.

Reyes, C.O., Treviño, G.E.J., Jiménez, P.J., Aguirre, C.O. A., Cuellar, R.L.G., Flores, G.J.G., & Buendía, R.E. (2017). Dinámica de la biomasa aérea derivada de un programa de reforestación en San Luis Potosí. *Revista mexicana de ciencias forestales*, 8(39), 45-58.

Rodríguez, E. M. (2005). Errores frecuentes en la interpretación del coeficiente de determinación lineal. *Anuario jurídico y económico escurialense*, (38), 315-331.

Rodríguez, V.P., Wheeler, J., Louis, V., Tansey, K., & Balzter, H. (2017). Quantifying Forest Biomass Carbon Stocks From Space. *Current Forestry Reports*, 3(1), 1-18. <https://doi.org/10.1007/s40725-017-0052-5>

Rosenqvist, Å., Milne, A., Lucas, R., Imhoff, M., & Dobson, C. (2003). A review of remote sensing technology in support of the Kyoto Protocol. *Environmental Science and Policy*, 6(5), 441–455. [https://doi.org/10.1016/S1462-9011\(03\)00070-4](https://doi.org/10.1016/S1462-9011(03)00070-4)

Rouse, J.W., R.H. Haas, J.A. Schell, and D.W. Deering, 1974. Monitoring vegetation systems in the Great Plains with ERTS, In: S.C. Freden, E.P. Mercanti, and M. Becker (eds) *Third Earth Resources Technology Satellite–1 Symposium. Volume I: Technical Presentations*, NASA SP-351, NASA, Washington, D.C., pp. 309-317

Rügnitz, M., Chacón, M., & Porro, R. (2009). Guía para la Determinación de Carbono en pequeñas propiedades rurales. <https://doi.org/ISBN:978-92-9059-254-9>

Saatchi, S., Houghton, R. A., Dos Santos Alvalá, R. C., Soares, J. V., & Yu, Y. (2007). Distribution of aboveground live biomass in the Amazon basin. *Global Change Biology*, 13(4), 816–837. <https://doi.org/10.1111/j.1365-2486.2007.01323.x>

Salgado, L. (2004). El Mecanismo de Desarrollo Limpio en Actividades de Uso de la Tierra, Cambio de Uso y Forestería (LULUCF) y su Potencial en la Región Latinoamericana. In *Revista Desarrollo y Sociedad* (Issue 0).

Sarker, M. L. R., Nichol, J., Iz, H. B., Ahmad, B. Bin, & Rahman, A. A. (2013). Forest biomass estimation using texture measurements of high-resolution dual-polarization C-band SAR data. *IEEE Transactions on Geoscience and Remote Sensing*, 51(6), 3371–3384. <https://doi.org/10.1109/TGRS.2012.2219872>

Sarzynski, T., Giam, X., Carrasco, L., & Huay L. J. S. (2020). Combining radar and optical imagery to map oil palm plantations in Sumatra, Indonesia, using the Google Earth Engine. *Remote Sensing*, 12(7). <https://doi.org/10.3390/rs12071220>

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. <https://doi.org/10.1007/s13762-015-0750-0>

Sobrino, J.A., Jiménez-Muñoz, J.C., Paolini, L. 2004. Land surface temperature retrieval from LANDSAT TM 5. *Remote Sensing of environment*. 90(4):434-440.

Tamiotti, L.; Teh, R.; Olhoff, A.; Simmons, B.; Abaza, H. (2009). El Comercio y el Cambio Climático. Informe de la OMC y del PNUMA. In *World Trade Organization: Vol. III*. https://www.wto.org/spanish/res_s/booksp_s/trade_climate_change_s.pdf%0Ahttp://www.wto.org

Tovar, B. A. L., Lizarazo, S. I. A., & Rodríguez, E. N. (2020). Estimación de biomasa aérea de *Eucalyptus grandis* y *Pinus spp* usando imágenes Sentinel1A y Sentinel2A en Colombia. *Colombia Forestal*, 23(1), 117–141. <https://doi.org/10.14483/2256201X.14854>

U.S. Geological Survey. (2019). *Landsat 8 Data Users Handbook*. Nasa, 8(November), 114. <https://landsat.usgs.gov/documents/Landsat8DataUsersHandbook.pdf>

Villarreal, H., Núñez, M., Zorro, W., & Pacheco, C. (2017). Plan de manejo del Santuario de Fauna y Flora Iguaque. *Parques Nacionales Naturales de Colombia*.

Wegmuller, U. (1999). Automated terrain corrected SAR geocoding. In *IEEE 1999 International Geoscience and Remote Sensing Symposium. IGARSS'99* (Cat. No. 99CH36293) (Vol. 3, pp. 1712-1714). IEEE.

Woodham, R., Lee, T. 1985. Photometric method for radiometric correction of multispectral scanner data. *Canadian Journal of Remote Sensing*. 11(2):132-161.

Ximénez, M. C., & San Martín, R. (2013). *Fundamentos de las Técnicas Multivariantes*. ProQuest Ebook.