

ESTIMACIÓN DE CARBONO ALMACENADO EN LA COBERTURA FORESTAL A PARTIR DE LA CORRELACIÓN ENTRE MODELOS ALOMÉTRICOS Y TÉCNICAS DE SENSORES SATELITALES, APLICADO A UN BOSQUE ANDINO DE LA SUBCUENCA DEL RÍO LAS PIEDRAS, MUNICIPIO DE POPAYÁN.

**JUAN CAMILO ROJAS LUCERO
MARIA FERNANDA ARTEAGA RODRÍGUEZ**

**UNIVERSIDAD DEL CAUCA
FACULTAD DE INGENIERÍA CIVIL
MAESTRÍA EN GEOMÁTICA
POPAYÁN
2022**

ESTIMACIÓN DE CARBONO ALMACENADO EN LA COBERTURA FORESTAL A PARTIR DE LA CORRELACIÓN ENTRE MODELOS ALOMÉTRICOS Y TÉCNICAS DE SENSORES SATELITALES, APLICADO A UN BOSQUE ANDINO DE LA SUBCUENCA DEL RÍO LAS PIEDRAS, MUNICIPIO DE POPAYÁN.

**JUAN CAMILO ROJAS LUCERO
MARIA FERNANDA ARTEAGA RODRÍGUEZ**

Trabajo de grado modalidad profundización como requisito parcial para optar el título de magister en Geomática

**Director
PhD Fernando Felipe Muñoz
Codirectora:
PhD María Cristina Ordoñez**

**UNIVERSIDAD DEL CAUCA
FACULTAD DE INGENIERÍA CIVIL
MAESTRÍA EN GEOMÁTICA
POPAYÁN
2022**

NOTA DE ACEPTACIÓN

La tesis de maestría titulada “ESTIMACIÓN DE CARBONO ALMACENADO EN LA COBERTURA FORESTAL A PARTIR DE LA CORRELACIÓN ENTRE MODELOS ALOMÉTRICOS Y TÉCNICAS DE SENSORES SATELITALES, APLICADO A UN BOSQUE ANDINO DE LA SUBCUENCA DEL RÍO LAS PIEDRAS, MUNICIPIO DE POPAYÁN”, presentada por Juan Camilo Rojas Lucero y María Fernanda Arteaga Rodríguez, cumple con los requisitos establecidos para optar al título de Magister en Geomática.

PhD Fernando Felipe Muñoz.
Director del trabajo de investigación

Jurado

Jurado

Popayán, julio 15 de 2022

AGRADECIMIENTOS

A la Universidad del Cauca, especialmente a la Facultad de Ingeniería Civil y a cada uno de sus honorables docentes, por su contribución en nuestra formación académica y personal.

A nuestro director, PhD Fernando Felipe Muñoz, por depositar su confianza en nosotros, estimular el aprendizaje y en especial por brindarnos su disponibilidad y paciencia, de igual manera por todo lo aprendido junto a él, porque sin su ayuda realizar ésta investigación no hubiese sido posible.

A la PhD Yady Tatiana Solano Correa, por compartir con nosotros su tiempo y conocimiento, siendo nuestra guía durante el desarrollo del trabajo de investigación.

A la PhD María Cristina Ordoñez, por su acompañamiento y orientación en todo el proceso de investigación.

A nuestros amigos más cercanos, por sus consejos y años de trabajo y amistad.

TABLA DE CONTENIDO

INTRODUCCIÓN	9
2 PLANTEAMIENTO DEL PROBLEMA	12
3 JUSTIFICACIÓN	14
4 OBJETIVOS	17
4.1. Objetivo General.....	17
4.2. Objetivos Específicos.....	17
5 MARCO TEÓRICO	18
5.1. Fijación de carbono en los bosques	18
5.2. Estimación de biomasa aérea a partir de modelos alométricos.....	19
5.3. Estimación de biomasa aérea a partir de sensores remotos.....	22
5.4. Modelos de regresión para la estimación de biomasa aérea	30
5.4.1. Regresión lineal múltiple.....	30
5.4.2. Árbol de decisión	31
5.4.3. Red neuronal artificial (RNA).....	32
6 METODOLOGÍA	38
6.1. Área de estudio.....	38
6.2. Área de investigación.....	39
6.3. Revisión de datos - inventarios forestales.....	40
6.4. Análisis estadístico descriptivo de las variables de interés	41
6.5. Estimación de carbono en biomasa aérea forestal a partir de índices espectrales	41
6.6. Localización geográfica del inventario forestal	42
6.7. Selección de Imágenes Satelitales Sentinel 2A	42
6.8. Pre-procesamiento de imágenes satelitales.....	44
6.9. Generación de índices de vegetación a partir de bandas espectrales	45
6.10. Generación del modelo de regresión lineal múltiple.....	46
6.11. Configuración de la red neuronal	47
6.12. Generación y representación de los datos de biomasa aérea y carbono almacenados	47
7. RESULTADOS y discusión	48
7.1. Estimación de biomasa aérea usando modelos alométricos.....	48
7.2. Correlación entre índices espectrales y biomasa aérea	52
7.4. Regresión múltiple lineal.....	63
7.5. Red Neuronal Artificial.....	65

8. CONCLUSIONES 78
9 RECOMENDACIONES 80
10 REFERENCIAS BIBLIOGRÁFICAS..... 81

LISTA DE FIGURAS

Figura 1. Representación de una red neuronal artificial.....	33
Figura 2. Ubicación Subcuenca del Río Las Piedras.....	39
Figura 3. Flujo metodológico	40
Figura 4. Imagen RGB de la zona de estudio para el año 2016.....	43
Figura 5. Imagen RGB de la zona de estudio para el año 2020.....	43
Figura 6. Preprocesamiento en SEN2COR	44
Figura 7 Flujo de trabajo en ModelBuilder	46
Figura 8 Histogramas de densidad de DAP – Biomasa aérea	49
Figura 9. Comportamiento de la biomasa en diferentes rangos de DAP	51
Figura 10. Resultado del Índice NDVI.....	53
Figura 11. Correlación entre NDVI y biomasa aérea medida en campo.	54
Figura 12. Resultados del índice SAVI. Fuente: Propia	56
Figura 13. Correlación entre SAVI y biomasa aérea medida en campo.....	57
Figura 14. Resultados de GNDVIre3n. Fuente: Propia	59
Figura 15. Correlación entre GNDVIre3n y biomasa aérea medida en campo.....	59
Figura 16. Relación entre valores de NDVI y biomasa aérea.....	60
Figura 17. Relación entre valores de SAVI y biomasa aérea. Fuente: Propia.....	61
Figura 18. Relación entre valores de GNDVIre3n y biomasa aérea.....	62
Figura 19. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. Fuente: Propia.....	64
Figura 20. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. Fuente: Propia.....	64
Figura 21. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. Fuente: Propia.....	67
Figura 22. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. Fuente: Propia.....	68
Figura 23. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. Fuente: Propia.....	70
Figura 24. Configuración de la RNA. Fuente: Propia	70
Figura 25. Rendimiento del entrenamiento, validación y prueba.....	70
Figura 26. Regresión lineal del entrenamiento, validación y prueba.	71
Figura 27. Comparación entre imágenes RGB para el año 2016 2020.	75

LISTA DE TABLAS

	Pág
Tabla 1. Índices de vegetación	26
Tabla 2. Categorización DAP de los individuos identificados en la parcela	48
Tabla 3. Coeficientes de correlación para la regresión múltiple lineal.....	63
Tabla 4. Resultados las RNAs a partir de los índices de vegetación.	66
Tabla 5. Resultados de las RNAs configuradas.....	68

LISTA DE ECUACIONES

Ecuación 1. Regresión lineal	31
Ecuación 2. Relación de derivada del coste y parámetros	35
Ecuación 3. Función de activación	36
Ecuación 4. Derivada de la función de activación.....	36
Ecuación 5. Coste Z con respecto a parámetro w y b.....	36
Ecuación 6. Derivada del sesgo independiente	36
Ecuación 7. Equivalencia del coste Z con respecto a W.....	36
Ecuación 8. Regla de la cadena.....	36
Ecuación 9. Representación de la variación del error.....	37
Ecuación 10. Derivadas parciales de la última capa.....	37
Ecuación 11. Función sigmoide.....	37
Ecuación 12. Función de unidad lineal rectificadora.....	37
Ecuación 13. Función logística.....	37

LISTA DE MAPAS

Mapa 1. Resultados de biomasa aérea usando RNA para el año 2016.....	73
Mapa 2. Resultados de biomasa aérea usando RNA para el año 2020.....	74
Mapa 3. Resultados de carbono almacenado usando RNA para el año 2016	76
Mapa 4. Resultados de carbono almacenado usando RNA para el año 2020	77

LISTA DE ANEXOS

Anexo 1. Imágenes satelitales preprocesadas del año 2016 y 2020 e índices de vegetación.	
Anexo 2. Resultados de los índices espectrales y códigos de programación de los algoritmos de RNA y árbol de decisión	
Anexo 3. Mapas de Biomasa y carbono almacenado	

INTRODUCCIÓN

En las últimas décadas el crecimiento económico ha aumentado las emisiones de gases de efecto invernadero – GEI a la atmósfera siendo el dióxido de carbono (CO₂) uno de los principales gases que inciden directamente en la temperatura del planeta, desde el 2011 se registra un aumento significativo en la atmósfera alcanzando promedios anuales de 410 ppm de CO₂, suceso que ha contribuido que las últimas cuatro décadas sean más cálidas. Entre el 2001 al 2020 el incremento fue de 0,99 [0,84 -1,10 °C] superando las temperaturas registradas en las décadas pasadas, reportes que permitieron inferir que los GEI aportan en el calentamiento de la superficie del planeta entre 1,0 °C a 2,0°C (IPCC et al. 2021).

En este contexto la comunidad internacional científica integrada en el panel intergubernamental del cambio climático - IPCC ha diseñado diferentes metodologías e implementado estrategias para que los países aliados realicen inventarios de GEI, esto con el fin de generar medidas de mitigación que buscan la reducción de emisiones de gases de efecto invernadero. En este sentido, Colombia no ha sido ajena ante estos compromisos ratificados en la Convención Marco de las Naciones Unidas Sobre el Cambio Climático (CMNUCC), siendo El IDEAM la autoridad científica en liderar los estudios nacionales de GEI que busca la cuantificación de los gases emitidos hacia la atmósfera, es así que para el año 2012 se llevó a cabo el último estudio donde se presentó detalladamente los resultados del inventario GEI diferenciados por sectores mostrando que para los años 2010 y 2012 el equivalente de CO₂ en el sector transporte aporta el 30,4 ppm, el sector Agrícola 27,9 ppm, industria y manufactura 29,4 ppm, sector pecuario 26,2 ppm, residuos 10,9 ppm, residencial – comercial 6,2 ppm y finalmente la deforestación para el año 2010 aportó el 78,9 ppm. (IDEAM, 2015)

Por lo anterior y según las cifras reportadas por deforestación en el País, estas se han incrementado en los últimos años, estudios elaborados por el IDEAM a través del Sistema de Monitoreo de Bosques y Carbono - SMBYC realizó el seguimiento de la deforestación para el año 2020 registrando una tasa de deforestación de 171.685 Hectáreas (IDEAM 2021), situación que genera que se liberen grandes cantidades de CO₂ a la atmósfera, según las investigaciones elaboradas por Cortés et al. (2020); Gasparri, y Manghi (2004); Melo, Rodríguez, y Rojas (2011) han demostrado que la tala de bosques contribuyen aproximadamente en un tercio del calentamiento de algunas regiones del planeta ya que las masas forestales tienen la capacidad de mitigar y regular las emisiones de gases de efecto invernadero, actuando como secuestradores de dióxido de carbono a partir de la fijación de este gas en la biomasa forestal (Yepes et al. 2016)

Por consiguiente, el papel de los bosques por su capacidad de captación y almacenamiento de CO₂, es de gran relevancia en la mitigación del cambio climático, no obstante los ecosistemas forestales poseen diferentes capacidades en el almacenamiento de carbono, se cree que los bosques tropicales y subtropicales representan casi el 70% de todo el Carbono almacenado, sin embargo estas estimaciones se basan en estudio de ecosistemas de tierras bajas, los cuales presentan gran variación dificultando la capacidad de extrapolar las tendencias y los resultados de retención de carbono, de manera que resulta más eficiente determinar el secuestro de carbono en áreas con heterogeneidad ambiental como los bosques de montaña, de manera que los bosques andinos por sus características medio ambientales son considerados como una fuente de reservorios de carbono. Investigaciones recientes han demostrado que estos sistemas presentan una tasa de captación de dióxido de carbono alta por hectárea que está incluso por encima de los bosques amazónicos. No obstante, y a pesar del gran potencial de los bosques andinos en la captación de carbono según sus características biofísicas y medio ambientales se han evaluado con modelos globales a resoluciones geográficas relativamente generales lo que ha propiciado que no se determine con certeza el verdadero potencial de este ecosistema (Duque et al. 2021).

Por lo tanto, existe una necesidad considerable de realizar estudios que permitan cuantificar la variación espacio-temporal de la biomasa aérea en los ecosistemas andinos con el fin de mejorar los modelos y estimaciones encaminadas en determinar la dinámica del carbono en estos bosques y por ende su capacidad de almacenamiento.

Dentro de los estudios desarrollados para la determinación de biomasa y secuestro de carbono se han empleado diferentes herramientas, en los últimos 40 años, las observaciones terrestres y satelitales, se han utilizado con éxito para apoyar los esfuerzos en la estimación de biomasa aérea en diferentes ecosistemas Räsänen et al. (2019); Cunliffe et al. (2020); Théau et al. (2021); Chandrakant (2022); para ello se han empleado datos satelitales, producto de sensores pasivos y activos con el fin de obtener rápidamente datos que cubren grandes extensiones de áreas, por lo que muchos estudios han utilizado varios datos de detección remota para estimar la biomasa aérea a escala regional, empleando principalmente índices de vegetación (IV) extraídos de sensores ópticos los cuales pueden indicar directamente la condición de los componentes de la planta sobre el suelo (Gano et al. 2021). y su habilidad como predictores de biomasa aérea.

Para la presente investigación se emplearon datos satelitales producto del sensor remoto Sentinel 2A, seleccionado por presentar alta resolución espacial y espectral, que a partir de la combinación de las bandas espectrales se calculó ocho (8) índices de vegetación entre los cuales se encuentran: índice de vegetación de diferencia normalizada (NDVI), índice de vegetación de diferencia normalizada verde (GNDVI),

Índice de vegetación mejorado (EVI), índice de vegetación ajustado al suelo (SAVI), índice de vegetación de amplio rango dinámico (WDRVI), índice de vegetación de diferencia normalizada verde – borde rojo 1 (GNDVIre1n), el índice de vegetación de diferencia normalizada verde – borde rojo 2 (GNDVIre2n), y índice de vegetación de diferencia normalizada verde – borde rojo 3 (GNDVIre3n), los cuales se emplearon como variables predictoras de la biomasa aérea.

A partir de las variables anteriormente nombradas, se empleó modelos no paramétricos y paramétricos, como la red neuronal artificial (RNA) y el modelo de regresión múltiple lineal (RLM) respectivamente, para estimar la biomasa aérea como variable de respuesta, siendo las RNAs una técnica relativamente nueva de investigación del aprendizaje automatizado que presentan una serie de ventajas sobre los modelos de RML, (Liakos et al. 2018).

Finalmente, y a partir del modelo regresor empleado se estimó la biomasa aérea con el fin de determinar el carbono almacenado en la cobertura forestal a partir de la correlación entre modelos alométricos y técnicas de sensores satelitales, aplicado a un bosque andino de la subcuenca del río las piedras, municipio de Popayán.

2 PLANTEAMIENTO DEL PROBLEMA

El desarrollo de las actividades humanas relacionadas con los procesos productivos, industriales y tecnológicos han incrementado las concentraciones de gases de efecto invernadero (GEI) en la atmósfera, esto sumado a las alteraciones producidas por la liberación de emisiones de carbono que se han almacenado en la tierra a lo largo de la historia, están incidiendo en el incremento de la temperatura y en el cambio del clima del planeta. Cada año se depositan en la atmósfera 6.500 millones de toneladas adicionales de dióxido de carbono (CO₂) (UNFCCC (2004); Fernández (2015)). Las Naciones Unidas afirman que las principales causas del cambio climático están relacionadas con los cambios de uso del suelo, principalmente la deforestación y desertificación. A partir de estos se emiten alrededor de 25%-30% de los GEI que inciden en la ruptura del equilibrio biológico y energético del planeta (Rodríguez, 2019).

Las cifras presentadas en el reporte especial sobre los impactos del calentamiento global establecen que el aumento de temperatura inducida por el impacto antropogénico ha alcanzado aproximadamente 1°C por encima de los niveles preindustriales y de continuar así se alcanzaría el 1.5 °C alrededor del 2050 (Masson et al. 2019 y IPCC 2021)

En este sentido, la creciente problemática del cambio climático, ha generado una preocupación mundial por mitigar sus efectos. Desde 1994 La Convención Marco de las Naciones Unidas sobre el Cambio Climático ha venido trabajando en la generación de medidas para reducir las emisiones de GEI principalmente las concentraciones de CO₂, debido a que se produce en cantidades considerables. En este contexto colombiano, se han diseñado políticas de carácter nacional de producción más limpia y estrategias de desarrollo sostenible orientadas en la implementación de tecnologías de producción limpia (Guevara 2019). Asimismo, se ha reconocido la importancia de los ecosistemas y en particular de los forestales por su papel en la captación de cantidades significativas de CO₂, resaltando que contienen más del 83% del carbono global (Maser et al. 2003, IPCC 2021).

En Colombia, los estudios enfocados en la cuantificación de carbono almacenado han cobrado importancia, dada la gran variedad de bosques con altos contenidos de carbono que existen a lo largo del territorio nacional (Alvares et al. 2012, Aguas 2016). La medición y el monitoreo de carbono en la biomasa forestal se ha convertido en un tópico de gran interés en el campo investigativo. Por lo tanto, conocer y mejorar la cuantificación de sumideros de carbono y su dinámica, permite gestionar los bienes y servicios ambientales suministrados por los bosques para generar medidas de protección ante los procesos de deforestación.

La problemática generada por la deforestación ha impulsado el desarrollo de diferentes metodologías, técnicas y evaluaciones enfocadas al estudio de la cobertura forestal. Las técnicas de teledetección son cada vez más recurrentes y pueden jugar un papel importante en el seguimiento y cuantificación de las reservas de carbono en biomasa vegetal (Zhao et al., 2016), debido a los inconvenientes relacionados con el tiempo de muestreo, sobrecostos y dificultad para el acceso a las zonas de estudio.

Atendiendo lo planteado, esta investigación pretende responder la siguiente pregunta de investigación, ¿La percepción remota a partir del sensor Sentinel 2A proporciona estimaciones eficaces y confiables para determinar el almacenamiento de carbono en la biomasa aérea de un bosque Andino de la subcuenca del río Las Piedras?

3 JUSTIFICACIÓN

Los bosques andinos son reconocidos por su papel importante en la regulación y protección de las fuentes hídricas, brindando refugio a varias especies, (Yepes et al. 2015; Bokkestijn 2017), además de presentar una gran diversidad y endemismo. En este sentido, su papel en el ciclo y almacenamiento de carbono ha cobrado reconocimiento en los últimos años (Girardin et al. 2014; Gómez 2018 Spracklen y Righelato 2014). La mayoría de los estudios existentes, se han concentrado en bosques andinos de tierras bajas, debido a que son zonas de fácil acceso, y porqué son considerados los bosques más productivos del planeta (Yepes et al. 2015, Gómez 2018). Sin embargo, los bosques andinos que se encuentran a alturas superiores a los 2000 msnm, los que ocupan cerca del 7.97% del territorio nacional, son menos estudiados(Álvarez et al. 2017; Yepes et al. 2015; Gómez 2018).

Los bosques andinos colombianos son fuertemente intervenidos, lo que ha conducido a su degradación (Peña , 2014). La intervención humana ha contribuido con la desaparición de hasta el 70% de la cobertura vegetal original, debido principalmente a la ampliación de la frontera agropecuaria. Yepes et al. (2015) afirman que en Colombia queda menos del 10% de los bosques andinos originales, y probablemente, menos del 5% de los bosques altoandinos. Entre los bosques andinos más representativos en Colombia están los robledales, los cuales son rodales dominados por la especie *Quercus humboldtii*, un representante florístico de las regiones templadas holárticas, que además contienen una alta riqueza florística y gran potencial maderero de extracción (Yepes et al. 2015).

Los bosques andinos poseen la capacidad de almacenar CO₂, por lo tanto, tiene la función de mitigar el cambio climático (Théau et al. 2021; Yue, Yang, and Feng 2016; Castillo et al. 2017). Es por ello, que es importante su monitoreo, y por lo cual se han diseñado políticas internacionales, que buscan establecer compromisos vinculantes para la reducción de las emisiones GEI por parte de los países industrializados (Lezama, 2014), empleando ciertos mecanismos mediante los cuales se podrían incentivar la búsqueda de captura de carbono a través del manejo y la gestión forestal (protocolo de Kioto). De esta forma, las Naciones Unidas a través del programa de reducción de emisiones producto de la deforestación y la degradación de los bosques (REDD+) genera apoyo técnico a los países en pro de mitigar el cambio climático con el fin de estructurar un sistema de vigilancia forestal y establecer un monitoreo de estimación de las emisiones de GEI provenientes de la dinámica del uso del suelo forestal y la densidad de carbono asociada (Shao et al.,2016); así mismo, se enfatiza la implementación de sistemas de monitoreo que utilicen datos obtenidos a partir de

sensores remotos e inventarios forestales para estimar el carbono almacenado en los bosques.

En este sentido, se han desarrollado diversos métodos para la estimación de biomasa arbórea con el fin de evaluar el almacenamiento de carbono en los bosques (Askar et al. 2018). Por ello, las evaluaciones indirectas utilizando técnicas de teledetección son cada vez más recurrentes y empleadas, permitiendo reducir la intensidad del muestreo y con ello los costos de inventario forestales en escalas espaciales y temporales amplias (Balido et al. 2018). Sin embargo, en zonas altas, existen limitaciones como la nubosidad para la aplicación de éstos métodos.

Por consiguiente, las técnicas derivadas del uso de datos satelitales multiespectrales se han empleado como una herramienta determinante en la evaluación de los bosques; según Milanese, (2016), la estimación de la biomasa en bosques de zonas templadas a partir de imágenes satelitales presentó un coeficiente de correlación de 0.82, situación contraria en los bosques húmedos tropicales donde se obtuvo resultados limitados al relacionar datos satelitales con biomasa, índice de área foliar y edad de los bosques secundarios. No obstante, las técnicas e imágenes satelitales se han ido perfeccionando, con el tiempo, y de acuerdo a lo evidenciado por Li et al. (2020) se logran mejores estimaciones con la utilización de datos de imágenes Sentinel- 2A (RMSE = 7.99t/hm² para vegetación baja, 45.66t/hm² para bosques latifoliados y 6.89 t / hm² para bosque de coníferas); el estudio permitió mostrar el potencial de las imágenes Sentinel 2A para estudios de ecosistémicos de superficies pequeñas, proporcionando información útil sobre la estimación de la biomasa de la vegetación con datos de teledetección por satélite.

Por lo anterior, los datos extraídos de las imágenes Sentinel 2A presentan un gran potencial para la estimación de biomasa aérea, esto debido a que es un sensor multiespectral de alta resolución espacial (10 m) y de escala temporal corta, que incluye 3 nuevas bandas dentro de la región del espectro denominada borde rojo (680-750nm), que posibilita la aplicación de diversos índices de vegetación con el fin de mejorar la precisión de la estimación de variables biofísicas. Las ventajas de usar estas bandas en el mapeo de vegetación, ha sido evaluado en base a conjuntos de datos hiperespectrales sobre el sector agrícola obteniendo resultados confiables (Korhonen et al. 2017).

Por lo tanto, este estudio pretende determinar y evaluar índices de vegetación derivados del sensor Sentinel 2A*, con el fin de obtener un modelo de cálculo de biomasa aérea eficiente, rápido y económico que permitan determinar la cantidad de carbono almacenado en el bosque andino, esto con el fin de monitorear y evaluar el potencial de las imágenes Sentinel 2A para el cálculo de almacenamiento de carbono

en estos ecosistemas, y que sirva como una herramienta para el monitoreo de la distribución de esta variable biofísica, que permita proporcionar a los expertos y autoridades directamente vinculados a la toma de decisiones un argumento para el cuidado y protección de estos ecosistemas contribuyendo a mitigar el cambio climático.

4 OBJETIVOS

4.1. Objetivo General

Estimar el carbono almacenado en la cobertura forestal a partir de la correlación entre modelos alométricos y técnicas de sensores satelitales, aplicado a un bosque andino de la subcuenca del río las piedras, municipio de Popayán.

4.2. Objetivos Específicos

- Determinar la biomasa aérea y el contenido de carbono almacenado en el bosque andino de la subcuenca del río Las Piedras, a partir de inventarios forestales previos, desarrollados en la zona.
- Estimar la biomasa aérea y el contenido de carbono almacenado mediante la combinación de índices espectrales para bosque andino en la subcuenca del río Las Piedras.
- Validar la estimación de biomasa área y carbono almacenado a partir de información obtenida del sensor Sentinel 2A en relación a la cuantificación de almacenes de carbono de inventarios forestales del bosque andino, en la subcuenca del río Las Piedras.

5 MARCO TEÓRICO

5.1. Fijación de carbono en los bosques

Los ecosistemas forestales funcionan como uno de los principales sumideros de carbono de la superficie de la tierra, se estima que el 80% del carbono que es intercambiado entre la vegetación y suelo corresponde a los bosques, jugando un papel de gran importancia en el balance del carbono (Korhonen et al. 2017), elemento considerado como uno de los principales gases que contribuyen al efecto invernadero (GEI).

Entre los gases de efecto invernadero el mayor porcentaje de carbono en la atmósfera se encuentra en forma de dióxido de carbono (CO_2), y en menor proporción el metano (CH_4), Perfluorocarbonos (PFCs) e Hidrofluorocarbonos (HFC), que contribuyen con el equilibrio térmico del planeta. En este sentido todas las actividades que generen la liberación de carbono tales como las relacionadas al uso del suelo, alteración en la biomasa forestal, influyen directamente en la alteración del balance de carbono (Rügnitz, et al. 2008, Lakshmi 2016; Rodríguez y Jimenez 2019).

El proceso de intercambio de carbono entre la tierra y la atmósfera se da mediante los procesos de fotosíntesis, la respiración y la emisión de CO_2 producidos por las actividades humanas. Las especies vegetales capturan carbono (C) mediante la fotosíntesis, absorben energía solar y CO_2 de la atmósfera, produciendo oxígeno; proceso que se constituye como fijación de carbono en la biomasa de la vegetación generando un almacén natural de carbono, proceso contrario se presenta por la respiración de animales y plantas sumado a las acciones antropogénicas, contribuyendo así al desequilibrio del ciclo del carbono (Lakshmi 2016) .

El cambio climático es uno de los principales problemas ambientales que enfrenta la sociedad mundial, y se manifiesta en la existencia de una relación directa entre emisiones de GEI y elevación de la temperatura media del planeta. Los GEI están presentes en la atmósfera en concentraciones muy pequeñas, pero aumentan significativamente la temperatura debido a su capacidad de absorber y emitir radiación infrarroja. Los GEI acorde a los procesos físicos, químicos y biológicos presentan periodos cortos y largos de vida; el CO_2 , CH_4 y N_2O su periodo de tiempo de vida es relativamente más largo, principalmente el CO_2 que alcanza un tiempo de vida mayor a 100 años (IDEAM et al. 2015), siendo este el principal gas de efecto invernadero de origen antropogénico.

El aumento en la concentración de CO₂ en la atmósfera de la tierra es una preocupación mundial, y se considera como uno de los 6 principales gases que intervienen en el efecto invernadero, el cual está contribuyendo en mayor proporción al cambio climático (Masson et al. 2019)

Ante esta temática de interés mundial, organismos competentes se han comprometido en cooperar en la investigación y observación del sistema climático mundial acorde a los acuerdos alcanzados a partir del Protocolo de Kyoto, se establecieron metas de reducción de emisiones de GEI a través de tres mecanismos innovadores de aplicación conjunta, para un desarrollo limpio y de comercio de los derechos de emisión, cuyo objetivo es conseguir que las medidas de mitigación del cambio climático sean eficaces en relación con los costos ofreciendo a las partes medios para recortar las emisiones, o incrementar los sumideros de carbono (Tauli et al. 2011).

Una forma natural de mitigar los efectos del CO₂ en el planeta es a través de dos procesos; la fotosíntesis y la segunda mediante la descomposición y mineralización de la materia orgánica (Castro et al. 2014). En este contexto los ecosistemas forestales desempeñan un papel vital en el ciclo global del carbono, ya que lo absorben a través de la fotosíntesis y lo transforman en biomasa, creando así un almacenamiento natural de más del 40-50% del total de la absorción terrestre (Stephens et al. 2007). Los bosques además de cumplir con su rol en la conservación de biodiversidad y el mantenimiento de las reservas de carbono proveen otros servicios imprescindibles para la vida humana y la sociedad, como son la regulación hídrica y la conservación de suelos.

Por ello, el rol de los bosques es particularmente importante como reservorios de carbono porque los árboles almacenan más carbono por unidad de área que otros tipos de vegetación (Castañeda et al. 2017) en este sentido y en particular los bosques de alta montaña se han tornado en un ecosistema de interés no solamente por su función hidrológica sino por su funcionalidad en almacenamiento de carbono, considerados potencialmente como sumideros de carbono.

No obstante, el potencial de almacenamiento de carbono de un sistema forestal dependerá del contenido inicial en carbono orgánico, de las tasas de crecimiento, edad del bosque y de la capacidad biológica inherente al lugar, estas variaciones se encuentran directamente relacionadas entre ecosistemas y tipos de bosques. (Spracklen 2014)

5.2. Estimación de biomasa aérea a partir de modelos alométricos

Los bosques son los almacenes importantes que los convierten en un determinante del ciclo global del carbono (Yepes et al. 2015), responsables de la mayor parte de los flujos de carbono entre la tierra y la atmósfera a través de la fotosíntesis y la respiración (Durán y Gianoli 2013). Aproximadamente el 90% de la biomasa acumulada en la tierra se encuentra en los bosques en forma de fustes, ramas, hojas, raíces y materia orgánica (Castañeda et al. 2017).

La información obtenida de la biomasa de los árboles es esencial para evaluar el almacenamiento de carbono y su dinámica (Binkley et al. 2004), razón por la cual se ha diseñado diferentes metodologías y ecuaciones que permitan evaluar y cuantificar la estructura y condiciones de los bosques con el fin de determinar la cantidad de carbono almacenado y con ello contribuir a mitigar los impactos del cambio climático.

En particular, en los bosques andinos se presentan fuertes gradientes ambientales en distancias cortas, que pueden tener impacto en la biomasa aérea y el almacenamiento de carbono. Estudios desarrollados a lo largo de gradientes altitudinales, han concluido que a medida que incrementa la altitud disminuye la biomasa aérea (Spracklen y Righelato, 2014), en respuesta posiblemente a las limitaciones en el crecimiento que supone la disminución de la temperatura, las fuertes pendientes, cambios en la precipitación, velocidad del viento, o nubosidad, características de zonas altas.

En este sentido, las mediciones de biomasa se realizan mediante estimaciones directas e indirectas, siendo el primero un método destructivo, que implica la tala del árbol para determinar la biomasa pesando directamente cada componente del árbol (Durán y Gianoli 2013). En cuanto a los métodos indirectos son más comúnmente utilizados, donde se emplean ecuaciones alométricas, herramienta matemática que permite conocer de forma simple, la cantidad de biomasa de un árbol por medio de la medición de variables, como la altura o el diámetro. Las ecuaciones son generadas a partir de los análisis de regresión, donde se estudian las relaciones entre la masa (generalmente en peso seco) de los árboles y sus datos dimensionales (ej. altura, diámetro) (Rügnitz, et al. 2008; Yepes et al. 2015).

Una gran cantidad de modelos alométricos para las estimaciones de la biomasa aérea se han publicado durante las últimas décadas (Yepes et al. 2016; B. Liu et al. 2018; Ordoñez et al. 2020). De igual forma, para Colombia los modelos para la estimación de biomasa planteados por Chave et al. (2005) son ampliamente considerados como la mejor aproximación actual para sitios en donde las ecuaciones locales no están disponibles.

Generalmente las ecuaciones alométricas emplean el diámetro a la altura del pecho (DAP) como la única variable independiente y establecen una relación entre esta

variable y los componentes de la biomasa del árbol (Babcock et al. 2018). Otros autores incorporan la altura de los árboles o la densidad de la madera como la segunda variable predictora; sin embargo, los modelos a emplear dependerán del tipo de especie forestal, el área a estudiar y varía en función de la edad, diámetro, altura de los componentes arbóreos, la densidad de la población de cada estrato y de la comunidad vegetal.

En este sentido, el cálculo de biomasa aérea está fuertemente determinado por la variación espacial de las características funcionales y arquitecturales de las especies tales como la densidad de la madera y la altura total (Alvares et al. 2011; IDEAM et al. 2015).

En Colombia se han llevado a cabo estudios e investigaciones con el fin de estimar la biomasa aérea forestal a fin de proponer modelos a escala regional y nacional que permitan determinar estimaciones con mayor precisión en los bosques del país; los modelos desarrollados se han realizado en seis zonas de vida. Al respecto, se resalta la necesidad de generar modelos específicos para formaciones vegetales a escalas locales (Alvares et al. 2011; IDEAM et al. 2015). Teniendo en cuenta lo anterior, Yepes et al. (2015), Aguas (2016); Ontiveros et al. (2015); Gómez (2018) estudiaron la relación entre la biomasa aérea en los bosques ubicados en el sur de la región andina colombiana y el gradiente altitudinal, encontrando que los valores de biomasa más altos se encuentran en rango altitudinal de 1700 – 1800, donde las condiciones ambientales podrían ser más favorables para su crecimiento. De igual forma, afirma que incluir el DAP en modelos alométricos a escala local permitirían obtener resultados prácticos y precisos, situación contraria que ocurre a una escala regional.

Autores como Martínez et al. (2014), mencionan que el uso de ecuaciones alométricas para estimar la cantidad de biomasa y de carbono en sistemas vegetales, resulta ser más práctica y confiable. Diversos estudios (Ontiveros et al. 2015; Gómez 2018; Blanco et al. 2020) han utilizado ecuaciones alométricas para la estimación de biomasa, entre los que destacan los de Acosta, (2008), quienes generaron ecuaciones alométricas para seis especies forestales del bosque mesófilo de montaña y bosque de encino (*Quercus* spp) en Oaxaca, México. Dichas ecuaciones se basaron en el modelo $Y=bX^k$, donde Y es la biomasa aérea (Kg), X es el diámetro (cm) a la altura del pecho (DAP) y b y k son los parámetros a estimar.

De igual forma, Triana (2018), evaluó 13 modelos alométricos para establecer la biomasa presente en el bosque húmedo tropical de Paindamó, departamento del Chocó, en el cual se evidenció que el mejor modelo era el propuesto por Chave et al. (2005) que relacionó una única variable dasométrica y diámetro a la altura del pecho. Agudelo, (2018) estimó 279,73 t ha⁻¹ de carbono almacenado en un bosque de roble

(*Quercus humboldtii*) que hace parte del corredor de conservación de robles, Guantiva - La Rusia – Iguaque, ubicado en la vertiente occidental de la cordillera Oriental, en los departamentos de Cundinamarca, Boyacá y Santander. Igualmente, investigaciones, como las de Alvares et al. (2012), analizaron datos de biomasa aérea de 631 árboles en diferentes regiones biogeográficas en Colombia, evaluando la precisión de los modelos alométricos pantropicales más utilizados para la estimación de la biomasa aérea y a partir de éstas, desarrollaron nuevos modelos que permitan estimaciones más precisas de las reservas actuales de carbono en la biomasa aérea de los ecosistemas forestales naturales en Colombia.

En Colombia los bosques de roble se distribuyen desde los 750 hasta los 3450 m.s.n.m. y concurren en cerca de 18 departamentos del país, con lo que se reconocen como elementos importantes de los bosques andinos de Colombia. Sin embargo, la especie *Quercus humboldtii* hace parte de los individuos responsables de almacenar grandes cantidades de carbono en los bosques tropicales (Yepes et al. 2015).

5.3. Estimación de biomasa aérea a partir de sensores remotos

La biomasa aérea (hojas, ramas y tallo del árbol) adquiere una importancia trascendental en temas de conservación, aprovechamiento de energía, estimación de la fijación de carbono derivado del crecimiento de las plantas y que están directamente relacionados con los procesos de cambio climático (Battude et al. 2018). Por tal motivo, durante las últimas décadas los avances tecnológicos han contribuido a los estudios e investigaciones relacionados con la estimación de variables biofísicas de las masas forestales, siendo de gran importancia para lograr un mejor entendimiento del ciclo global del carbono, de las causas y efectos del calentamiento global. (Battude et al. 2018)

En la actualidad, la aplicación de las técnicas de teledetección enfocadas al inventario y monitoreo de biomasa forestal y del contenido de carbono en la vegetación son cada vez más empleadas. El uso de sensores ópticos a escala global, son el método más práctico y económico para monitorear regularmente el estado de los bosques (Battude et al. 2018); situación contraria se evidencia en la estimación de la biomasa aérea y carbono almacenado a través de los métodos directos tradicionales a partir de variables alométricas, caracterizándose por requerir un mayor esfuerzo para su implementación, no obstante, los resultados obtenidos son de alta precisión. Sin embargo, éste método aplicado en superficies extensas y de difícil acceso, no garantiza la precisión adecuada para la estimación de biomasa aérea (Torres et al. 2018). Por lo tanto, la identificación de sistemas forestales a través de sensores remotos se convierte en una herramienta fundamental para la cuantificación de la biomasa aérea y de los cambios asociados a

ella, que representan un apoyo en las investigaciones encaminadas en dar cumplimiento a los acuerdos alcanzado en el Protocolo de Kyoto.

En este sentido, autores como Milanese, (2016), Li et al. (2020) y Korhonen et al. (2017) han utilizado estas técnicas de percepción remota para realizar avances en la investigación del monitoreo, estimación de la biomasa aérea y carbono almacenado con el uso de sensores remotos pasivos y datos de campo de inventarios forestales, con diferentes grados de coeficiente de determinación; en zonas con áreas inaccesibles, las técnica de teledetección favoreció el cálculo de la biomasa forestal a partir de los parámetros derivados espectralmente de la reflectancia medida por el sensor obteniendo mayor precisión y predicción de la biomasa para el mapeo de varias características de la vegetación determinando estimaciones de predicción alrededor de $R^2 = 0.87$ y $RMSE = 10.75 \text{ t ha}^{-1}$ (Torabzadeh, et al. 2019).

La cuantificación de la biomasa aplicando técnicas de teledetección a partir de relaciones empíricas se realiza mediante índices de vegetación, definidos como un parámetro calculado a partir de valores de la reflectancia a distintas longitudes de onda, cuyo fin es extraer información relativa a la vegetación, minimizando las perturbaciones debidas a factores tales como el suelo y/o la atmósfera. Estos índices se emplean para estimar la cantidad, calidad y desarrollo de la vegetación, asimismo, pueden ser usados como indicadores de productividad en un período de crecimiento de los cultivos y plantaciones, debido a que son capaces de caracterizar la variación en la fenología y el potencial fotosintético de los cultivos y ayudar a identificar el ciclo de cultivo y el crecimiento (Jia et al. 2014).

Los índices están condicionados por cambios en el estado fisiológico de las coberturas vegetales, los más comúnmente empleados son el índice de vegetación de diferencia normalizada (NDVI), que ha demostrado ser una variable de predicción efectiva para modelar la biomasa aérea en estudios previos, sin embargo, se han evidenciado casos donde este índice se satura en coberturas densas (Tilly et al. 2015); también es comúnmente utilizado el índice de vegetación ajustado al suelo (SAVI), el que presenta un adecuado resultado cuando la cobertura vegetal es densa, debido a que este índice tienen rangos dinámicos amplios y menor susceptibilidad a las perturbaciones atmosféricas (Saadat et al. 2011); cuando se utiliza este índice, dos coberturas vegetales de igual actividad fotosintética, pero sobre suelos muy diferentes, aparecerán con igual o muy similar índice SAVI, a diferencia de lo que puede suceder en el NDVI clásico (Muñoz 2013). El índice de vegetación de diferencia normalizada verde (GNDVI), es más sensible a la variación en el contenido de clorofila que el NDVI (Jia et al. 2014) y que el índice de vegetación mejorado (EVI), que permite monitorear altas densidades de biomasa y su estado. Por lo tanto, se ha demostrado que los índices de

vegetación extraídos de datos de satélites ofrecen estimaciones útiles acerca del contenido de biomasa y por ende de carbono almacenado (Yepes et al. 2015).

La combinación de bandas espectrales derivadas de imágenes satelitales, a partir de operaciones algebraicas, permite determinar los índices que se han implementado con el fin de resaltar la vegetación sobre los demás elementos que se encuentra en el contexto, en este sentido, el cálculo de estos índices se ha logrado realizar con sensores remotos a diferentes resoluciones espaciales, principalmente aplicados a estudios que abarcan grandes superficies. Por lo tanto, a partir de los nuevos sistemas satelitales de resolución moderada, la estimación de la biomasa a nivel de parcela también se puede lograr a través de sensores con una resolución temporal más corta. Entre estas nuevas plataformas se encuentran los satélites Sentinel 2 (S2) que permiten proporcionar datos multispectrales con una frecuencia de 5 días. (Korhonen et al. 2017), además de permitir el monitoreo mejorado a una mayor resolución temporal de los datos. Sentinel 2A con las tres nuevas bandas espectrales de borde rojo S2 (RE1, RE2, RE3), mejora la precisión de la estimación de diversas variables biofísicas. Las longitudes de onda de dichas bandas varían de 705 a 865 nm y tienen una resolución espacial de 20 m. Por lo tanto, ha permitido el mapeo de vegetación evaluado con base a conjuntos de datos hiperespectrales sobre el sector agrícola y ambiental obteniendo resultados favorables (Korhonen et al. 2017).

La aplicación de imágenes Sentinel, para la estimación de biomasa y carbono almacenado, implica el cálculo de los diferentes índices de vegetación que son desarrollados a partir de la construcción de algoritmos de un modelo matemático en relación a las bandas de reflectancia del sensor (Blanco, 2018). Muhsoni et al. 2018 se enfocó en determinar un modelo para estimar el carbono almacenado en ecosistemas de manglar usando información de campo combinada, con datos de teledetección, obteniendo resultados ideales y prácticos para estimación de reservas de carbono; este resultado se obtuvo del uso de Sentinel 2 y las bandas 2, 3, 4, 5, 6, 8, 8A y 24 algoritmos de índices de vegetación. Los resultados arrojados demostraron que el mejor modelado de Sentinel-2 para la estimación del carbono de manglar es el modelo estimado con la regresión potencial geométrica.

En este mismo sentido, Blanco, (2018) estimó la biomasa aérea en plantaciones forestales de *Eucalyptus grandis* y *Pinus* spp. ubicadas en el sector centro-oriental del departamento del Cauca (Colombia), a partir de datos de radar de apertura sintética (SAR) de Sentinel-1A, datos ópticos de Sentinel 2A y datos de inventarios forestales, empleando el algoritmo Random Forest, demostrando el potencial de combinar datos Sentinel para estimar la biomasa aérea en plantaciones comerciales. Sin embargo, aún se requiere el estudio de acoplamiento espacial de los datos de campo y su incidencia

en las estimaciones de los modelos, así como la pertinencia de adelantar estudios a nivel de especies para evaluar su incertidumbre.

Askar et al. (2018), evaluaron el potencial de los índices de vegetación derivados del Sentinel-2 para estimar la biomasa aérea de los bosques. Los resultados reflejaron que el índice de diferencia normalizada (NDVI) exhibió una fuerte correlación con la biomasa aérea en comparación con otros índices. Asimismo, se empleó la regresión lineal escalonada ajustada para establecer el modelo entre la biomasa aérea y los índices de vegetación ($R_2=0.81$). Torabzadeh, et al. (2019), demostraron el potencial del instrumento multiespectral Sentinel-2 (MSI) para evaluar su rendimiento para un bosque en la provincia de Kurdistán, al oeste de Irán, utilizando el valor de biomasa aérea medido en campo, datos espectrales e índices de vegetación espectral derivados, como variables independientes en la regresión forestal aleatoria, obteniendo un valor de $R_2=0.87$. Este resultado se explica por la naturaleza técnicamente avanzada de Sentinel-2, que incluye una resolución espacial fina (10 y 20 m) y bandas estratégicamente posicionadas (red edge), realizadas en diferentes condiciones topográficas con un algoritmo de aprendizaje automático avanzado.

Igualmente, en el estudio propuesto por Blanco et al. (2020), se estimó la biomasa aérea a partir de la combinación de datos ópticos y SAR, usando sistemas de aprendizaje automatizado, los mejores resultados arrojados mostraron un coeficiente de determinación $R^2 = 0.27$ y un error cuadrado promedio $EMC = 42.75 \text{ t.ha}^{-1}$, generando buenas estimaciones de Biomasa aérea, para ello se empleó el método Random Forest, en cuanto al manejo de los datos satelitales, la retrodispersión con polarización VV mostró ser una variable importante para la estimación de biomasa aérea en el área de estudio, así como el GNDVI, no obstante se recomienda considerar una mayor área de las parcelas que incluyan más de un pixel para reducir el sistema de incertidumbre respecto a la asociación espacial entre los datos espectrales y los levantados en campo.

En general, los índices de vegetación de las imágenes multiespectrales de Sentinel-2 pueden proporcionar un resultado aceptable en términos de estimar la biomasa aérea en los ecosistemas estudiados.

Las firmas espectrales de la imagen satelital Sentinel-2 están representadas por un valor numérico que depende de la radiación almacenada en el píxel de la imagen, además, son niveles de energía de la radiancia intrínseca del objeto de estudio (Korhonen et al., 2017).

A continuación, se presenta la tabla 1, identificando los índices espectrales derivados del Sentinel 2A estudiados en el presente estudio.

Tabla 1. Índices de vegetación

Índice	Ecuación	Fuente
índice de vegetación de diferencia normalizada (NDVI)	$NDVI = \frac{NIR - RED}{NIR + RED}$	(Cunliffe et al. 2020, Théau et al. 2021)
El índice de vegetación de diferencia normalizada verde	$GNDVI = \frac{NIR - GREEN}{NIR + GREEN}$	(Prabhakara et al. 2015)
Índice de vegetación Mejorado	$EVI = 2.5 \frac{NIR - RED}{NIR + 6RED - 7.5BLUE + 1}$	(Martínez et al. 2014, Guerini Filho, Kuplich, and Quadros 2020)
El índice de vegetación ajustado al suelo	$SAVI = 1 + L \frac{NIR - RED}{NIR + RED + L}$	(Lu et al. 2004, Prabhakara, 2015)
índice de vegetación de amplio rango dinámico	$WDRVI = \frac{0.1 * NIR - RED}{0.1 * NIR + RED}$	(Vina, 2004, Cao et al. 2020)
El índice de vegetación de diferencia normalizada verde – borde rojo 1	$GNDVIre1n = \frac{REDedge1 - GREEN}{REDedge1 + GREEN}$	(Blanco, 2020)
El índice de vegetación de diferencia normalizada verde – borde rojo 2	$GNDVIre2n = \frac{REDedge2 - GREEN}{REDedge2 + GREEN}$	
El índice de vegetación de diferencia normalizada verde – borde rojo 3	$GNDVIre3n = \frac{REDedge3 - GREEN}{REDedge3 + GREEN}$	

Fuente: Propia. *Rededge1: Banda de borde rojo (1), Rededge2: Banda de borde rojo (2); Rededge3: Banda de borde rojo (3).*

Los índices de vegetación convencionales están basados en las bandas del rojo e infrarrojo cercano (NIR) del espectro electromagnético, utilizados comúnmente para estimar el área foliar y biomasa, sin embargo dichos índices son sensibles a los efectos del suelo y problemas de saturación, con el fin de disminuir este inconveniente la sustitución por bandas de borde rojo muestra modificaciones significativas ya que la reflectancia en la región espectral del mencionado borde es más sensible al contenido de clorofila ideal para identificar el estado fitosanitario de las plantas (Marini et al. 2019) por lo tanto los índices de vegetación que incluyan bandas de borde rojo permiten obtener mejores resultados en comparación con los índices que carecen de esta; por tal motivo se incluyen los índices de vegetación de diferencia normalizada de borde rojo 1, 2 y 3 que a la fecha han sido poco investigados para los bosques andinos.

El índice de vegetación de diferencia normalizada (NDVI), es un indicador adimensional que describe la diferencia de la reflectancia de la vegetación en el rango del espectro visible y el infrarrojo cercano, (González et al. 2006, Matsushita et al. 2007) ver tabla 1. Es globalmente usado para la evaluación y seguimiento de la vegetación, dado que compensa cambios en las condiciones de iluminación, la pendiente de la superficie sobre la cual se asientan las plantas, exposiciones y otros factores externos (Lakshmi 2016).

El rango de valores del NDVI oscila entre (+1,-1) es debido a que el pigmento de las hojas de las plantas, la clorofila, absorbe fuertemente la luz visible (de 0,4 a 0,7 μm) para desarrollar la fotosíntesis. Según Cunliffe et al. (2020), la estructura celular de las hojas, refleja fuertemente la luz del infrarrojo cercano (de 0,7 a 1,1 μm), cuantas más hojas tiene una planta, más se ven afectadas estas longitudes de onda de luz, respectivamente. En este sentido, según la clasificación de Ya'Acob et al. (2014) los valores negativos de la función de NDVI indican nubes, agua y nieve, los valores negativos cercanos a cero están formados principalmente por rocas y suelo descubierto.

De igual forma, Los valores entre (0.1 - 0.0) corresponden a áreas sin rocas, arena o nieve. Los valores moderados (0,2 a 0,3) representan arbustos y praderas, mientras que los valores grandes mayores a 0.6 indican bosques templados y tropicales.

En relación con la biomasa aérea, el NDVI a menudo también se ha considerado un predictor de superficie total de biomasa, sin embargo, diferentes tejidos vegetales tienen diferentes propiedades de reflectancia, y la biomasa aérea está dominada por tejidos no fotosintéticos, como tallos leñosos, en muchas comunidades de vegetación (Cunliffe et al. 2020).

En este sentido, el Índice de vegetación de diferencia normalizada verde (GNDVI), también juega un papel importante en la cuantificación de la biomasa; el GNDVI es similar al NDVI, no obstante, en lugar de registrar energía en el espectro rojo lo refleja en el espectro verde, ver tabla 1. Este indicador evidencia la actividad fotosintética de vegetación (Moges et al. 2004); su uso más frecuente es evaluar el contenido de humedad y la concentración de nitrógeno en las hojas de las plantas, en comparación con el índice NDVI, es más sensible a la concentración de clorofila (Prabhakara, et al. 2015).

De acuerdo a que el índice GNDVI es más sensible a la variación de la clorofila en cultivos que el índice NDVI y presenta un punto de saturación más alto. En relación a la biomasa aérea, Gano et al. (2021) menciona que el GNDVI presenta correlación baja, pues la predicción de biomasa fue menos precisa que LAI (Índice de área foliar), dado que la complejidad de los rasgos de la biomasa, no está necesariamente ligada a un solo índice de vegetación.

Otro índice predictor de la biomasa aérea es el índice de vegetación mejorado (EVI), que optimiza la señal de la vegetación aumentando su sensibilidad en casos de altas densidades de biomasa, mediante la separación de la señal proveniente de la vegetación y la influencia atmosférica (H. Q. Liu and Huete 1995). El EVI es un índice mejorado del NDVI con un factor de corrección del suelo $L=1$, dos coeficientes $C1=6$ y $C2=7.5$ que corrigen efectos de resistencia de aerosoles y un factor de ganancia $G=2.5$, (H. Q. Liu and Huete 1995) que se calcula de acuerdo a la tabla 1.

El EVI se diseñó basado en la retroalimentación que incorpora los conceptos de ajuste de fondo y resistencia atmosférica en el NDVI (H. Q. Liu and Huete 1995). Por lo tanto, este índice se ha considerado un NDVI modificado con una sensibilidad mejorada a las regiones de alta biomasa y una mejor capacidad de monitoreo de la vegetación (Matsushita et al. 2007). Según lo determinado por Matsushita et al. (2007), el EVI reduce los efectos adversos de los factores ambientales, como las condiciones atmosféricas y el fondo del suelo, pero no tiene en cuenta el efecto topográfico, que se define como la variación en la radiación que acompaña a un cambio de orientación de una superficie horizontal a una inclinada.

Por otro lado, el índice de vegetación ajustado al suelo (SAVI) presenta una ligera variante respecto a la fórmula tradicional del NDVI para mitigar distorsiones en los valores cuando la vegetación se encuentra sobre suelos expuestos. Condiciones como la temperatura o la humedad pueden ejercer influencia en las bandas de trabajo analizadas.

El índice de vegetación SAVI ajusta la influencia del suelo sobre los resultados añadiendo una variable denominada línea del suelo, que se genera ajustando una regresión lineal entre las bandas roja e infrarroja a partir de muestra de píxeles representativa de la cobertura del suelo desnudo permitiendo trabajar en escenarios donde el desarrollo vegetal sea bajo. Ver tabla 1.

Para el estimación de biomasa usando el SAVI y datos SAR, Kumar et al. (2016) obtuvo un $R^2= 0.86$, indicando que presenta una relación positiva moderada, como estimador de Biomasa aérea en Tailandia. En contraste, en el estudio desarrollado por (Bordoloi et al. 2022) se obtuvo una baja correlación en comparación con otros índices estudiados, debido a que la reflectancia del suelo fue minimizada sobre las propiedades de reflectancia del dosel de la alta vegetación. Por lo anterior, el SAVI, presenta mejores resultados en áreas de pastizales con baja vegetación.

Igualmente, otro de los índices predictores de la biomasa aérea, es el índice de vegetación de amplio rango dinámico (WDRVI) el cual realiza cálculos ponderados donde el coeficiente de ponderación tiene un valor de $a = 0.1$, aumentando la correlación con la fracción de vegetación mediante la linealización de la relación para las condiciones de biomasa media a alta. En este sentido, el WDRVI usa las mismas

bandas que el NDVI (ver tabla 1), permitiendo una caracterización más robusta de las características fisiológicas y fenológicas de la vegetación.

Según lo mencionado por Cao et al. (2020), indica que este modelo, es particularmente importante en condiciones de densidades moderadas a altas de biomasa, dado que la banda NIR es significativamente mayor que la banda roja, mejorando la linealidad y reduciendo la saturación, lo que facilita un control preciso del crecimiento generando al menos tres veces resultados más preciso que el NDVI, siendo capaz de detectar diferencias sutiles en el dosel en condiciones mediana y alta densidad de vegetación, importante para cultivos con copas densas y maduros.

Otros de los índices importantes propuestos para la identificación de la biomasa aérea son los índices de vegetación diferenciada normalizada verde de bordes rojos 1, 2 y 3. Dichos índices se constituyen como una mezcla de varias bandas, ver tabla 1, las bandas de borde de borde rojo oscilan entre las longitudes de ondas (680nm-740nm) han demostrado ser particularmente sensibles para detectar pequeños cambios de clorofila, pudiendo ser una herramienta valiosa para la detección temprana del estrés (Nolasco 2015).

Si bien la importancia de las bandas de borde rojo en la estimación de biomasa aérea se ha abordado en investigaciones anteriores por Blanco et al. (2020) afirma que índice GNDVI construido con las bandas de borde rojo, se muestra sensible en la determinación del contenido de clorofila, pigmento que se encuentra directamente relacionado al vigor vegetal, y a su vez, es importante para la estimación de la biomasa aérea.

Los índices de vegetación convencionales están basados en las bandas del rojo e infrarrojo cercano (NIR) del espectro electromagnético, utilizados comúnmente para estimar el área foliar, sin embargo dichos índices son sensibles a los efectos del suelo y problemas de saturación, con el fin de disminuir este inconveniente la sustitución de bandas de borde rojo muestra modificaciones significativas ya que la reflectancia en la región espectral del mencionado borde es más sensible al contenido de clorofila ideal para identificar el estado fitosanitario de las plantas (Marini et al. 2019) por lo tanto los índices de vegetación que incluyan bandas de borde rojo permiten obtener mejores resultados en comparación con los índices que carecen de esta; por tal motivo se incluyen los índices de vegetación de diferencia normalizada de borde rojo 1, 2 y 3.

De acuerdo a los índices propuestos como predictores de biomasa aérea, se requiere implementar un modelo estimativo de la misma, teniendo en cuenta el tipo de variable, se establece modelos de regresión paramétricas y no paramétricas con fin de evaluar su confiabilidad en la estimación de biomasa aérea.

5.4. Modelos de regresión para la estimación de biomasa aérea

El análisis de regresión es una técnica que calcula la relación estimada entre una variable dependiente y una o varias variables explicativas. A partir de la regresión, es posible modelar la relación entre las variables elegidas, así como predecir valores basándose en el modelo (Han et al. 2022). Existen varias opciones para estimar un modelo de regresión, entre los que se destacan por su facilidad de aplicación e interpretación, el modelo de regresión lineal y la red neuronal artificial, que se clasifican como modelo paramétrico y no paramétricos, respectivamente (Montero 2016).

Los modelos paramétricos parten de una relación entre variables conocidas, y limita el problema a predecir las diferentes variables que se adaptan eficientemente a las observaciones de la muestra en estudio (Verrelst et al. 2015). La implementación de estos modelos en algunas ocasiones resulta ser muy potente cuando el proceso generador de datos sigue la distribución propuesta, aunque pueden llegar a ser muy sensibles frente a la negación de la hipótesis de partida cuando se utilizan muestras de reducido tamaño (Montero 2016). En este sentido, los modelos paramétricos presentan limitaciones para calcular los parámetros de una función, dado que ellos parten de una relación conocida entre variables.

Teniendo en cuenta lo anterior, existen los modelos no paramétricos, que no dependen de un conocimiento previo de la relación existente de las variables explicativas y la variable dependiente. Estos últimos, resultan ser más prácticos dada las pocas restricciones para reconstruir la función de clasificación (L. Wang et al. 2018; Pattanayak et al. 2021, Bonilla M., Olmeda I. 2003).

Es importante resaltar que tanto para los modelos paramétricos y no paramétricos, es necesario estimar los parámetros que depende la función elegida, sin embargo, para los modelos paramétricos, la elección de función se establece con anterioridad, lo cual una elección imprecisa arrojará un modelo ineficaz que no se ajusta correctamente a los datos. Para la estimación de la biomasa aérea y el carbono almacenado, se estableció un modelo de regresión paramétrico y no paramétrico, como lo es la regresión múltiple lineal y la red neuronal artificial. De igual forma, para la remoción de nubes y sombras se implementó el árbol de decisión, caracterizado por ser un modelo no paramétrico (Das, Pramod, and Sunitha 2022).

5.4.1. Regresión lineal múltiple

La regresión lineal múltiple, es una técnica estadística que utiliza diferentes variables explicativas para predecir el resultado de una variable de respuesta. La regresión lineal múltiple modela la relación lineal entre las variables explicativas y las variables de respuesta (Montero 2016). A diferencia de la regresión simple, se aproxima más a

situaciones de análisis real puesto que los fenómenos, hechos y procesos ambientales, por definición, son complejos y, en consecuencia, deben ser explicados en la medida de lo posible por la serie de variables que, directa e indirectamente, participan en su relación (Montero 2016). Lo anterior expresado en la siguiente función:

$$y_i = B_0 + B_1X_{i1} + B_2X_{i2} + \dots + B_pX_{ip} + E \quad (1)$$

Donde, para $i=n$ observaciones, y_i =variable dependiente, x_i =variables explicativas, β_0 =intersección con el eje Y, (término constante), β_p =coeficientes de pendiente para cada variable explicativa, E =término de error del modelo (también conocido como los residuos).

Para llevar a cabo el modelo de regresión múltiple se debe garantizar los supuestos de linealidad, aleatoriedad, colinealidad, y homocedasticidad.

Es importante tener en cuenta que el coeficiente de determinación (R^2) es una métrica estadística que se usa para medir qué parte de la variación en el resultado puede explicarse por la variación en las variables independientes. R^2 siempre aumenta a medida que se agregan más predictores al modelo, aunque es posible que los predictores no estén relacionados con la variable de resultado (Novales 2010). Por lo tanto, R^2 por sí solo no se puede usar para identificar qué predictores deben incluirse en un modelo y cuáles deben excluirse. R^2 solo puede estar entre 0 y 1, donde 0 indica que ninguna de las variables independientes puede predecir el resultado y 1 indica que el resultado se puede predecir sin error a partir de las variables independientes.

Los métodos paramétricos (lineal, cuadrática, múltiple) aplicados sobre una gran variedad de bosques, han obtenidos valores de R^2 para datos multiespectrales de media y alta resolución entre 0.63 y 0.66 asumiendo una relación directa entre la reflectividad y los valores observados (Galidaki et al. 2017).

Por otro lado, los modelos no paramétricos hacen parte del aprendizaje automático, que es una rama en evolución de los algoritmos computacionales que están diseñados para emular la inteligencia humana aprendiendo del entorno circundante. Las técnicas basadas en el aprendizaje automático se han aplicado con éxito en diversos campos del conocimiento. Entre los modelos no paramétricos más utilizados está la red neuronal artificial y el árbol de decisión.

5.4.2. Árbol de decisión

Éste último se caracteriza dado que proveen de una herramienta de clasificación muy potente, teniendo en cuenta las diferentes posibilidades que brinda y la facilidad de comprender sus resultados ya que implementa un aprendizaje inductivo a partir de las observaciones y construcciones lógicas, similares a los sistemas de predicciones

basados en reglas, que sirven para representar y categorizar una serie de condiciones que ocurren de forma sucesiva, para la resolución de un problema (Charris et al. 2018).

Dicha representación y categorización, se realiza mediante dos etapas; en la primera etapa se construye el árbol de decisión a partir del conjunto de datos de entrenamiento; comúnmente cada nodo interno del árbol se compone de un atributo de prueba y la porción del conjunto de entrenamiento presente en el nodo es dividida de acuerdo con los valores que pueda tomar ese atributo (Sharma 2021).

La construcción del árbol inicia generando su nodo raíz, eligiendo un atributo de prueba y dividiendo el conjunto de entrenamiento en dos o más subconjuntos; para cada partición se genera un nuevo nodo y así sucesivamente, cuando en un nodo se tienen objetos de más de una clase se genera un nodo interno; cuando contiene objetos de una clase solamente, se forma una hoja a la que se le asigna la etiqueta de la clase (Xochitl 2021; Charris et al. 2018)

En la segunda etapa del algoritmo cada objeto nuevo es clasificado por el árbol construido; después se recorre el árbol desde el nodo raíz hasta una hoja, a partir de la que se determina la membresía del objeto a alguna clase. El camino a seguir en el árbol lo determinan las decisiones tomadas en cada nodo interno, de acuerdo con el atributo de prueba presente en él (Wei et al. 2019; Charris et al. 2018).

5.4.3. Red neuronal artificial (RNA)

Las RNA están diseñadas en la funcionalidad del cerebro humano, emulando funciones complejas como la generación de patrones, la cognición, el aprendizaje y la toma de decisiones (Mendoza 2018). Las RNA son modelos supervisados que normalmente se usan para problemas de regresión y clasificación. Los algoritmos de aprendizaje comúnmente utilizados en las RNA incluyen las redes de función de base radial (Liakos et al. 2018), los algoritmos de perceptrón (Rosenblatt 1958) y la retropropagación (P. A. Blanco 2014), que se desarrollan a través de unidades de procesamiento interconectadas y organizadas en una topología específica, las cuales consisten en una capa de entrada de los datos que se introducen en el sistema, seguido de una o más capas ocultas donde tiene lugar el aprendizaje y finalmente una capa de salida, que da la estimación, como se aprecia en la siguiente figura.




Figura 1. Representación de una red neuronal artificial
Fuente: propia

Las RNAs son un área relativamente nueva de investigación del aprendizaje automatizado que permite que los modelos computacionales que se componen de múltiples capas de procesamiento aprendan representaciones de datos complejos utilizando múltiples niveles de abstracción (Liakos et al. 2018).

Las RNAs tiene ciertas limitaciones en comparación con los modelos estadísticos tradicionales; un claro ejemplo, es la precisión durante el aprendizaje automático que básicamente, está fuertemente relacionada con el número y calidad de los datos, y durante del proceso, ésta puede tomar mucho tiempo o sufrir problemas de mínimos locales (Guerini Filho et al. 2020). En este sentido, existen los mecanismos subyacentes del procesamiento de información en paralelo y el almacenamiento distribuido para los modelos RNA que no son comprensibles.

Otra habilidad de la RNA consiste en resolver el problema relacionado con el peso de la convergencia de la red; pero no garantiza que la solución sea óptima; por lo tanto, se requiere un entrenamiento repetido para obtener una red neuronal óptima y lograr resultados razonables. Es importante aclarar que, aunque la red neuronal resuelve problemas multifactoriales lineales y no lineales, obtiene mayor precisión que los modelos estadísticos tradicionales; los procesos de entrenamiento de la red neuronal y las ecuaciones del modelo no se pueden observar, por lo tanto, se torna complejo explicar los resultados de RNA desde una perspectiva teórica (Batanero 2001, Naqa and Murphy 2015, Liakos et al. 2018).

La geometría de una RNA actúa como un modelo de caja negra con una arquitectura compleja que, a su vez, puede proporcionar buenos resultados para un conjunto específico de datos, es posible que no proporcione resultados precisos para otro conjunto de datos, debido al problema de sobreajuste de un modelo RNA (Naqa and Murphy 2015).

La arquitectura de la RNA, incluye también un número óptimo de capas y neuronas ocultas que depende estrictamente del problema en sí y de las pruebas repetidas, cuando el número de neuronas en la capa oculta es demasiado pequeño, el algoritmo no podrá enfocarse en la propagación inversa para alcanzar el valor mínimo durante el entrenamiento, caso contrario sucede, cuando el número de neuronas en la capa oculta es demasiado grande, la red tiende a sobreestimar. (Batanero 2001).

Dentro de la funcionalidad de la RNA, la retropropagación es una herramienta o algoritmo necesario para hacer mejoras cuando se experimentan resultados imprecisos en el aprendizaje de la máquina. Para ello, se utiliza el algoritmo de Gradiente descendente, para calcular los pesos de cada error automáticamente a través de la red (Charris et al. 2018).

En primera instancia, el conjunto de datos de entrenamiento es dividido en mini-lotes y cada mini-lote recorre el modelo hasta completar el conjunto de datos de entrenamiento, donde cada recorrida es llamada época. Cada mini-lote es pasado a la primera capa de las neuronas de la red y se va propagando hacia adelante a través de todas las capas intermedias y superiores hasta generar una salida. Sin embargo, los resultados se almacenan en cada capa para luego utilizarlos en la propagación hacia atrás (Charris et al. 2018).

Al final de la propagación hacia adelante, la función de pérdida, calcula el error teniendo en cuenta la salida de la última capa. En la propagación hacia atrás, el error se propaga a partir de la capa de salida, hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida, recibiendo el porcentaje de error aproximado a la participación de la neurona intermedia en la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aporte relativo al error total. Basándose en el valor del error recibido, se reajustan los pesos de conexión de cada neurona, de manera que la siguiente vez que se presente el mismo patrón, la salida este más cercana a la deseada, es decir, que el error disminuya (Räsänen et al. 2019).

Finalmente, el algoritmo realiza un paso de gradiente descendente para ajustar todos los pesos de conexión en la red, utilizando los gradientes de error que acaba de calcular (Girardin et al. 2014). El algoritmo de retropropagación tiene tres versiones: por lotes, cuando en la fase *hacia adelante* se calcula la función de costo como un promedio sobre los errores cometidos sobre todos los datos de entrenamiento.

En este sentido, el algoritmo de retropropagación puede calcular el gradiente del error de la red con respecto a cada parámetro del modelo. En otras palabras, puede descubrir cómo se debe ajustar cada peso de conexión y cada término de sesgo para reducir el error. Una vez que tiene estos gradientes, solo realiza un paso de descenso

de gradiente y todo el proceso se repite hasta que la red obtenga en la solución (Pattanayak et al. 2021).

El algoritmo de retropropagación requiere que las funciones de activación sean no lineales para que trabaje adecuadamente (Montero 2016). Debido a que la derivada de la función de paso es plana (cero) este algoritmo no puede trabajar con esta función. Por esta razón es necesario utilizar otras funciones de activación las cuales sean no lineales. Adicionalmente, una red neuronal de múltiples capas cuyas funciones de activación son lineales se reduce a una red neuronal de una sola capa lineal y por lo tanto no es posible resolver problemas complejos con esta aproximación. Una red neuronal de múltiples capas y con funciones de activación no lineales es capaz de aproximar cualquier función.

A partir de lo anteriormente definido y lo argumentado por Lourakis y Argyros (2005), matemáticamente el algoritmo de retropropagación se expresa, teniendo en cuenta lo siguiente:

Para determinar el coste respecto a cada uno de las modificaciones de los parámetros de la red neuronal (peso y sesgo), se implementa las derivadas parciales de cada una de estos parámetros respecto al coste, como se plantea en la siguiente expresión.

Dónde w y b , se corresponde al peso y sesgo, y L el súper índice de la última capa.

$$\frac{\partial C}{\partial b^L} \quad \frac{\partial C}{\partial w^L} \quad (2)$$

El algoritmo de retropropagación desarrolla los cálculos desde atrás hacia adelante, es decir se calculan primero las métricas de la última capa, analizando los datos de entrada, salida y el proceso respectivo. Cada neurona posee una suma ponderada (Z), la cual sería evaluada por la función de activación (a) que finalmente se evaluaría por la función de coste (C), para determinar el error.

Todo lo anterior, se estructura en una composición de funciones, que para ser solucionada se debe hacer uso de una herramienta de cálculo matemático que llamada Regla de la Cadena, la cual indica que se debe multiplicar cada una de las derivadas parciales intermedias, de la siguiente manera.

Para W (los pesos),

$$\frac{\partial C}{\partial w^L} = \frac{\partial C}{\partial a^L} \frac{\partial a^L}{\partial z^L} \frac{\partial z^L}{\partial w^L}$$

Para b (sesgo)

$$\frac{\partial C}{\partial b^L} = \frac{\partial C}{\partial a^L} \frac{\partial a^L}{\partial z^L} \frac{\partial z^L}{\partial b^L}$$

Es importante denotar que $\frac{\partial C}{\partial a^L}$ es la derivada de la activación con respecto al coste de la RNA, en esta se evidencia como varía el coste de la red cuando varía la salida de la red neuronal, en síntesis, se tiene la función del error cuadrático medio y su derivada:

$$C(a_j^L) = \frac{1}{2} \sum_j (Y_j - a_j^L)^2 \quad (3)$$

$$\frac{\partial C}{\partial a^L} = (a_j^L - Y_j) \quad (4)$$

En cuanto a la activación con respecto a Z, se expresa como varía la salida de la neurona cuando se modifica la suma ponderada; para este caso, se debe derivar la función de activación, como se representa a continuación:

$$\frac{\partial z^L}{\partial w^L} \frac{\partial z^L}{\partial b^L} \quad (5)$$

Siendo la derivada del sesgo con respecto a la suma ponderada, 1, dado que el término del sesgo es independiente.

$$\frac{\partial z^L}{\partial b^L} = 1 \quad (6)$$

Con respecto a w, la derivada es simplemente el valor de entrada a la neurona que conecta a esa conexión para cual ese parámetro hace referencia.

$$\frac{\partial z^L}{\partial w^L} = a_i^{L-1} \quad (7)$$

Finalmente, la solución para los parámetros de la última capa se obtiene computando las derivadas intermedias anteriormente descritas. Sin embargo, se reestructura las expresiones, teniendo en cuenta que:

$$\frac{\partial C}{\partial a^L} \frac{\partial a^L}{\partial z^L} = \frac{\partial C}{\partial z^L} = \delta^L \quad (8)$$

Representando la variación del error en función del valor de Z calculada dentro de la neurona, dicha derivada informa en qué grado se modifica el error cuando se produce un cambio en la suma ponderada de la neurona. Dicha derivada evidencia la

responsabilidad de la neurona en el error final. Luego, para las expresiones iniciales, se tendría:

$$\frac{\partial C}{\partial b^L} = \delta^L \quad \frac{\partial C}{\partial w^L} = \delta^L - a_i^{L-1} \quad (9)$$

Con lo anterior, se deduce las expresiones para hallar las derivadas parciales y el error en la última capa. Posteriormente, se define la función para calcular el error en las capas anteriores, se tienen finalmente las siguientes expresiones:

$$\delta^{L-1} = W^L \delta^L \frac{\partial a^{L-1}}{\partial z^{L-1}} \quad \frac{\partial C}{\partial b^{L-1}} = \delta^{L-1} \frac{\partial C}{\partial w^{L-1}} = \delta^{L-1} a^{L-2} \quad (10)$$

Es importante denotar que una de las funciones de activación más utilizadas en redes neuronales artificiales es la función logística, la cual se presenta en la Ecuación 13. La salida de la función logística esta entre 0 y 1. Aunque tiene una derivada bien definida en todo el plano, cuando tiene valores grandes o pequeños a la entrada, la función se satura y la derivada se hace cero o casi cero.

Otras funciones utilizadas en redes neuronales artificiales es la función de tangente hiperbólica, la siguiente ecuación, es también es una función sigmoide con la diferencia que su salida está en el rango de -1 y 1.

$$\sigma(z) = \frac{1}{(1 + \exp(-z))} \quad (11)$$

Debido a que la función logística es poco sensible a valores muy grandes o muy pequeños se prefiere utilizar otra función de activación como la función de Unidad Lineal Rectificada, se presenta las siguientes ecuaciones.

$$ReLU(z) = \max(0, z) \quad (12)$$

$$\sigma f(z) = \frac{2}{(1 + e^{-2z})} - 1 = 2 \sigma(2z) - 1 \quad (13)$$

6 METODOLOGÍA

La presente investigación se estructuró bajo el enfoque cuantitativo, que permitió diseñar y aplicar instrumentos de medición para la obtención de datos verificables a partir de la aplicación de métodos matemáticos y estadísticos.

6.1. Área de estudio

La investigación se desarrolló en el área de la subcuenca río Las Piedras (ver figura 2), localizada al nororiente del municipio de Popayán, entre latitudes 2°26'57,658 "N y 2°25'28,161"N, longitudes 76°31'13,995" W y 76°23'8,273" W, presenta una extensión de 6.626 hectáreas y comprende alturas que oscilan desde 1.980 a 3.820 msnm, teniendo jurisdicción los corregimientos de Quintana y Las Piedras, esta área se caracteriza por la presencia de zonas de páramo, subpáramo, bosques alto-andinos, andinos y subandinos, siendo la subcuenca la principal fuente abastecedora de agua para el municipio de Popayán (Devereux 2013).

En la Subcuenca del río Las Piedras, dominan diferentes especies forestales entre las cuales se encuentra el roble (*Quercus humboldtii*), arrayan (*Myrcianthes* sp. O. Berg), jigua (*Nectandra reticulata* Mez), *Guarea kunthiana* A.Juss, entre otras. Para el desarrollo de esta investigación se seleccionó una ventana de estudio que comprende un área de 612.928 hectáreas localizada en la vereda Quintana, presentando una altitud de 2.600 m.s.n.m.; con rangos promedio anuales de temperatura de 18,4°C; precipitación de 1.729 mm; y humedad relativa de 84 % (CRC, 2006); en esta zona previamente se establecieron parcelas permanentes de un área de 7.5 hectáreas para monitoreo de vegetación, como resultado de un proyecto de investigación (Valencia 2013).

Los datos empleados para la estimación de carbono almacenado del presente estudio se realizaron a partir del cálculo de biomasa aérea, para ello, fueron tomados los datos de la parcela permanente del inventario forestal suministrado por Valencia,(2013) y el grupo de investigación de estudios ambientales (GEA) de la Universidad del Cauca. Dentro de la parcela permanente se encontraron inventariadas diferentes especies forestales pertenecientes a la clasificación de bosque andino (Cortés, Ballesteros, y Matoma 2020), clasificados según las condiciones medio ambientales y gradiente altitudinal característico de estos ecosistemas (Kattán, 2003). En esta zona se identifican relictos de bosque andino, caracterizados por ser un ecosistema estratégico, no solamente por ser una zona de nacimiento de fuentes hídricas que abastecen de

agua a acueductos municipales, sino también por la importancia y la función de los bosques en la captación y fijación del carbono atmosférico (Ontiveros et al. 2015).

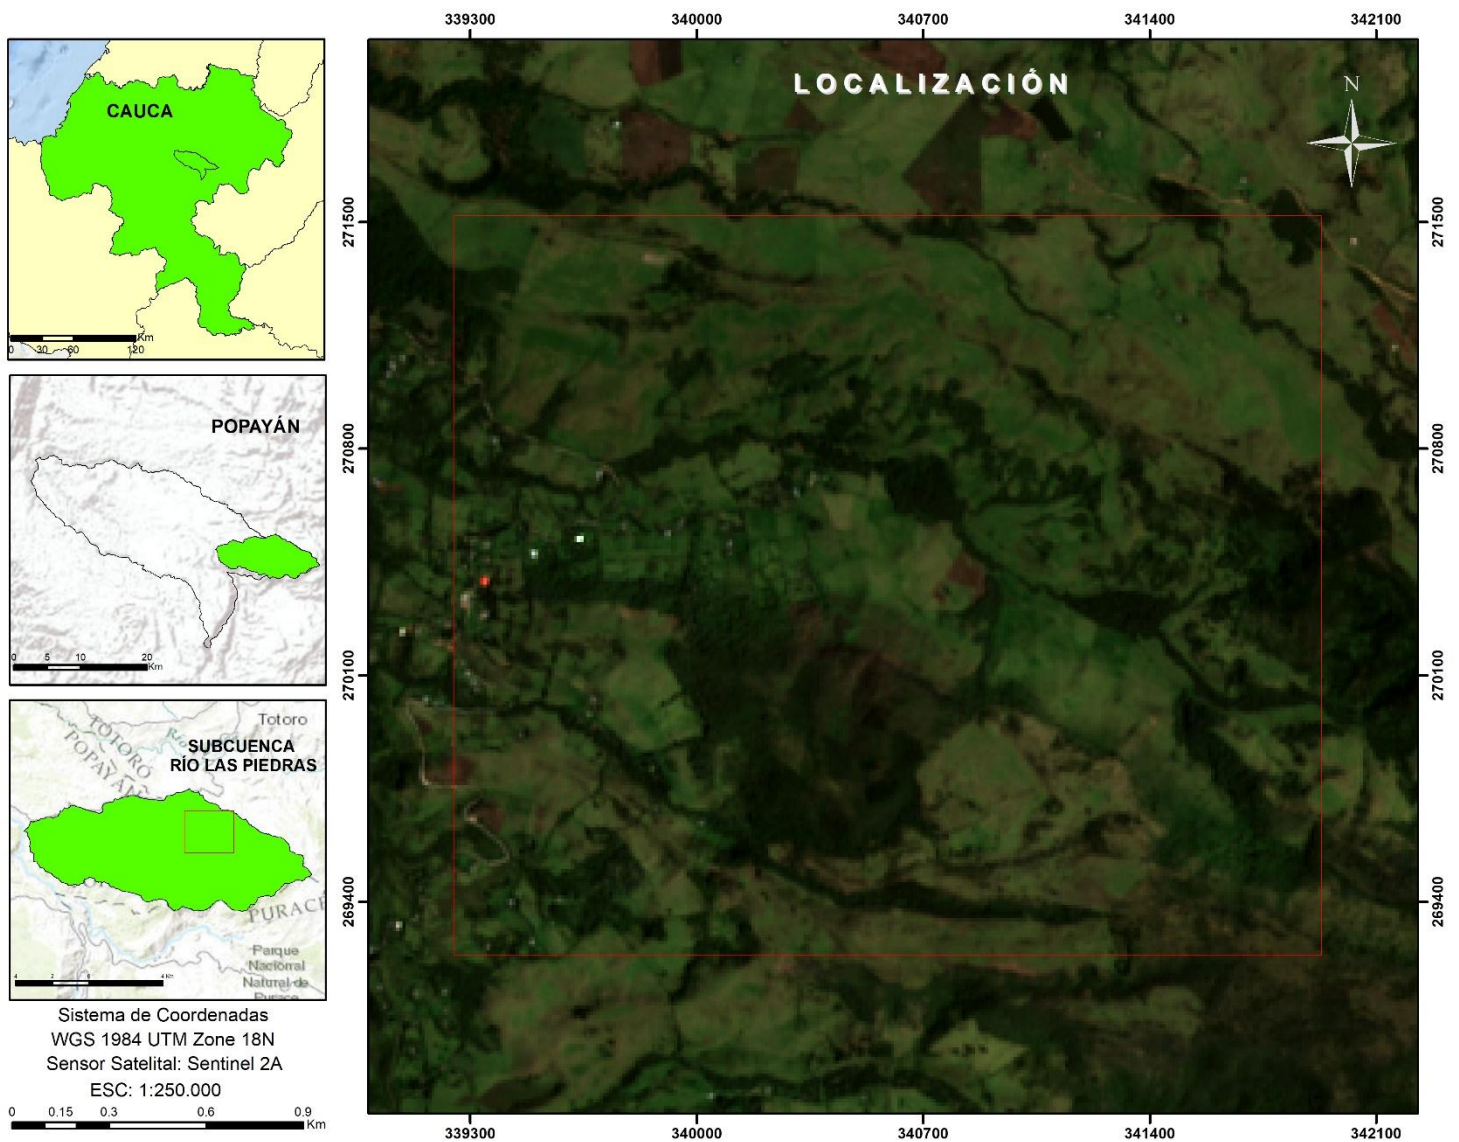


Figura 2. Ubicación Subcuena del Río Las Piedras

Fuente: Propia

6.2. Área de investigación

Para el desarrollo de esta investigación se realizó la búsqueda y revisión de inventarios forestales, donde se tuvo como parámetro de selección factores ambientales, como el gradiente altitudinal, para el cual se tomaron parcelas de especies forestales entre 2.400 y 3.400 m.s.n.m pertenecientes a la clasificación de bosque andino (Kattán, 2003). Los relictos de bosques se encuentran localizados en la subcuena del Río Las

Piedras. (Ontiveros et al. (2015). A continuación, se presenta la figura 3 del flujo metodológico desarrollado, que permite visualizar las actividades que dieron lugar al objetivo de la presente investigación.

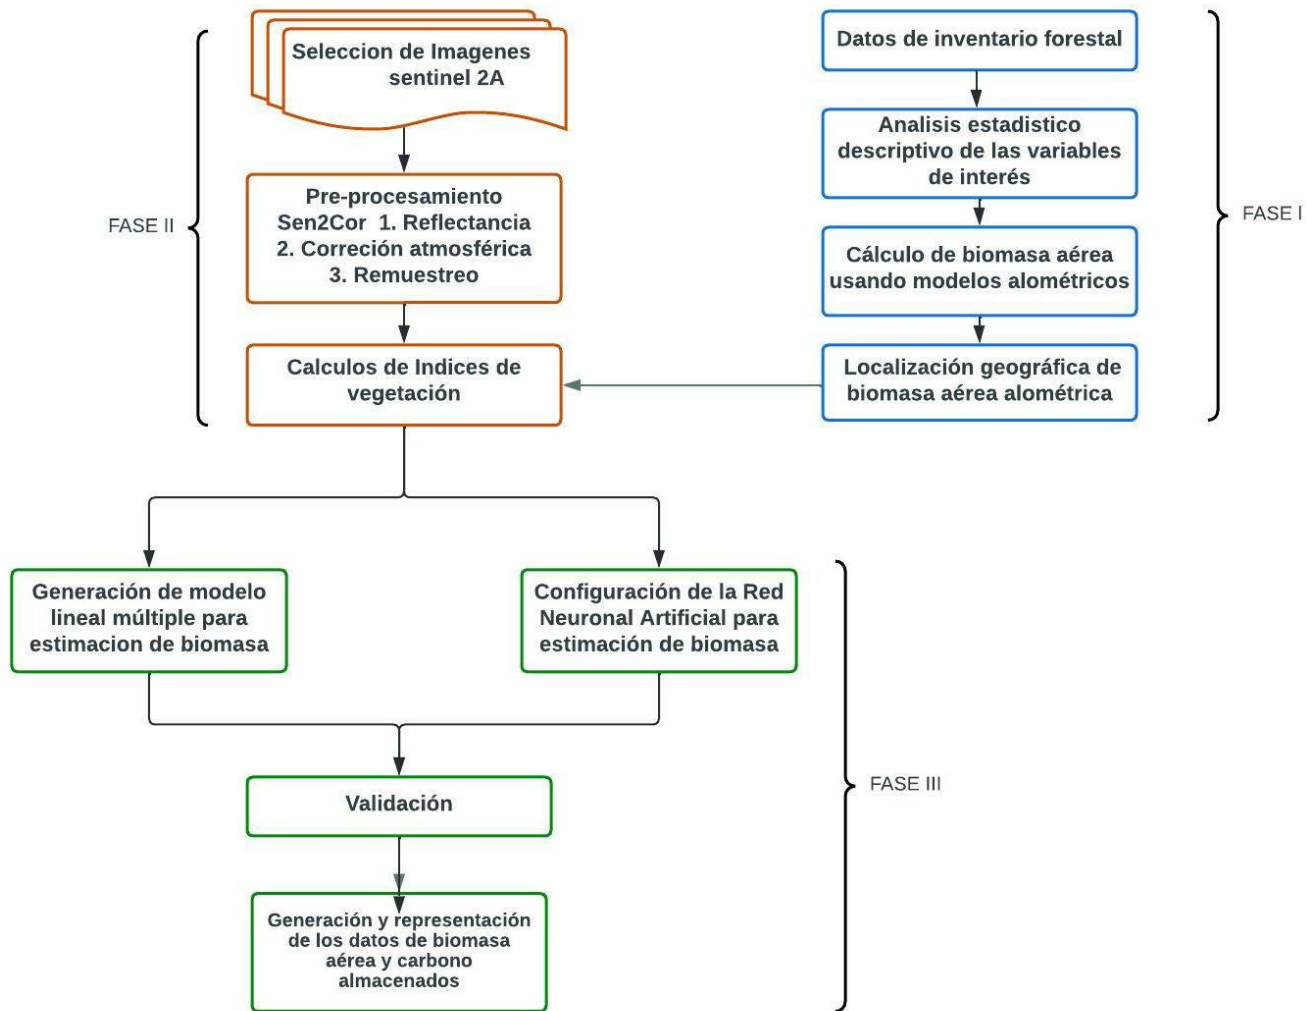


Figura 3. Flujo metodológico

Fuente: Propia

6.3. Revisión de datos - inventarios forestales

Los datos obtenidos del inventario forestal de la Reserva de la Sociedad Civil Arrayanales, en la Vereda Quintana, Municipio de Popayán, incluyen la composición y estructura vegetal, según la base de datos suministrada; la información se encuentra establecida por cuadrantes de la A a la Z y están clasificados por familia, especie, registrando el diámetro a la altura del pecho DAP y altura total.

La zona de estudio comprende un área de 7.5 hectáreas en la que se ubica el bosque andino y se encuentra espacializado el inventario forestal, el cual fue utilizado, para realizar el modelo estimativo. Esta área se subdividió en 26 cuadrantes para un total de 1055 individuos y un área resultante de 1.5 hectáreas, según el diseño experimental realizado de Sarria et al., (2013). entre las especies más representativas se identificó El roble (*Quercus humboldtii*), El Encenillo (*Weinmannia sp.*), Arrayán (*Myrcianthes leucoxylla*), (*Freziera canescens*), Mortiño, (*Vismia lauriformis*), Mayo (*Tibouchina sp.*), Pino Colombiano (*Podocarpus oleifolius*), mandur (*Tibouchina sp.*), Cucharo (*Clusia sp.*), Motilón (*Miconia caudata*), Mano de Oso (*Oreopanax discolor*), Chilco (*Baccharis latifolia*), Jigua (*Nectandra sp.*), Carne Fiambre (*Roupala sp.*), entre otras, los individuos presentaron un DAP ≥ 5 cm, igualmente (Sarria et al., 2013).

6.4. Análisis estadístico descriptivo de las variables de interés

El procesamiento estadístico de los datos del inventario forestal suministrado, se estructuró mediante el programa computacional R Studio de licencia libre, en aras de identificar tendencias y características más representativas de los individuos arbóreos. De igual forma, a partir de los resultados, se organizó la información, en subpoblaciones, dado el DAPs, obteniendo cinco grupos con rangos diferentes de DAPs, con el fin de caracterizar e identificar la distribución de los datos determinando la media, desviación estándar y curtosis, lo que finalmente, permitió conocer el comportamiento general del bosque andino.

6.5. Estimación de carbono en biomasa aérea forestal a partir de índices espectrales

La cuantificación del carbono almacenado en la biomasa aérea se realizó a partir de datos dasométricos suministrados por el Grupo de Estudios Ambientales (GEA) de la Universidad del Cauca, implementando el modelo alométrico propuesto por Álvarez et al., (2012), el cual permite calcular la biomasa aérea de los árboles individuales, partiendo de las variables tales como el diámetro del tronco a la altura del pecho DAP y la densidad de la madera. Posteriormente, la biomasa es convertida en unidades de carbono a partir del factor de conversión 0.5 establecido por Eggleston et al., (2006).

El modelo diseñado por Álvarez et al., (2012), se ajusta a las dinámicas específicas de los bosques naturales presentes en el país y que además es específico para las zonas de vida identificadas y descritas dentro del estudio como bosque húmedo según Holdridge et al. (1971) que tiene en cuenta el rango altitudinal, y el potencial de evapotranspiración.

$$\ln(AGB) = a + b_1 \ln(D) + b_2 (\ln(D))^2 + b_3 (\ln(D))^3 + d \ln(\rho) \quad (1).$$

Dónde: **AGB** (Kg) = Sigla en inglés de above-ground biomass (biomasa por encima del suelo o aérea). **a** = 1,836 **b1**= -1,255 **b2**= 1,169 **b3**= - 0,122 **d** = - 0,222 **D** = Diámetro a la altura del pecho (expresado en cm) ρ = Densidad de la madera (expresada en g cm-3)

6.6. Localización geográfica del inventario forestal

Los datos del inventario forestal de cada uno de los cuadrantes inventariados, se sistematizaron y se ubicaron geográficamente, determinando así la zona de estudio, localizada en la Subcuenca del río Las Piedras, información que fue utilizada en la selección de las imágenes satelitales de las cuales se extrajo datos de biomasa que fueron comparables con la información extraída mediante la aplicación de un modelo alométrico implementado para este estudio.

La localización de los datos del inventario forestal se realizó con el apoyo de herramientas de sistemas de información geográfica - SIG a partir del software ArcGis 10.5 en su versión académica.

6.7. Selección de Imágenes Satelitales Sentinel 2A

Los datos satelitales empleados en la presente investigación fueron obtenidos a partir del sensor remoto Sentinel 2A, imágenes que fueron seleccionadas por su potencial para evaluar parámetros biofísicos como el índice de área foliar, temáticas relacionadas con carbono terrestre y vigilancia de los bosques y vegetación (Blanco,2020).

La selección de las imágenes estuvo sujeta a la fecha del levantamiento del inventario forestal suministrado que data del año 2015, de manera que se descargaron imágenes obtenidas en el periodo comprendido entre junio del 2015 a diciembre 2016, no obstante, la zona objeto de estudio presenta alta nubosidad durante todo el año, por lo tanto, el análisis se realizó con la imagen de fecha 16/09/2016 (ver figuras).



Figura 4. Imagen RGB de la zona de estudio para el año 2016

Fuente: Propia



Figura 5. Imagen RGB de la zona de estudio para el año 2020

Fuente: Propia

Cabe anotar que también se realizó la descarga de imágenes, en otras temporalidades; datos del 2020, esto con el fin de realizar un análisis temporal adicional de toda la ventana objeto de investigación y estudiar el comportamiento de la biomasa.

6.8. Pre-procesamiento de imágenes satelitales

Una vez realizada la descarga de los datos satelitales se procedió a verificar el nivel de procesamiento de cada una de las imágenes, encontrando que las mismas presentaban un nivel de procesamiento L1C, es decir, ortorectificadas y con niveles de reflectancia por encima de la atmósfera (TOA), condición que no considera el efecto de la atmósfera imposibilitando la adecuada detección de lo sucedido en la superficie.




Figura 6. Preprocesamiento en SEN2COR
Fuente: Propia

Por lo anterior se procedió a realizar el procesamiento de las imágenes Sentinel 2A, empleando el software de uso libre SNAP (Sentinel Application Platform), a partir de la herramienta Sen2Cor, aplicación que permitió corregir las distorsiones radiométricas y geométricas de las imágenes obteniendo un nivel de procesamiento L2A, pasando los datos de reflectancia a nivel de la superficie (BOA), generando datos más precisos removiendo la textura blanquecina producida por el efecto de la presencia de la atmósfera. (Mendoza 2018), sin embargo, esta herramienta no removió la totalidad de la nubosidad dada la proporción de la misma, lo que hizo indispensable implementar un método más robusto como lo es el método de Árbol de decisión.

Para ello, se establecieron las clases que agrupan nubes, no nubes, sombras y no sombras, a partir de la banda de borde rojo 1, se obtuvieron 10 puntos de valores espectrales por cada clase, como insumo principal del Random Forest, que acorde a sus características permiten caracterizar idóneamente las nubes y las sombras.

A partir de la clasificación obtenida, se realizó un recorte sobre los datos espectrales usando el software ArcGIS 10.5, para obtener finalmente el mapa de biomasa aérea y carbono almacenado sin afectación de la nubosidad.

Como paso final, se realizó el remuestreo de las bandas, es decir que para todas las bandas espectrales se trabajó con una resolución de 10m, esto apoyado en el estudio desarrollado por Qunming, et al. (2016).

6.9. Generación de índices de vegetación a partir de bandas espectrales

La selección de los índices de vegetación consistió en identificar a partir de estudios relacionados, la habilidad de estimar la biomasa aérea en vegetación densa, estableciendo los índices de la tabla 1

En cuanto al índice EVI, las constantes relacionadas dentro de la ecuación como el coeficiente de corrección del suelo $L=1$, y el coeficiente de corrección por dispersión atmosférica $C1=6$ y $C2=7.5$ son establecidas directamente para el sensor Sentinel por la ESA. De igual manera, para el índice SAVI, su coeficiente ($L=0.5$) fue establecido teniendo en cuenta las condiciones de la zona de estudio y lo reportado en el estudio (Bordoloi et al. 2022).

El cálculo de los índices de vegetación se inició a partir de la operación entre bandas espectrales del Sentinel 2A, preprocesadas y corregidas atmosféricamente, usando el software Matlab en su versión académica. Seguidamente, con los índices de vegetación calculados, se usó la aplicación *ModelBuilder* de ArcGis ESRI creando un flujo de trabajo como se ve en la siguiente figura para recortar todos los índices a la zona de estudio de forma eficiente.

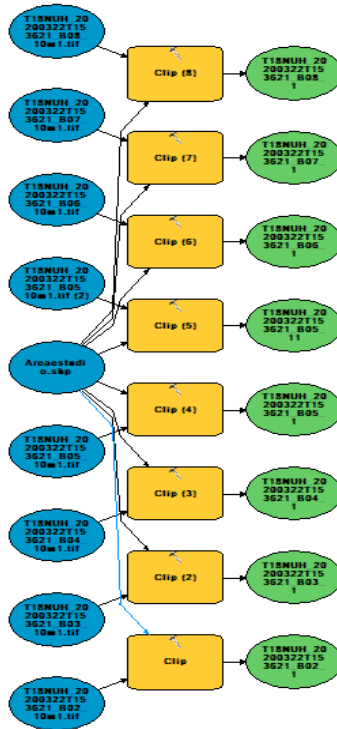


Figura 7 Flujo de trabajo en ModelBuilder
Fuente: Propia

6.10. Generación del modelo de regresión lineal múltiple

Inicialmente se asumió el cumplimiento de los supuestos estadísticos entre las variables predictoras (índices de vegetación), tales como colinealidad, homocedasticidad, linealidad, y aleatoriedad, con el objetivo de explicar la variable respuesta (biomasa aérea).

Para la construcción y validación de un modelo estadístico en la estimación de biomasa aérea en términos de la reflectancia, se usó el software Matlab en su versión académica para relacionar el valor del índice espectral con la biomasa calculada mediante los datos de campo.

Para ello, se dividió el total de los datos de biomasa en campo, seleccionando aleatoriamente el 70% para el entrenamiento y el 30% para la validación a partir del modelo establecido.

Teniendo en cuenta lo anterior, se procedió a interpretar las relaciones estadísticas entre biomasa medida en campo y los valores de los índices espectrales estudiados, mediante análisis gráfico de carácter individual, de igual forma, se obtuvieron los valores de biomasa estimados en relación al resultado de la biomasa medida en campo.

El comportamiento de las variables predictoras en las diferentes combinaciones y el valor de biomasa aérea medido en campo, fueron calculados a partir de los diferentes coeficientes de correlación, que muestra la proporción de la varianza de la variable dependiente explicada por el modelo.

6.11. Configuración de la red neuronal

Las variables ingresadas como datos de entrada a la red neuronal fueron los índices de vegetación espectral calculados para la predicción de biomasa aérea, utilizando el software Matlab, se desarrolló la fase de configuración de la RNA, en dos etapas de identificación, teniendo en cuenta la división de los datos de campos realizada anteriormente.

Índices espectrales influyentes: se configuró a partir de las diferentes combinaciones de índices de vegetación propuestos, en relación a los errores generados a nivel interno de la RNA y la validación con los datos de campo, obteniendo la combinación espectral adecuada.

Estructura de la red neuronal: a partir de la combinación de índices espectrales seleccionada, se estableció como algoritmo de retropropagación, a *Levenberg-Marquard*, teniendo en cuenta lo afirmado por Lourakis y Argyros (2005).

Seguidamente, se realizaron las pruebas modificando el número de capas ocultas y el número de neuronas, evaluadas a partir del RMS obtenido en cada una de ellas, y de esta manera se estableció la mejor combinación de capas ocultas y neuronas.

Finalmente, obtenidas el número de capas ocultas, se estableció como funciones de transferencia, las determinadas por Dorofki et al. (2012), teniendo en cuenta las ventajas reflejadas en *purelin*, *Log-sigmoid* y *Hyperbolic tangent sigmoid*.

6.12. Generación y representación de los datos de biomasa aérea y carbono almacenados

Como resultado final de la red neuronal configurada y evaluada, se obtuvo el valor de biomasa aérea a partir de los índices espectrales de cada temporalidad. Con la determinación de la biomasa aérea se procedió a determinar el carbono almacenado a partir del factor de conversión. Los anteriores resultados fueron presentados a partir del software ArcGIS 10.5.

7. RESULTADOS Y DISCUSIÓN

Los resultados se presentaron en tres secciones; en el primer aparte se desarrolló la estimación de biomasa aérea a partir de modelos alométricos, posteriormente se aborda la estimación de biomasa a partir de los modelos paramétricos y no paramétricos empleados para estudio, y finalmente se estableció un comparativo de los resultados obtenidos.

7.1. Estimación de biomasa aérea usando modelos alométricos

La estimación de la biomasa aérea para cada individuo arbóreo inventariado se realizó a partir de un DAP > 10 cm. De acuerdo con Agudelo (2009), los árboles de diámetros menores contribuyen poco a la biomasa y carbono de un bosque, especialmente los árboles de gran porte como el roble *Quercus humboldtii*. Las variaciones encontradas en los DAP de las diferentes especies se categorizaron en los siguientes rangos como se muestra en la tabla 2.

Tabla 2. Categorización DAP de los individuos identificados en la parcela

Rango DAP (cm)	Número de individuos	Biomasa Aérea Promedio $ton\ ha^{-1}$	Carbono almacenado Promedio $ton\ ha^{-1}$	Desviación estándar	Porcentaje (%)
10-20	336	35.97	17.98	0.13	9.87
20-40	244	136.75	68.37	0.34	37.51
40-60	57	103.39	51.69	0.53	28.36
60-80	13	53.32	26.66	0.65	14.62
80-100	5	35.17	17.58	0.97	9.65

Fuente: propia

Es importante resaltar que la desviación estándar representó un comportamiento directo en relación con los rangos de DAP y número de individuos por rango (tabla 2), es decir, se encontró el valor más bajo para los rangos de DAP de 10-20 cm, esto debido a que para este grupo se presentó una mayor cantidad de individuos (336 individuos). Caso contrario sucedió con el rango de 80-100 cm, dado que se presentó una desviación estándar alta de 0.97.

El análisis de la estadística descriptiva determinó que dichas variables tanto el DAP y la biomasa área en todos los rangos establecidos, mantienen un comportamiento asimétrico positivo, como se determinó en la figura 8, lo cual indica que se encuentran valores menores de Biomasa y DAP con mayor frecuencia, lo cual es característico de un bosque relativamente joven, pues cuenta con suficientes individuos en estado de

crecimiento que aportan biomasa a la medida que se van desarrollando (Bokkestijn 2017). Dicha característica, es más prominente en los rangos de DAP pequeños y que a medida que se incrementa el DAP, tiende a un comportamiento normal de los datos, lo cual según Cortes et al. (2020) indica que la tendencia de la distribución asimétrica positiva, evidencia una regeneración activa del bosque andino.

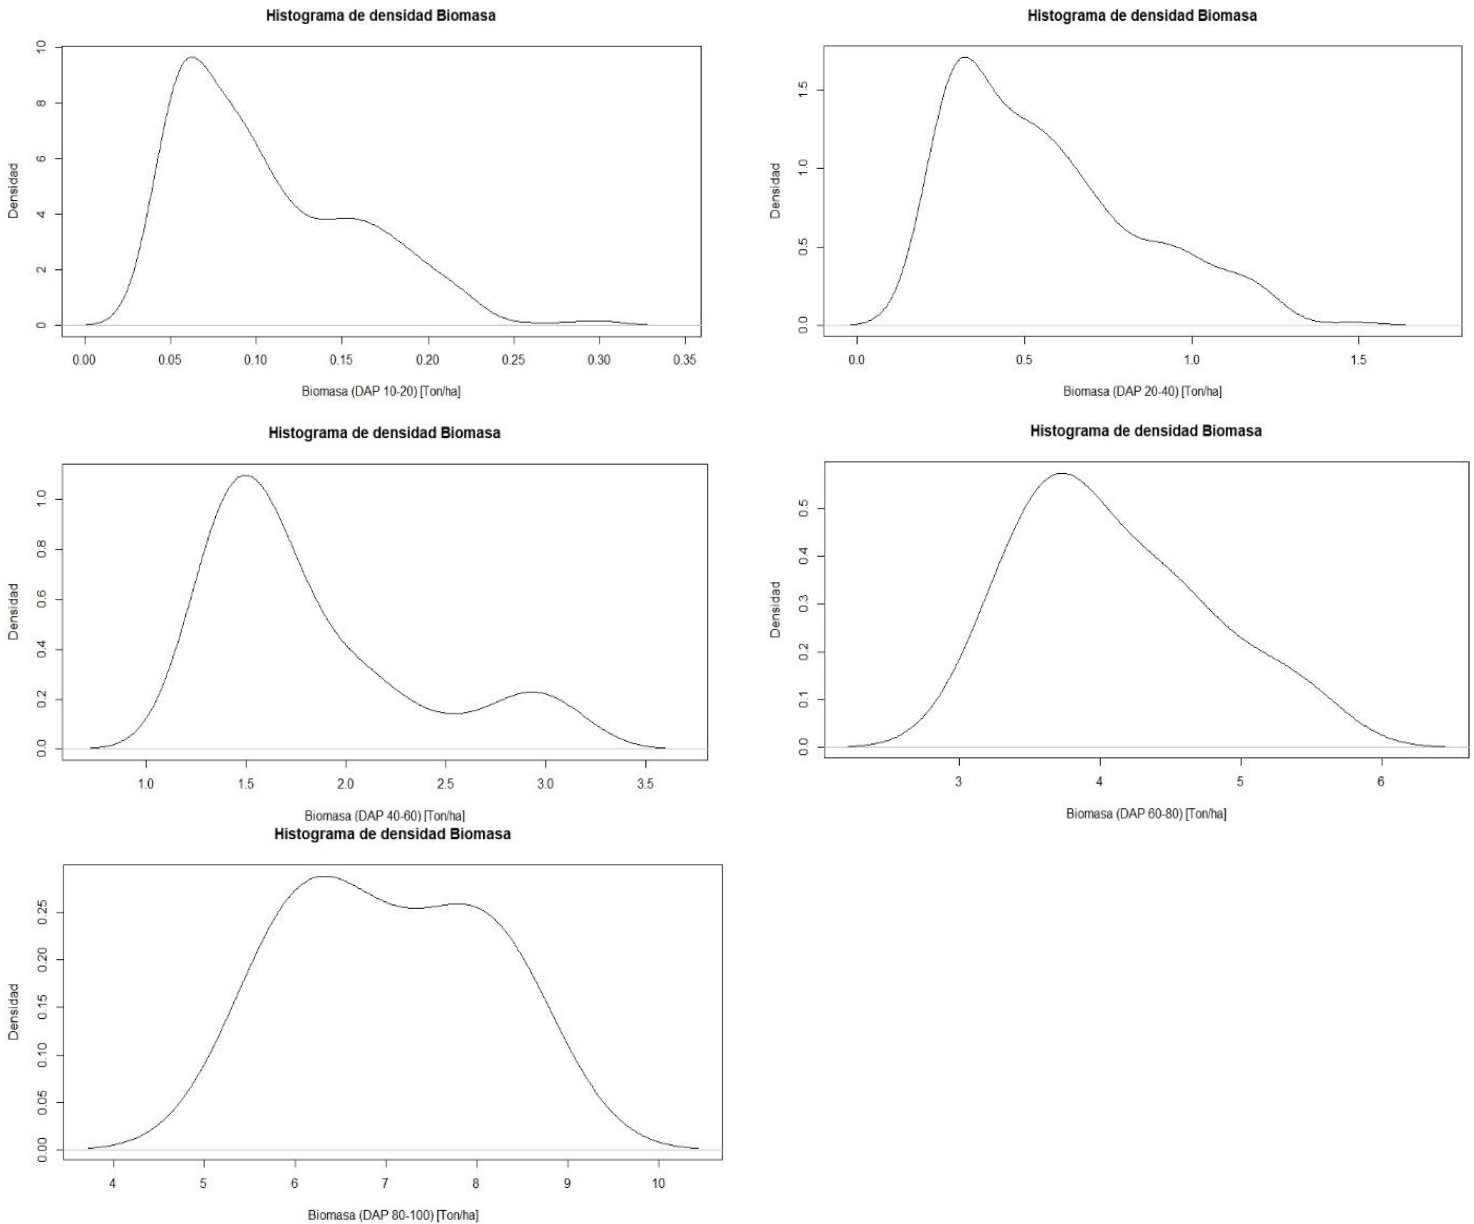


Figura 8 Histogramas de densidad de DAP – Biomasa aérea
Fuente: Propia

A partir del análisis de la curtosis, se pudo inferir que los rangos menores de DAP y el comportamiento de la biomasa, es de carácter leptocúrtica, dado que existe una gran concentración de los valores entorno a la media para dicho rango.

A medida que se incrementa en rango de DAP, se puede establecer una tendencia de los datos identificándose dentro la categoría platicurtica, pues existe una baja concentración de los valores en torno a su media, dicho análisis se corrobora con la desviación estándar pues a medida que se incrementa el DAP, la desviación estándar aumenta notoriamente.

El valor de biomasa total obtenido fue de 364.60 ton ha⁻¹ que es equivalente a 182.3 ton ha⁻¹ de carbono. correspondientes a los 656 individuos estudiados de un DAP>10cm, los cuales representan 62.2% de la población inventariada. El valor de biomasa obtenido es similar en comparación con el encontrado por Aguirre, (2018) quien obtuvo un valor de 343.42 ton ha⁻¹ en el bosque andino de Loja, Ecuador. La diferencia del contenido carbono puede ser debida a el compartimento leñoso (biomasa viva) de las especies endémicas del Ecuador como *Aetheolaena heterophylla* (Asteraceae), *Centropogon erythraeus* (Campanulaceae), *Ageratina dendroides* (Asteraceae) y *Senecio iscoensis* (Asteraceae) que fueron estudiadas.

Es importante resaltar que la especie *Quercus humboldtii*, aporta el 22.5% de biomasa teniendo en cuenta que existen 61 individuos; seguidamente, la especie *Myrcianthes sp. O. Berg* representa el 10.6% de la biomasa total con 67 individuos, por último, la especie *Nectandra reticulata Mez*, representa el 10% de la misma. La especie con más individuos presente en el área inventariada corresponde a *Guarea kunthiana A.Juss* con un total de 86 especies y una biomasa de 33.6 ton ha⁻¹ que corresponden al 9% del valor total.

Ahora bien, el comportamiento de la biomasa en relación a los individuos y según los rangos establecidos muestran los resultados como se pueden apreciar en la figura 9.

Como se puede evidenciar, el rango de 10-20 DAP, posee el mayor número de individuos, aportando el 9.9% de biomasa aérea con un coeficiente de regresión de $R^2=0.9$, seguidamente, el mayor valor de biomasa aérea se obtuvo para el rango que oscila entre 20-40 cm, dado que contiene 244 individuos con promedio de DAP de 27.41 cm y de biomasa aérea de 136.75 ton ha⁻¹, aportando el 37.5% de la biomasa total del área de estudio, a medida que se disminuye el número de individuos, para los rangos de 40-60, 60-80, y 80-100, el valor de biomasa aumenta y el coeficiente de regresión disminuye como se muestra en la siguiente figura.

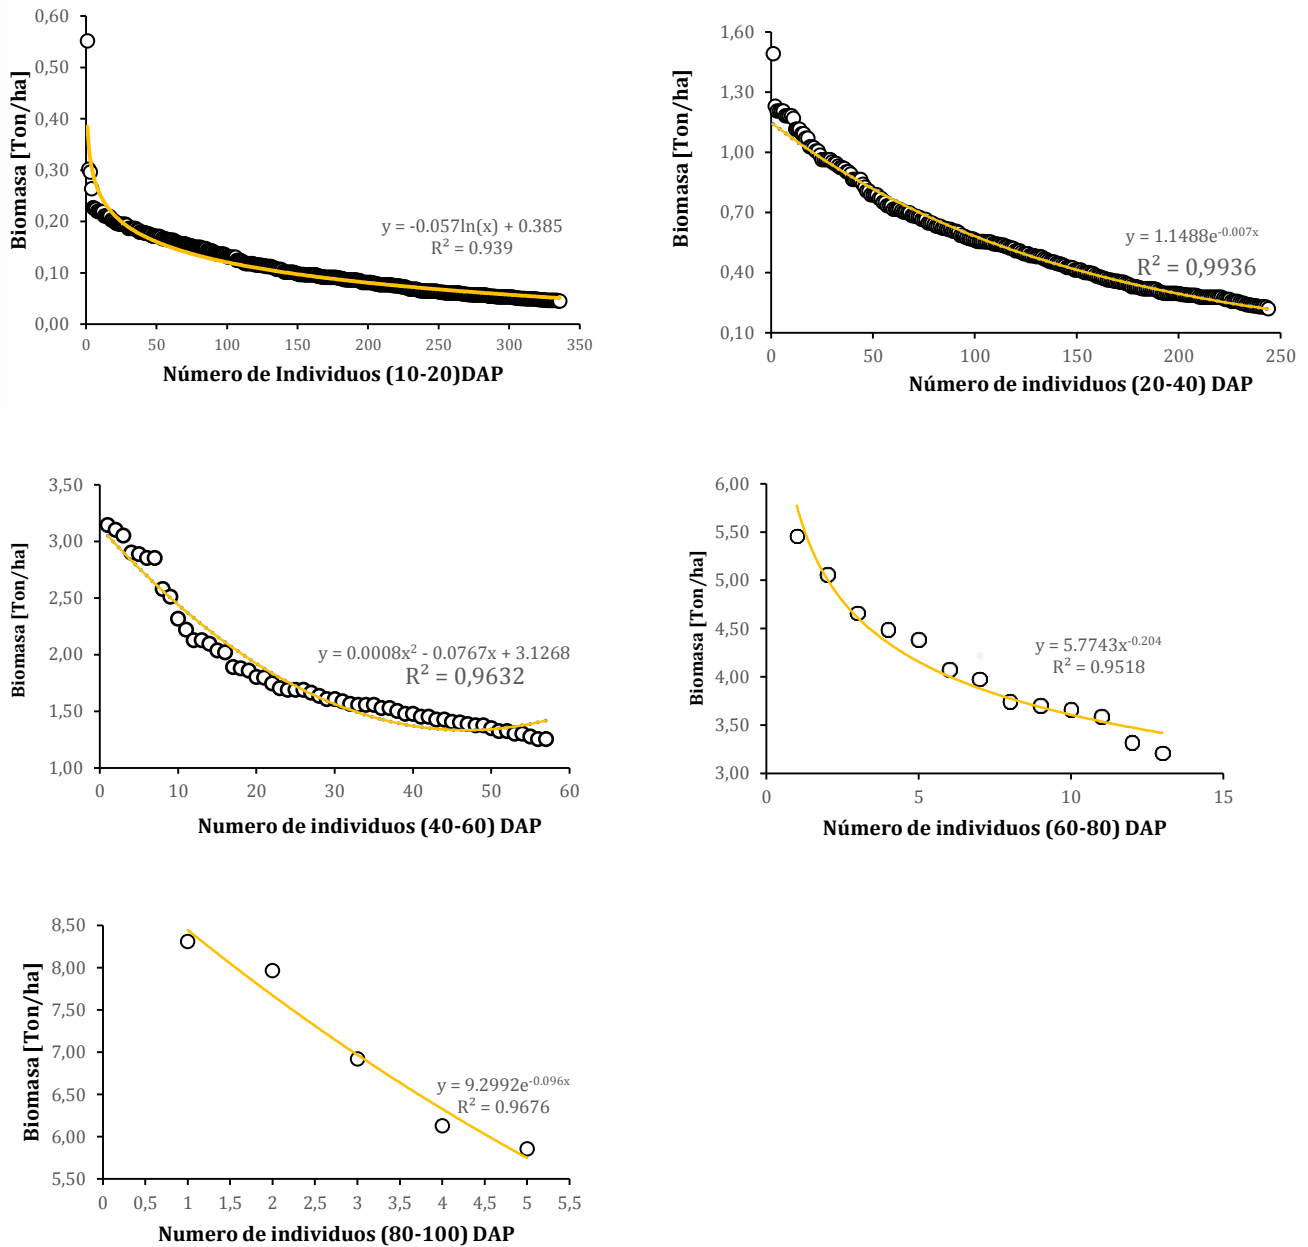


Figura 9. Comportamiento de la biomasa en diferentes rangos de DAP
Fuente: Propia

A partir del comportamiento de la biomasa, el número de individuos y lo expuesto por Torres et al (2017), el ecosistema en estudio tiene una longevidad aproximadamente de 40 años, dado que existe una relación directa entre la edad y la biomasa aérea de los bosques de 12, 30 y 40 años, pues el contenido de carbono almacenado en la biomasa aérea de los bosques aumenta conforme a su crecimiento y desarrollo de los mismos. Al respecto, Torres et al (2017), indica que la tasa de fijación de carbono tiene una relación inversa con la edad, dado que los bosques de menor edad, generan mayor tasa de fijación de Carbono. Es por ello, que este estudio la mayor tasa de fijación se

dio en el rango 20-40 cm que en el rango de 80-100 cm, debido al crecimiento de especies. Sin embargo, Segura et al (2002), indica que la captura de carbono depende principalmente de las condiciones edafológicas y climáticas, además de la capacidad de respuesta que presenten las especies.

Quercus humboldtii, se proyecta como una de las especies que mayor captura de carbono a largo plazo, pues dicha especie lleva a cabo su proceso de almacenamiento de materia de forma moderada teniendo en cuenta su condición de vida, según (Melo, Rodríguez, y Rojas 2011). Lo anteriormente expuesto, se ve reflejado en el comportamiento de la zona de estudio según Palacio y Fernández (2006) indican que El Roble común (*Quercus humboldtii*) es una especie característica de los Andes Colombianos, que crece desarrollando asociaciones con numerosas especies de flora y fauna.

El valor obtenido de Carbono almacenado $364.60 \text{ ton ha}^{-1}$ en el presente estudio es similar al encontrado en la investigación desarrollada por Agudelo, (2009) que corresponde a $139.86 \text{ ton ha}^{-1}$, dicho valor lo relaciona al Corredor de Conservación de Robles Guantiva – La Rusia – Iguaque, que abarca los parches más importantes de roble blanco (*Quercus humboldtii*) y roble negro (*Colombobalanus excelsa*) en Colombia; que se encuentra entre una altura mínima de 300 m sobre el nivel del mar y los puntos más altos que corresponden a zonas de páramo a 3900 m de elevación. Dichas condiciones altitudinales se relacionan con la zona de estudio presentando similitudes ambientales y biofísicas de los ecosistemas.

Los valores de biomasa encontrados en la presente investigación son característicos de otro tipo de ecosistemas; según Yepes et al. (2016) los resultados de biomasa total encontrados para los bosques de manglar del Caribe Colombiano es de $129.69 \pm 20.24 \text{ Ton/ha}$, es decir, que almacenan $64.85 \pm 10.12 \text{ Ton/ha}$. Sin embargo, según Gasparri, I. y Manghi, (2004), existen bosques andinos con valores de biomasa aérea variables, como el encontrado en el parque chaqueño Selva Misionera con 229.51 ton/ha , Selva Tucumano Boliviana 184.49 ton/ha y Bosques Andino Patagónicos $483,74 \text{ ton/ha}$ evidenciado las variaciones de los resultados dado que se implementaron diferentes metodologías en cada uno de los estudios

7.2. Correlación entre índices espectrales y biomasa aérea

Para el análisis de los resultados a partir de los índices espectrales, se ilustran las figuras correspondientes a los índices de vegetación NDVI, GNDVIre3n y SAVI, dada la extensión presente documento; sin embargo, las figuras de los índices en su totalidad reposan en el anexo 2.

Para la zona de estudio, el NDVI identificó valores que oscilan entre (0.81 – 0.88) lo cual es concordante con la clasificación de Ya'Acob et al. (2014), siendo este un bosque de montaña denso joven en crecimiento (ver figura 10). Al mismo tiempo, se evidencia otros valores cercanos al 0, representando vegetación baja, y suelo desnudo, correspondiente a la ampliación de la frontera agrícola relacionados con actividades agropecuarias en la subcuenca del río las piedras.

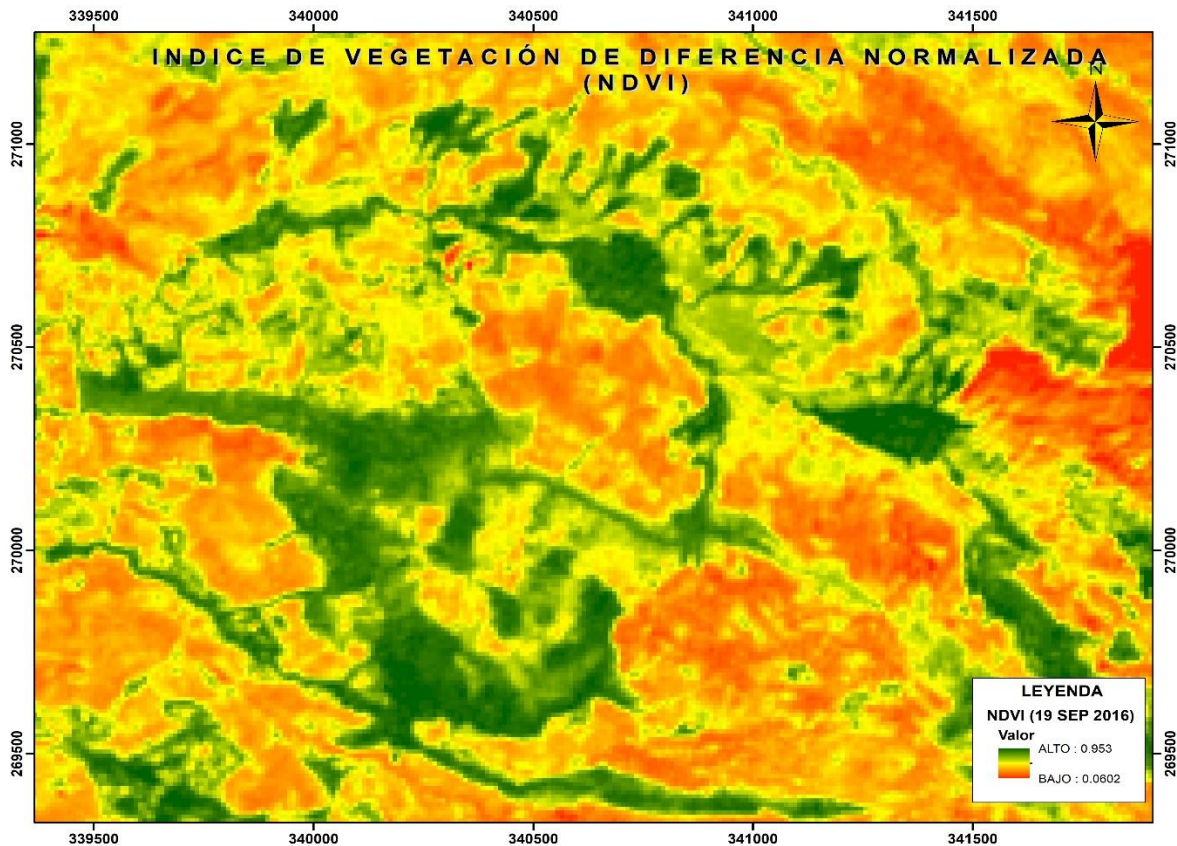


Figura 10. Resultado del Índice NDVI
Fuente: Propia

Es importante resaltar que, bajo los valores del NDVI del bosque andino en estudio, no es posible identificar claramente la diferencia entre el bosque denso, lo cual es consistente con los resultados encontrados por Blanco et al. (2020), Cunliffe et al. (2020) y Galidaki et al. (2017) referente al estado de saturación del índice en vegetación densa.

Sin embargo, en la siguiente figura, se ilustra la relación positiva entre la biomasa aérea medida en campo y el índice espectral, obtenido como mejor modelo, la función polinómica, con un $R^2 = 0.729$.




Figura 11. Correlación entre NDVI y biomasa aérea medida en campo.
Fuente: Propia

Teniendo en cuenta los resultados de la relación entre el NDVI y la biomasa aérea en este estudio (figura 11), y los obtenidos en diferentes estudios (Cunliffe et al. 2020, Bratsch et al. 2017, Räsänen et al. 2019), se ha evidenciado que el NDVI mantiene una relación positiva con la biomasa aérea y que podría ser un buen predictor. Sin embargo, Cunliffe et al. 2020 menciona que la limitación del índice para el estimación radica en que diferentes tejidos vegetales tienen propiedades de reflectancia, y la biomasa aérea está dominada por tejidos no fotosintéticos, como tallos leñosos (Elmendorf et al. 2012), sin embargo, según Bratsch et al. 2017 y Räsänen et al. 2019 , para mejorar la estimación de biomasa aérea requiere una evaluación conjunta con otros factores.

El índice GNDVI implementado como estimador arrojó valores, que oscilan 0.73-0.82 (ver anexo 2) que en relación con la biomasa medida en campo, presenta un coeficiente de correlación de $R^2=0.38$, indicando la limitación del índice por sí solo para estimar biomasa aérea y carbono almacenado. Al mismo tiempo, el GNDVI, clasifica mejor los tipos de cobertura, los valores cercanos al 0, identifican los suelos desnudos y a su vez la vegetación baja o pastizales. Siendo estos mejor diferenciados por el GNDVI. De igual forma, otra ventaja evidente de este Índice, es reflejar una diferencia más determinante, de la vegetación densa, de la arbustiva, siendo estos valores cercanos al 1. Dicha ventaja es sobresaliente en comparación con el NDVI, ya que no existe una saturación tan profunda. Sin embargo, la correlación entre GNDVI y biomasa aérea medida en campo (ver anexo 2), evidencia que los cambios en biomasa no corresponden directamente a un cambio en la misma magnitud del índice de vegetación.

Según Théau et al. (2021), el GNDVI puede obtener una alta precisión en pastizales. En este sentido, el GNDVI obtuvo una baja precisión en la estimación de la biomasa dado que la saturación juega un rol preponderante, el cual limita su aplicación en altos valores de biomasa, especialmente en biomasa con humedades altas. En concordancia con el presente estudio, el coeficiente obtenido permite establecer el nivel bajo de relación entre la biomasa y el índice, dado que, en esta zona, se caracteriza por ser un

bosque andino con precipitaciones y humedades altas. Sin embargo, otros autores Coltri et al. (2013) afirman que el índice GNDVI ha sido desarrollado para estimar la biomasa del dosel verde, encontrando una mejor correlación entre la concentración de clorofila y la banda verde, argumentando que el "NDVI verde" (GNDVI) es más sensible a la concentración de clorofila en comparación con el NDVI, haciéndolo más útil para estimar la biomasa de cultivos verdes.

En este sentido, los resultados de Coltri et al. (2013) indican que el GNDVI y el NDVI tiene una fuerte correlación en el cálculo de la biomasa en cultivos de café, sin embargo, el GNDVI presenta una mejor correlación con la biomasa seca en comparación con otros índices.

Otros de los índices considerados dentro de la investigación, fue el EVI, sin embargo, la zona de estudio se caracteriza por presentar un bosque de alta montaña, con fuertes pendientes factor que limita parcialmente la utilidad del índice como estimador; los valores del EVI (ver anexo 2) y el coeficiente de correlación respecto a la biomasa ($R^2=0.376$), infiriendo según los resultados éste índice está influenciado por el efecto topográfico.

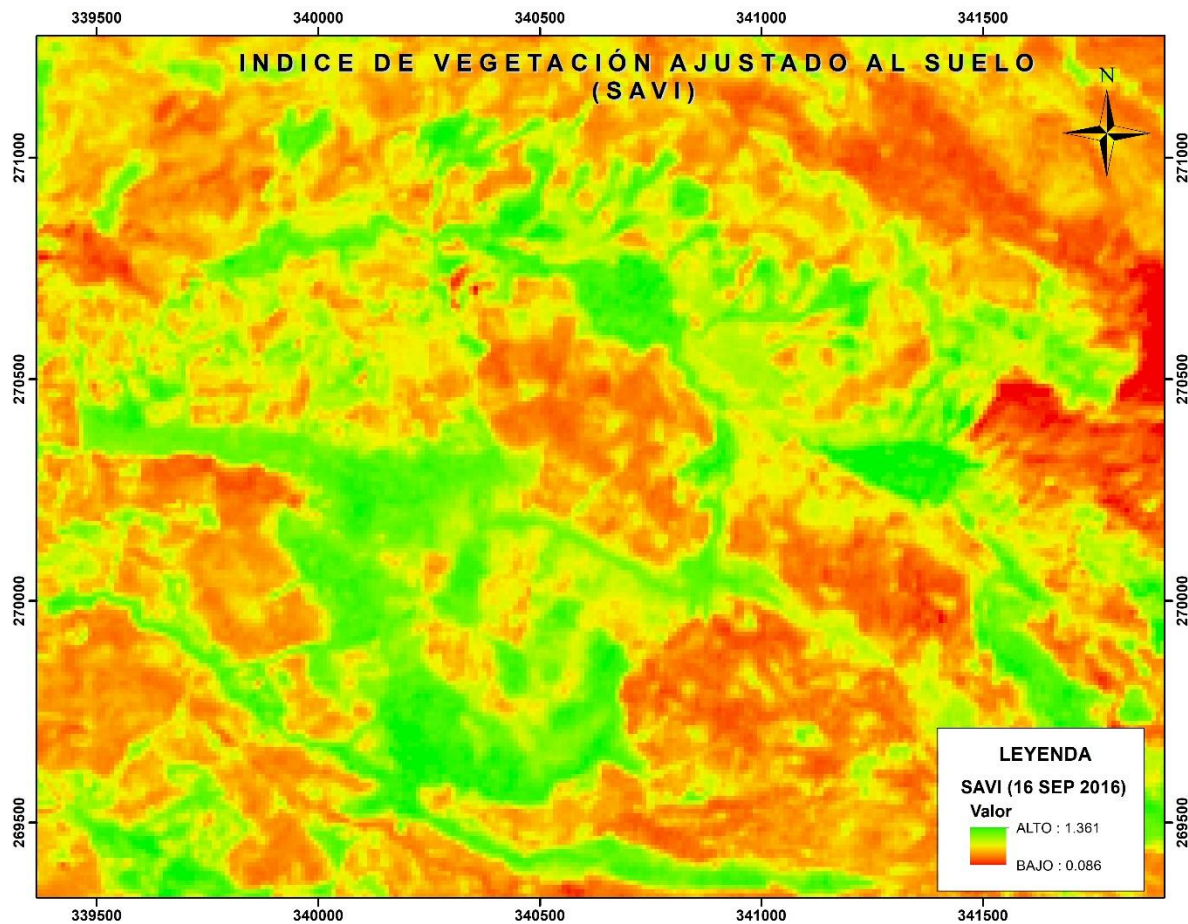
A partir del resultado del EVI (ver anexo 2), se puede evidenciar la habilidad del EVI, para identificar la diferencia entre vegetación densa y el resto de coberturas presentes, pues los valores más altos identifican el bosque andino (vegetación densa). Seguidamente, en la figura se visualiza los valores cercanos a 0, como vegetación baja o pastizales, siendo este un poco preciso. (Pinty et al. 2011).

El coeficiente de correlación obtenido en el presente estudio, permitió establecer que EVI, posee una limitación como estimador de biomasa, en comparación con lo encontrado por Munyati (2022), el EVI, presenta una habilidad como estimador al igual que otros índices como el NDVI y SAVI. No obstante, en esta investigación, se detalló que el EVI presenta influencia directa por inclinación del terreno, según menciona Pinty et al. (2011) podría eliminarse o debilitarse cuando los índices de vegetación se expresan como relaciones de banda, como en el NDVI, RVI, etc. A diferencia del NDVI, el EVI incluye un término constante, el factor de ajuste del suelo L, lo cual hace que no se pueda despreciar el efecto de la topografía, que contribuye al ruido en el resultado del EVI, sin embargo, esta condición depende de la resolución espacial de la imagen, dado que, si el tamaño de píxeles aumenta, el efecto de la topografía podría disminuir o anularse.

Según lo mencionado por Prabhakara et al. (2015), la relación entre la biomasa aérea y el comportamiento de índices como EVI, NDVI, SR, VARI y GNDVI, permitieron identificar una relación mayor de la biomasa con los índices NDVI y GNDVI, cuando existe una vegetación arbustiva o secundaria y una topografía plana, debido a que algunos índices no pueden diferenciar la cantidad de biomasa cuando existe mucha

vegetación, pues en este caso, la relación directa de la biomasa-índices se vuelve más difusa.

Los resultados de SAVI, (ver figura 12), que evidencia la principal habilidad que tiene el índice para identificar la vegetación baja o pastizales que están presente dentro del área de estudio, no obstante, logra también identificar la vegetación densa, que corresponden a los valores altos de SAVI, sin embargo, dicha identificación se caracteriza por presentar una saturación en las zonas de vegetación densa, del mismo



modo que el NDVI.

Figura 12. Resultados del índice SAVI. Fuente: Propia

En el presente estudio, es importante resaltar el SAVI al igual que NDVI, EVI y WDRVI, obtuvo un coeficiente de correlación alto ($R^2=0.729$) (ver figura 13).

Lo anterior, soporta los resultados encontrados por (Munyati 2022), dado que los índices ajustados al suelo como el SAVI, actúan mejor que el NDVI en los pastizales y vegetación subarborescente. En este sentido, SAVI entrega mayor detalle en la cobertura vegetal de baja y mediana densidad, como los matorrales. Según el estudio de Ceceña et al. (2021) el índice SAVI resultó ser una herramienta que proporciona datos

concretos para evaluar los cambios en la respuesta fotosintéticamente activa de la cobertura vegetal, particularmente la subarborescente.

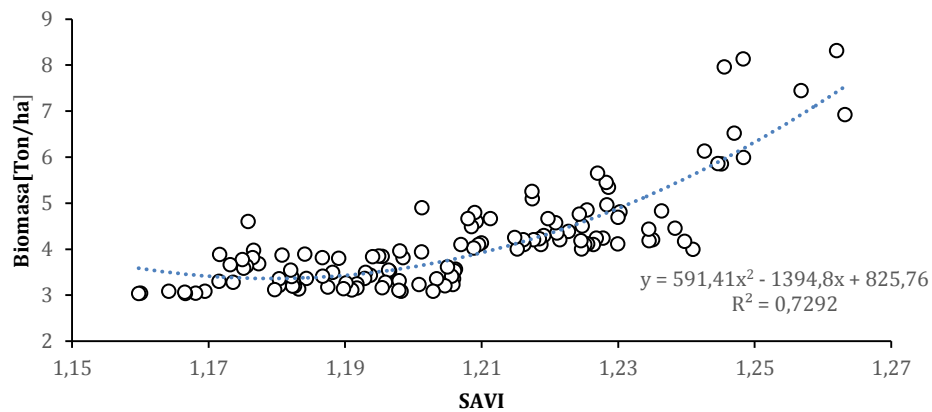


Figura 13. Correlación entre SAVI y biomasa aérea medida en campo.

Fuente: Propia

El SAVI, presentó una alta correlación con la biomasa aérea del bosque andino, debido a la densa vegetación y dado que este índice tiene grandes rangos dinámicos y una poca susceptibilidad a las perturbaciones atmosféricas.

Otro índice con potencial en la detección de biomasa es el WDRVI; (ver anexo 2), resalta la clasificación que realizó el índice sobre la zona de estudio, indicando las diferentes densidades de vegetación existente dentro de área de alta vegetación, con valores cercanos al 1. De igual forma, resalta la vegetación baja y subarborescente, directamente relacionada por las actividades antrópicas.

A partir de la correlación entre WDRVI y biomasa aérea medida en campo (ver anexo2), se evidencia la relación directa que existe entre el valor de biomasa y el índice WDRVI (ver figura), con un coeficiente de correlación de ($R^2=0.7382$).

El WDRVI permite la clasificación de diferentes densidades de alta de vegetación, como las existentes en un bosque andino natural, en contraste con el NDVI, que presenta saturación en este tipo de vegetación. Según Cao et al. (2020) el WDRVI describe correctamente las características fisiológicas de la alta biomasa, debido al rango dinámico de las bandas de NDVI. En este sentido, Yue, Yang, y Feng (2016) y Hank, Bach, y Mauser (2015) Cao et al. (2020) afirman que el WDRVI, se ha utilizado para monitorear indicadores de crecimiento de la biomasa para cultivos de trigo, soja, maíz, y algodón; estableciendo que las relaciones lineales entre el WDRVI y los indicadores de crecimiento fueron evidentes.

En aras de potencializar la detección de las diferentes densidades de la clorofila dentro de las coberturas del área de estudio, y partiendo de los resultados reportados por

Blanco, (2020), GNDVI se ajusta a las bandas de borde rojas propias del sensor sentinel 2A, las cuales según Castillo et al. (2017) presentan una mayor sensibilidad en la detección del contenido de clorofila para la detección del estado fitosanitario de las plantas, por lo tanto los índices de vegetación que incluyan bandas de borde rojo permiten obtener mejores resultados en comparación con los índices que carecen de esta.

Teniendo en cuenta lo anterior, se presenta el GNDVI en combinación con la banda 1 de borde rojo (GNDVIre1n), (ver anexo 2), evidenciando que existe una limitación para identificar por sí solo, las variedades de coberturas vegetales; no obstante, se alcanza a apreciar las coberturas que presentan vegetaciones densas como los parches de bosques, con valores cercanos a 0.90, en contraste, los valores cercanos a 0 pertenecen exclusivamente a los valores de nubosidad detectados por dicho índice.

La figura de la correlación entre GNDVIre1n y biomasa aérea medida en campo (ver anexo 2) muestra claramente la limitación del índice de GNDVIre1n como estimador de biomasa aérea por sí solo, lo que se traduce en una dificultad para encontrar una relación entre la biomasa aérea y los valores de índice de vegetación. Esto debido a que tiende a confundir la nubosidad y las sombras como vegetación.

Otro índice derivado del GNDVI y la banda 2 de borde rojo, es el GNDVIre2n, (ver anexo 2), presenta los resultados del índice, mostrando que posee habilidades para identificar diferentes coberturas de vegetación, específicamente la vegetación densa como los parches de bosques, con valores cercanos a 0.90, en contraste, los valores cercanos a 0 pertenecen exclusivamente a los valores de nubosidad detectados por dicho índice. Con todo lo anterior, el índice muestra una mejora en los resultados gráficos comparados con el GNDVIre1n (ver anexo 2).

La figura de la GNDVIre2n y biomasa aérea (ver anexo2), evidencia claramente la limitación del índice de GNDVIre2n como estimador de biomasa aérea por sí solo, obteniendo un coeficiente de correlación de 0.1, lo que se traduce en una dificultad para encontrar una relación entre la biomasa aérea y los valores del índice de vegetación.

El GNDVIre3n, incluye la banda 3 de borde rojo, ver figura 14, refleja los resultados del índice, que se muestran levemente mejorados en comparación con el GNDVIre1n y GNDVIre2n, dado que identifica la vegetación densa como los parches de bosques, con valores cercanos a 0.90, en contraste, los valores cercanos a 0 pertenecen exclusivamente a los valores de nubosidad detectados por dicho índice.

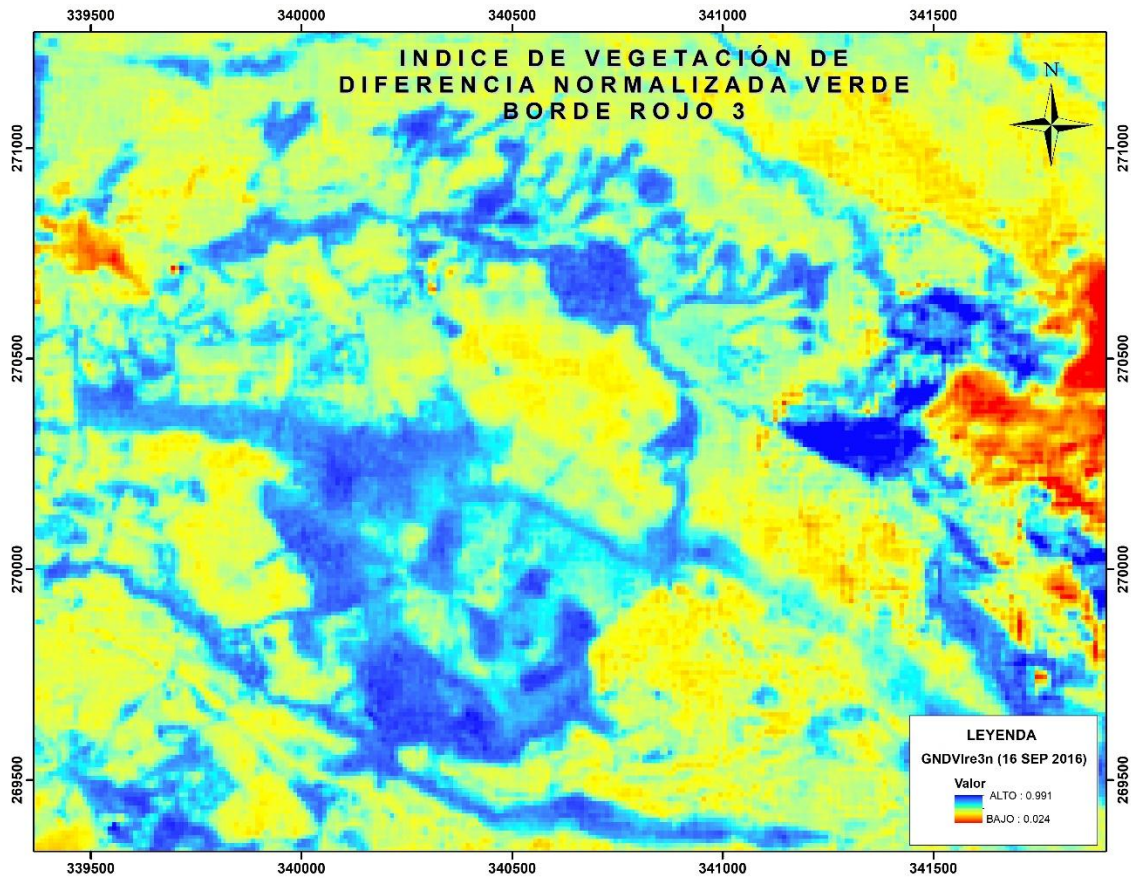


Figura 14. Resultados de GNDVire3n. Fuente: Propia

A partir de lo anterior, es importante resaltar que, en comparación con los tres índices diseñados por (Navarro 2017) utilizando las bandas de borde rojo, el índice GNDVire3n, reflejó una mejora gráficamente (ver figura 15), en comparación con los otros dos índices de borde 1 y 2, esto según lo determinado por el coeficiente de correlación superior a 0.6.

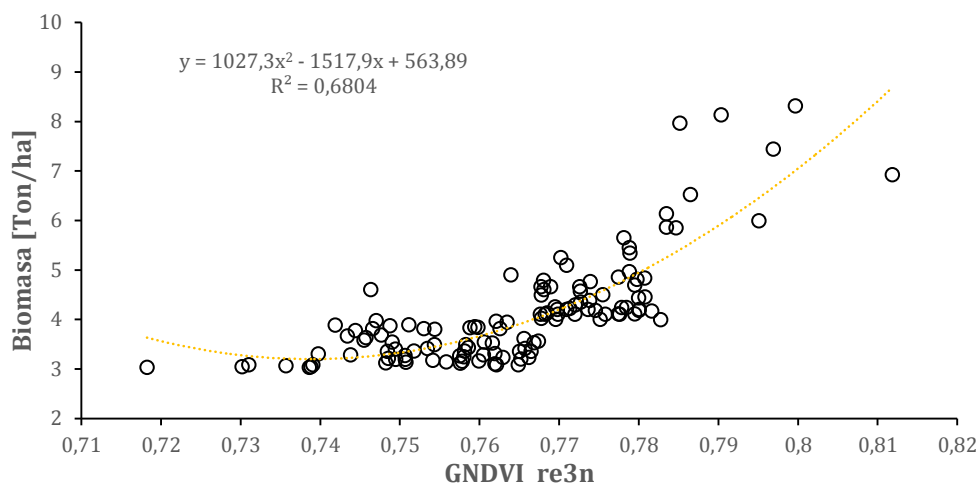


Figura 15. Correlación entre GNDVire3n y biomasa aérea medida en campo. Fuente: Propia

Los índices espectrales inicialmente seleccionados para el desarrollo de este estudio, fueron determinados a partir de las investigaciones previas, relacionadas como variables predictoras de la biomasa aérea, sin embargo, dicha selección se sometió a un análisis teniendo en cuenta el comportamiento de la variable espectral y la biomasa aérea medida en campo.

De acuerdo con a la figura 16, el NDVI es consistente en cuanto a los incrementos o decremento de biomasa en diferentes pixeles, estos cambios son considerados leves, en comparación con los cambios significativos de biomasa aérea medida en campo, esto es debido a que el NDVI se satura y pierde sensibilidad para identificar cambios de vegetación densa, específicamente en el bosque andino en estudio, según lo afirma (Blanco et al. 2020, Cunliffe et al. 2020 y Galidaki et al. 2017).




Figura 16. Relación entre valores de NDVI y biomasa aérea.

Fuente: Propia

Según Wang et al. (2016), la posible explicación es que la reflectancia tanto en el visible como en el infrarrojo cercano es sensible biomasa aérea por debajo del umbral de saturación, debido a que el pigmento de clorofila absorbió la mayor parte de la luz roja visible, mientras que la estructura celular de los individuos del bosque andino reflejaron la mayor parte de la luz del infrarrojo cercano, lo cual significa que existe una alta actividad fotosintética y un comportamiento del índice poco variable.

En este sentido y en comparación con otros índices, el NDVI está limitado en su capacidad para estimar biomasa en una vegetación densa. Por lo tanto, se estudia el comportamiento el índice EVI.

El comportamiento del EVI evidenciado (ver anexo2), establece relación con la biomasa aérea, dado que las magnitudes de los cambios tanto del EVI como en la biomasa son semejantes. El EVI es más sensible a las variaciones estructurales del dosel, incluido el índice de área foliar (LAI), el tipo de dosel, la fisonomía de la planta y la arquitectura del dosel. Todo lo anterior, se logra, por la habilidad del índice al separar la señal proveniente de la vegetación y de la influencia atmosférica.

Continuando con el análisis, el índice SAVI, evidenciado en la figura 17, presenta una relación directa con la biomasa aérea, sin embargo, esta relación no describe los cambios con la misma magnitud, resultado que afirma Araujo, et al. (2000), dado que no existe un comportamiento lineal entre estas dos variables de estudio.

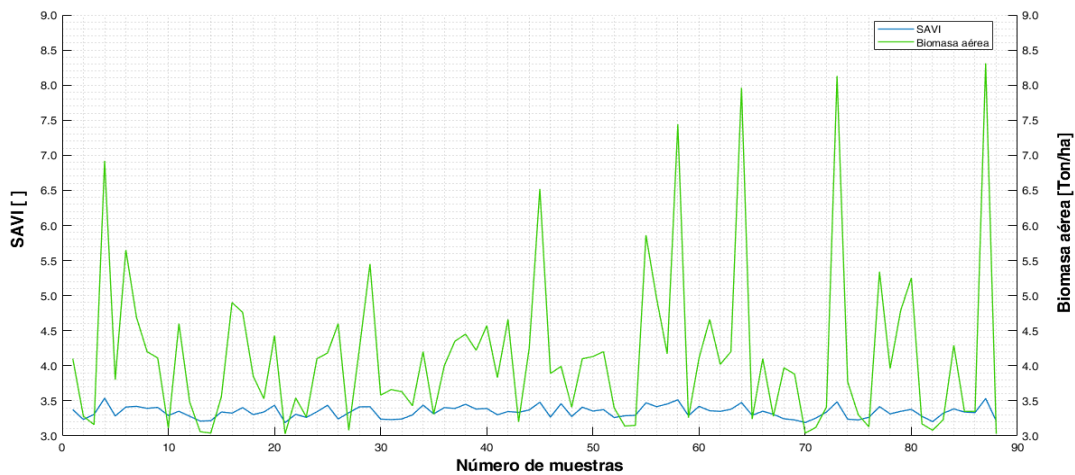


Figura 17. Relación entre valores de SAVI y biomasa aérea. Fuente: Propia

En este sentido, SAVI entrega mayor detalle en la cobertura vegetal de baja y mediana densidad, como los matorrales. Según (Ceceña-Sánchez et al. 2021) el índice SAVI presentó datos concretos para evaluar los cambios en la respuesta fotosintéticamente activa de la cobertura, particularmente la subarborescente.

Dentro de los índices detallados, podemos inferir que el índice WDRVI no corresponde a un comportamiento totalmente lineal con respecto a la biomasa aérea, sin embargo, se puede identificar claramente que existe una correspondencia a los cambios de biomasa entre píxeles, como se evidencia en el anexo 2.

No obstante, estos cambios no son significativos en comparación con la biomasa, pues dicho índice mejora la linealidad y reduce la saturación causada por la vegetación mediana y altamente densa, lo que facilita un control preciso del crecimiento y lo hace al menos tres veces más preciso que el NDVI. En este sentido, el potencial de este índice, se ve evidenciado por el estudio realizado por (Cao et al. 2020) donde afirma que el WDRVI presenta la habilidad para determinar las diferencias sutiles en el dosel del cultivo en condiciones moderadas y alta densidad de vegetación, como lo es en el bosque andino.

Por otro lado, el GNDVI muestra una relación directa con la biomasa aérea en campo, sin embargo, dicha relación no es fuerte, dado que la habilidad para este índice radica en la identificación de pastizales, lo cual evidencia la limitación para estimar la biomasa por sí sola, como se ilustra en el anexo 2. que de igual forma está en concordancia con el coeficiente de correlación obtenido dado que muestra un nivel bajo de relación entre la biomasa aérea en bosque denso y el índice.

En relación con el GNDVI y ajustado con las bandas de borde rojo, se determinan estos tres índices; GNDVI Borde rojo 1, GNDVI Borde rojo 2 y GNDVI Borde rojo 3. Al igual que el NDVI, presenta un comportamiento de saturación, dado que los cambios que se presentan entre valores de los índices de borde rojos son leves en comparación con los valores de biomasa aérea, a diferencia del índice GNDVI, el cual presenta una mejora gráficamente en su clasificación de vegetación densa, dado que el efecto de saturación no es profundo. A continuación, se presenta el resultado del GNDVI Borde rojo 3.




Figura 18. Relación entre valores de GNDVIre3n y biomasa aérea.

Fuente: propia

Por otro lado, autores como (Marini y Santamaría 2019), indican que los índices que incluyen bandas de borde rojo, permite disminuir el inconveniente la sustitución evidenciando modificaciones significativas, ya que la reflectancia en la región espectral del mencionado borde es más sensible al contenido de clorofila ideal. Sin embargo, en comparación con los resultados anteriores, y en contraste con los resultados encontrados por (Blanco et al. 2020) tan solo, el GNDVI y el GNDVI Borde rojo 3, presentan una diferencia perceptible gráficamente, determinando que el GNDVI borde rojo 1 y GNDVI borde rojo 2, reflejan problemas de saturación.

7.4. Regresión múltiple lineal

A partir de los índices espectrales, se procedió a implementar un modelo de regresión múltiple que evaluó diferentes escenarios, a partir de sus variables predictoras (índices de vegetación). A continuación, se presenta la tabla con los coeficientes de correlación obtenidos con sus respectivos índices de vegetación empleados.

Tabla 3. Coeficientes de correlación para la regresión múltiple lineal

N. Índices	Índices espectrales	Coefficiente Correlación
8	NDVI, GNDVI, GNDVI1N, GNDVI2N, GNDVI3N, SAVI, EVI, WDRVI	0.7296
6	NDVI, GNDVI, GNDVI1N, SAVI, EVI, WDRVI	0.7251
5	GNDVI, GNDVI1N, SAVI, EVI, WDRVI	0.7246
4	GNDVI, SAVI, EVI, WDRVI	0.7243
4	GNDVI1N, SAVI, EVI, WDRVI	0.7240
4	GNDVI1N, GNDVI, EVI, WDRVI	0.6851
4	NDVI, SAVI, EVI, WDRVI	0.7254
3	NDVI, SAVI, EVI	0.7132
3	WDRVI SAVI EVI	0.7217
3	GNDVI1N, EVI, WDRVI	0.6728
3	NDVI, EVI, WDRVI	0.7217

Fuente: propia

La evaluación de la influencia que tiene los predictores utilizados en cada prueba sobre la biomasa aérea, permiten inferir que existe una relación directa positiva con diferentes magnitudes, entre los índices de vegetación y la biomasa aérea.

Según los resultados obtenidos, la mayor relación existente está en la implementación de todos los ocho (8) índices espectrales, con un valor de 0.7296, lo cual indica que existe un mayor grado de ajuste lineal por parte del modelo establecido para obtención del valor de la biomasa, en comparación con los otros escenarios. Sin embargo, escenarios como GNDVIre1n, EVI, WDRVI, con $R^2= 0.6728$ permiten evidenciar que dicho escenario diseñado no presenta un modelo ajustado y por lo tanto es el menos fiable. No obstante, es importante resaltar, que en los escenarios planteados se obtuvieron valores mayores a $R^2=0.65$ que fue reportado por (Guerini Filho et al. 2020), para el cálculo de biomasa en pastizales usando información de Sentinel 2A con regresión lineal múltiple.

A continuación, se presenta la figura 19 del modelo de regresión múltiple con el coeficiente de correlación más bajo ($R^2=0.6851$) obtenido, que representa la diferencia entre el valor de la biomasa aérea medida en campo y el valor estimado de biomasa aérea por el modelo de regresión múltiple.




Figura 19. Comparación de resultados de biomasa aérea usando RLM y la biomasa aérea medida en campo. **Fuente: Propia**

Según los resultados arrojados se pudo inferir que la biomasa aérea calculada se subestima en relación con la biomasa aérea medida campo. Razón por la cual los resultados del coeficiente de correlación no describen adecuadamente la relación directa entre estos dos resultados.

Ahora bien, dentro de las combinaciones de las variables estudiadas, se logró determinar el mayor coeficiente de correlación ($R^2=0.7296$), resultado que muestra una moderada relación entre las biomazas estimada y medida en campo, información que se evidencia en la figura 20.




Figura 20. Comparación de resultados de biomasa aérea usando RLM y la biomasa aérea medida en campo. **Fuente: Propia**

A diferencia del modelo de regresión del cual se obtuvo el $R^2=0.6851$, se evidencia una menor subestimación, aproximándose cada vez más a los datos de biomasa aérea

medidos en campo, siendo este un modelo más confiable para la estimación de la biomasa, no obstante, el coeficiente de correlación no presenta una fuerte relación con los datos.

Todo lo anterior, se sustenta teniendo en cuenta que la regresión múltiple hace cuatro supuestos sobre los errores del modelo; ésta asume que los errores del modelo se distribuyen normalmente; que los errores tienen varianza constante; que la media de los errores es cero; y que los errores son independientes.

Finalmente, los valores obtenidos del coeficiente de correlación en cada escenario están caracterizados por presentar una estrecha diferencia entre ellos, alrededor de 0.70, lo cual infiere que existe una limitación para modelar relaciones complejas entre índices de vegetación.

7.5. Red Neuronal Artificial

Teniendo en cuenta la posibilidad que existe de una mejora significativa en términos de precisión en la implementación de los modelos no paramétricos para el cálculo de biomasa aérea, y los resultados arrojados por el modelo de regresión múltiple lineal desarrollado, se propuso evaluar la efectividad de un método para el modelado predictivo usando aprendizaje automático, en el que se implementó un algoritmo más robusto para predecir resultados continuos.

Para el caso en estudio, la red neuronal estableció una relación no lineal compleja entre los índices espectrales de vegetación y la biomasa aérea para un bosque andino, desarrollando operaciones rápidas y masivas de manera paralela.

En otros estudios (Dorofki et al. 2012 Naqa y Murphy 2015), se ha demostrado que los modelos RNA son superiores a otros métodos tradicionales en términos de precisión de datos, velocidad de procesamiento y resolución de problemas no lineales, por lo tanto, la red neuronal se ha aplicado ampliamente a los índices espectrales basados en estimaciones de biomasa aérea en diferentes regiones naturales. En este sentido, para poder determinar la mejor red neuronal, se realizaron diferentes configuraciones variando primero el número de índices, para identificar cuáles de estos índices espectrales presentaban una relación directa con la biomasa aérea. Para ello, se efectuó la función exponencial para todos los índices de vegetación con el objetivo de identificar con claridad su comportamiento.

A partir del análisis espectral desarrollado, se procede a correr la red neuronal con una configuración inicial para evaluar el comportamiento de todos los índices en conjunto, y de esta forma, determinar la pertinencia de cada uno respecto al valor de biomasa aérea.

La configuración inicial consistió en tres capas ocultas, con 8, 15 y 20 neuronas respectivamente, usando funciones de transferencia como *Hyperbolic tangent sigmoid*, la *Log-sigmoid*, y *lineal*.

Es importante denotar, que se implementó el algoritmo de Levenberg-Marquard, que según autores como (Lourakis,2005), lo catalogan como el más rápido algoritmo para solución de problema de mínimos cuadrados no lineales.

Seguidamente, los resultados obtenidos fueron evaluados a partir del 30% establecidos para validación propiamente. A continuación, se presenta la tabla 4, con los resultados y validaciones de los test realizados con sus respectivas configuraciones y errores generados, usando como medida el error cuadrático medio.

Tabla 4. Resultados las RNAs a partir de los índices de vegetación.

N. Versión	N. Índices	Índices espectrales	Performance (net)	Performance (test)
1	8	NDVI, GNDVI, GNDVI1N, GNDVI2N, GNDVI3N, SAVI, EVI, WDRVI	0.00995	1.5756
2	6	NDVI, GNDVI, GNDVI1N, SAVI, EVI, WDRVI	0.0108	0.8795
3	6	NDVI GNDVI GNDVI3N SAVI WDRVI	0.0326	0.9085
4	5	GNDVI, GNDVI1N, SAVI, NDVI, WDRVI	0.0325	0.889
5	4	GNDVI, SAVI, EVI, WDRVI	0.012	0.8553
6	4	GNDVI1N, SAVI, EVI, WDRVI	0.042	0.7316
7	4	GNDVI1N, GNDVI, EVI, WDRVI	0.033	0.8701
8	4	NDVI, SAVI, EVI, WDRVI	0.147	0.6951
9	3	NDVI, SAVI, EVI	0.0861	0.64069
10	3	WDRVI SAVI EVI	0.125	0.6243
11	3	GNDVI1N, EVI, WDRVI	0.0493	0.6843

Fuente: Propia

Es importante analizar el comportamiento gráfico de cada versión en los datos de entrada, para lo cual se visualizarán la de mayor y menor desempeños para evidenciar sus discrepancias. En este sentido, para la versión 1 (ver anexo 2), la inclusión de todos los 8 índices propuestos genera un desmejoramiento de la RNA como regresor, en comparación con los otros resultados, causando un sobre-entrenamiento, que, a su vez, genera una sobre estimación en los valores de biomasa estimados.

En la versión 2, evidencia (ver anexo 2) una leve subestimación, sin embargo, error cuadrático medio generado en la validación, indica una mejora en su estimación general cuando se eliminan los índices con borde rojo 2 y 3.

En la figura 21 de la versión 3, se obtiene el mejor resultado con un $RMS=0.9085$, descartando índices como el EVI, GNDVI1N y GNDV2N, lo cual permite clarificar que la saturación de dichos índices interfiere de manera directa en la estimación de la biomasa, debido a su limitación espectral sobre el bosque andino en estudio.

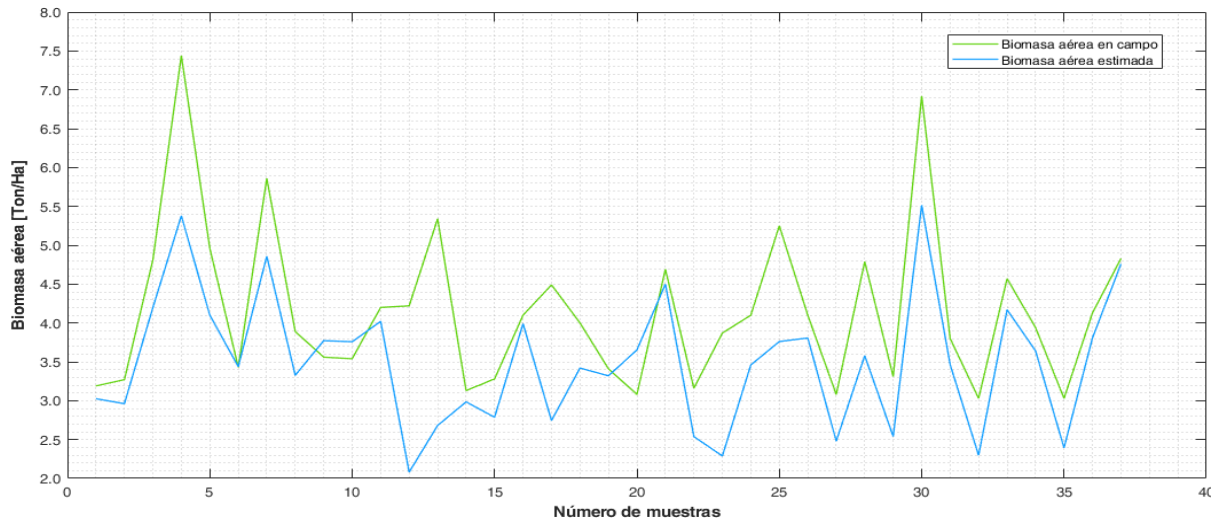


Figura 21. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. **Fuente: Propia**

En la versión 4 (ver anexo 2), se produce una desmejora del modelo ($RMS= 0.889$), descartando el GNDVI1N, pues en comparación con los índices de borde rojo 2 y 3, éste aporta una mejor precisión.

Al igual que en la versión 4, la versión 5 (ver anexo 2), se evidencia una desmejora significativa en la red neuronal descartando el GNDVI, ($RMS=0.8553$), por lo cual se intuye la habilidad que presenta el GNDVI para la mejora de la estimación de la biomasa aérea.

Seguidamente, en la versión 6 (ver anexo 2), se evidencia la habilidad del SAVI, pues en comparación con la versión 3, esta se desmejora ($RMS=0.7316$) por la ausencia de dicho índice, al mismo tiempo, se evalúa que como GNDVI1N, GNDVI, EVI y WDRVI, denotan la habilidad para la estimación de biomasa aérea.

La habilidad del GNDVI se evidencia en la versión 7 (ver anexo 2), dado que éste mejora cuando se incluye dentro del modelo, arrojando ($RMS=0.8701$). Sin embargo, denota una significativa sobreestimación de la biomasa.

Los datos de entrada que fueron conformado por solo tres índices de vegetación (ver anexo 2), presentaron una precisión baja, en comparación, con los datos de entrada de

más de 4 índices de vegetación, por lo cual, se permite afirmar que la biomasa no está correlacionada directamente con una sola variable, sino por el contrario, existe una mejora cuando se complementa con otras habilidades ofrecida otros índices.




Figura 22. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. Fuente: Propia

Teniendo en cuenta lo anterior, se permite establecer que la mejor configuración de índices espectrales consiste en **NDVI**, **GNDVI**, **GNDVI3N** **SAVI**, y **WDRVI**. Por lo cual, se inicia a configurar la red neuronal teniendo estos datos de entrada ya establecidos y justificados estadística y gráficamente.

La configuración de la red neuronal, consiste en ajustar parámetros como número de capas, neuronas y funciones de transferencias, hasta finalmente tener la estructura de la red neuronal más apropiada, según el valor de performance (error cuadrático medio). En la siguiente tabla, se evidencia las métricas que se obtuvieron de cada versión de la red neuronal.

Tabla 5. Resultados de las RNAs configuradas

N. Versión	Capas ocultas	N. Neuronas	Performance (rms)	Performance (Testing)
12	1	15	0.324	0.6418
13	1	25	0.0252	0.8069
14	1	35	0.0152	0.892
15	2	15 25	0.000192	0.862
16	2	15 35	0.0948	0.776
17	3	15 35 45	0.368	2.899
18	3	12 20 30	0.00802	0.885
19	3	12 18 25	1.18E-19	0.902
20	3	12 16 20	0.0303	0.9111
21	3	12 16 18	0.0326	0.9135

Fuente: propia

Las versiones configuradas fueron organizadas desde una sola capa hasta tres capas, respectivamente; sin embargo, se ilustra la que obtuvo un mejor desempeño.

Se inició la primera versión con una capa oculta con 15 neuronas generando un $RMS=0.6418$ (ver anexo 2) causando una sobreestimación de los datos. Seguidamente, se incrementó el número de neuronas a 25 produciendo en una mejora en la red neuronal llegando a $RMS=0.8069$ (ver anexo 2) y a su vez una sobreestimación significativa.

Posteriormente, se incrementó a 35 neuronas obteniendo un declive en la precisión y generando una $RMS=0.892$ (ver anexo 2), al igual que los modelos anteriores, ésta también presenta sobreestimación.

De igual manera, se incrementó a dos capas ocultas, con 15 y 25 neuronas respectivamente, generando una mejora con un $RMS= 0.862$, (ver anexo 2). Siendo evidente una menor sobreestimación en relación a los modelos anteriores.

Al mismo tiempo, se ajustaron el número de neuronas con 15 y 35, aumentando la precisión con un $RMS=0.776$ (ver anexo 2) siendo evidente la sobreestimación de los datos con lo cual permite afirmar que, a mayor número de neuronas, mayor sobreestimación de la red neuronal.

En este sentido, se aumentó otra capa oculta, modificando el número de neuronas por capa, quedando con 15, 35 y 45 neuronas, respectivamente, arrojando un $RMS=2.899$ (ver anexo 2) generando una sobreestimación. El cual refleja una desmejora sustancialmente del modelo, cuando se incrementa las capas y el número de neuronas.

Seguidamente, se ajustó el número de capa quedando finalmente 12 18 y 25, mejorando igualmente la precisión con un $RMS=0.885$. En este sentido, se siguió proyectando las tres capas, pero ajustando con un número más bajo de neuronas, tales como 12,16 y 20 y 12 16 y 18, arrojando un $RMS=0.902$ (ver anexo 2) y $RMS=0.9135$ (ver figura 23), respectivamente. Esta última modificación, evidencia el punto máximo de mejora en la precisión, se obtuvo con tres capas ocultas con 12 18 y 25 neuronas respectivamente.




Figura 23. Comparación de resultados de biomasa aérea usando RNA y la biomasa aérea medida en campo. Fuente: Propia

A partir de los resultados obtenidos de la mejor configuración de la RNA, se presenta su arquitectura, en la siguiente figura.



Figura 24. Configuración de la RNA. Fuente: Propia

Posteriormente, en la figura 25, se ilustra el rendimiento de la validación y la evaluación usando como medida el error medio cuadrático.

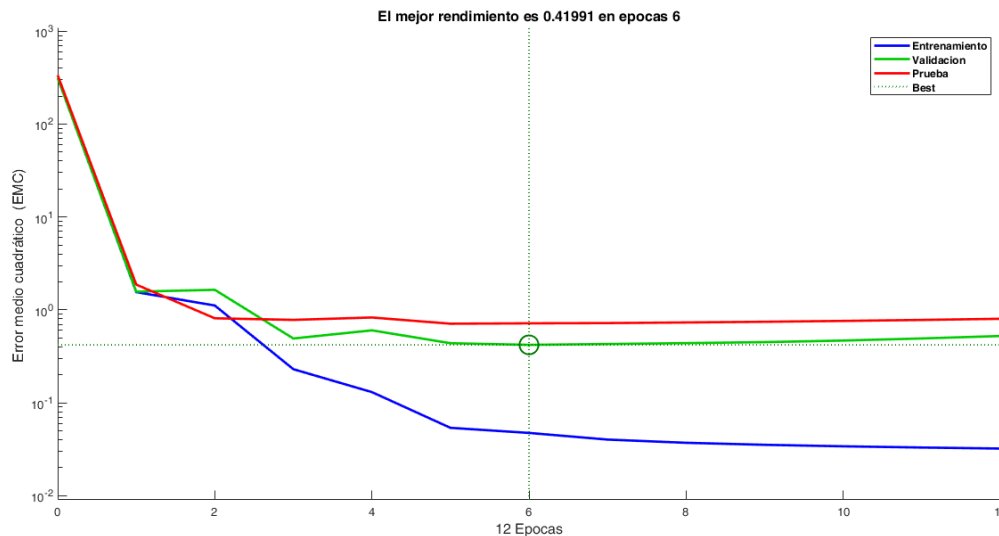


Figura 25. Rendimiento del entrenamiento, validación y prueba. Fuente: Propia

Dicha figura, representa la convergencia de la red neuronal y el logro del error mínimo de cuadrático medio (ECM) para los tres grupos de datos: los datos de entrenamiento (70%), validación (15%) y prueba (15%) de la RNA. Esta figura muestra que el valor

inicial del error cuadrático medio (ECM) es elevado, luego decrece con el número de épocas, como puede verse en esta cifra, hasta la época 6 (punto de mejor rendimiento del modelo), no se produjo un sobreajuste y su ECM es aceptable de aproximadamente 0.4199 para entrenamiento, validación y prueba.

Dicha cifra no indica ningún problema importante con el entrenamiento. Las curvas de validación y prueba son muy similares. Si la curva de prueba había aumentado significativamente antes de que aumentara la curva de validación, entonces es posible que se haya producido algún sobreajuste.

Seguidamente, la figura 26, muestra la relación entre los resultados de la red y los objetivos (target). Si el entrenamiento fuera perfecto, los resultados de la red y los objetivos serían exactamente iguales, pero la relación en este estudio, se presenta de la siguiente manera.

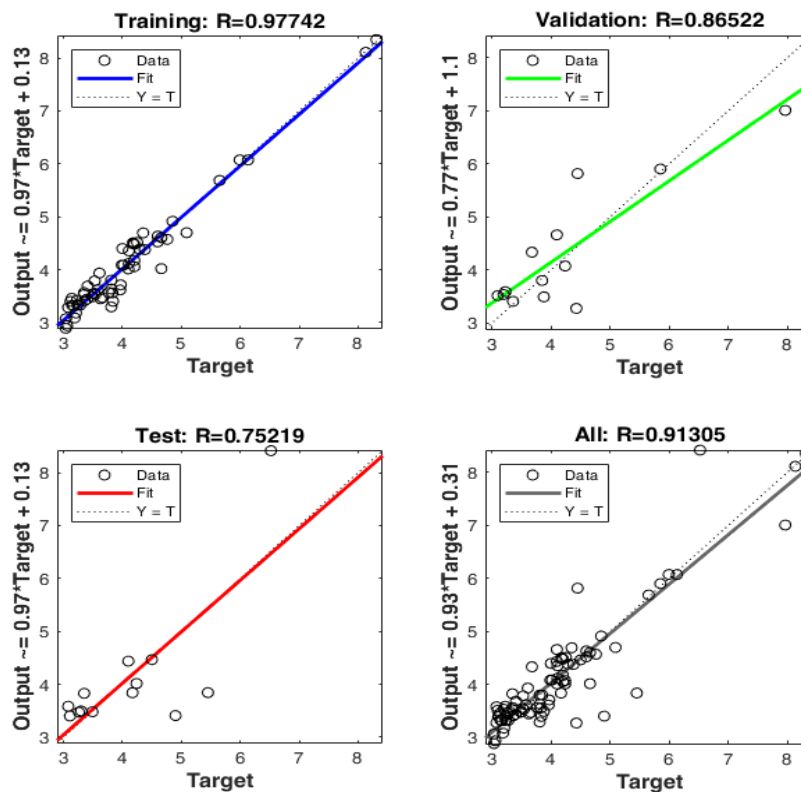


Figura 26. Regresión lineal del entrenamiento, validación y prueba.

Fuente: Propia

La figura anterior, representa los datos de entrenamiento, validación y prueba. La línea discontinua en cada gráfico representa el resultado perfecto: Biomasa aérea estimada es igual a la Biomasa aérea medida en campo.

La línea continua representa la línea de regresión lineal de mejor ajuste entre los resultados y los objetivos. El valor R es una indicación de la relación entre los

resultados y los objetivos. Para el caso en estudio el coeficiente de correlación R, para todos los datos fue de 0.91305, lo cual indica que existe concordancia entre los resultados experimentales y los resultados de RNA.

En contraste y en comparación, con los performances encontrados en el estudio en plantaciones de coníferas y latifoliadas usando datos Landsat-5 y GLAS desarrollados por (López et al. 2016), y en el cual implementaron modelos generados con random forest son relativamente altos, cuyo performances oscila entre 0.73 y 0.96, que comparados con los resultados arrojados se obtuvo un performance de 0.91, determinando que los método no paramétricos reflejan buenas estimaciones para el cálculo de biomasa aérea.

De igual forma, lo reportado por (Pattanayak et al. 2021) en su predicción de biomasa aérea en plantaciones de bamboo, indica que las RNAs obtuvieron una precisión mayor a 0.90, que comparados con los resultados obtenidos en la presente investigación, se asemejan permitiendo inferir que éste modelo no paramétrico se caracteriza por presentar habilidad para predecir valores de biomasa.

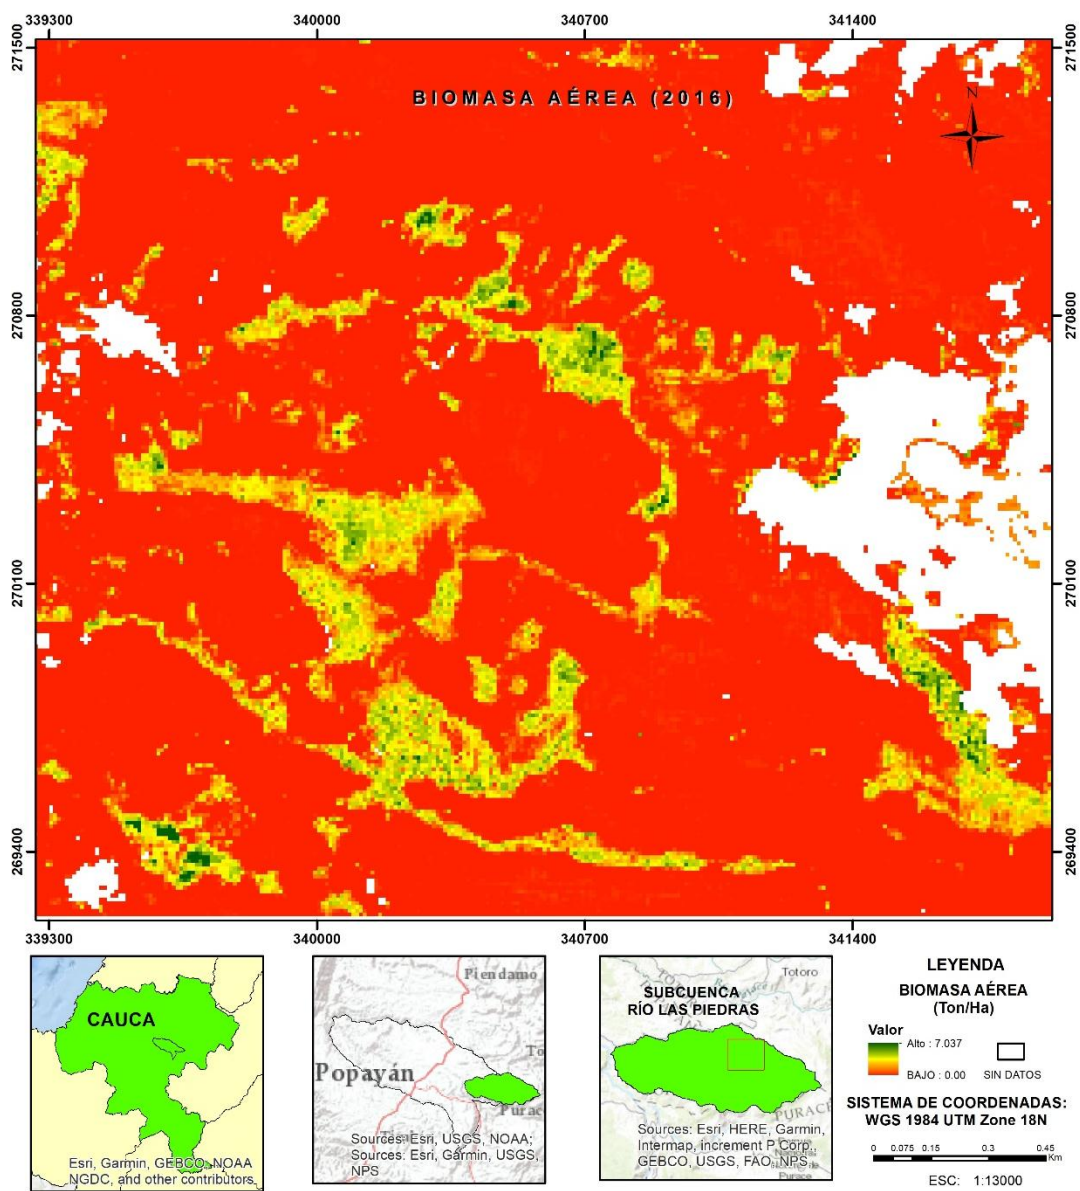
Según L. Wang et al. (2018) reportó los resultados de la comparación entre el modelos de regresión múltiples lineales y RNAs, para la predicción de Biomasa aérea en montañas del éste de China, evidenciando que los modelo con redes neuronales son más precisos y a su vez, afirma que la combinación de datos de sensores remotos e inventarios forestales de campo es una técnica práctica y efectiva para estimar la distribución de biomasa aérea requerida para las evaluaciones regionales de reservas de carbono.

En este sentido, los resultados presentados por (Chandrakant, 2022) para la estimación de biomasa aérea en bosques húmedos usando técnicas de machine learning como Random Forest y RNA, arrojaron que estos métodos son aplicables para el cálculo de biomasa aérea en bosques andinos.

Por lo anterior y una vez realizadas las pruebas y el entrenamiento de la RNA, se estableció que la mejor configuración para la estimación de biomasa consistió en la selección de cinco (5) índices de vegetación, tales como: GNDVI, GNDVIre3n-1, SAVI, NDVI y WDRVI, tres capas ocultas con 12, 18 y 20 neuronas respectivamente y cada capa oculta con una función de transferencia, siendo la primera ***Hyperbolic tangent sigmoid***, la segunda, ***Log-sigmoid***, y la tercera ***linear***.

A partir de la estructuración de la red neuronal anteriormente descrita, se obtuvieron los mapas de biomasa, para el determinación del carbono almacenado, para las temporalidades mencionadas, como se ilustra a continuación.

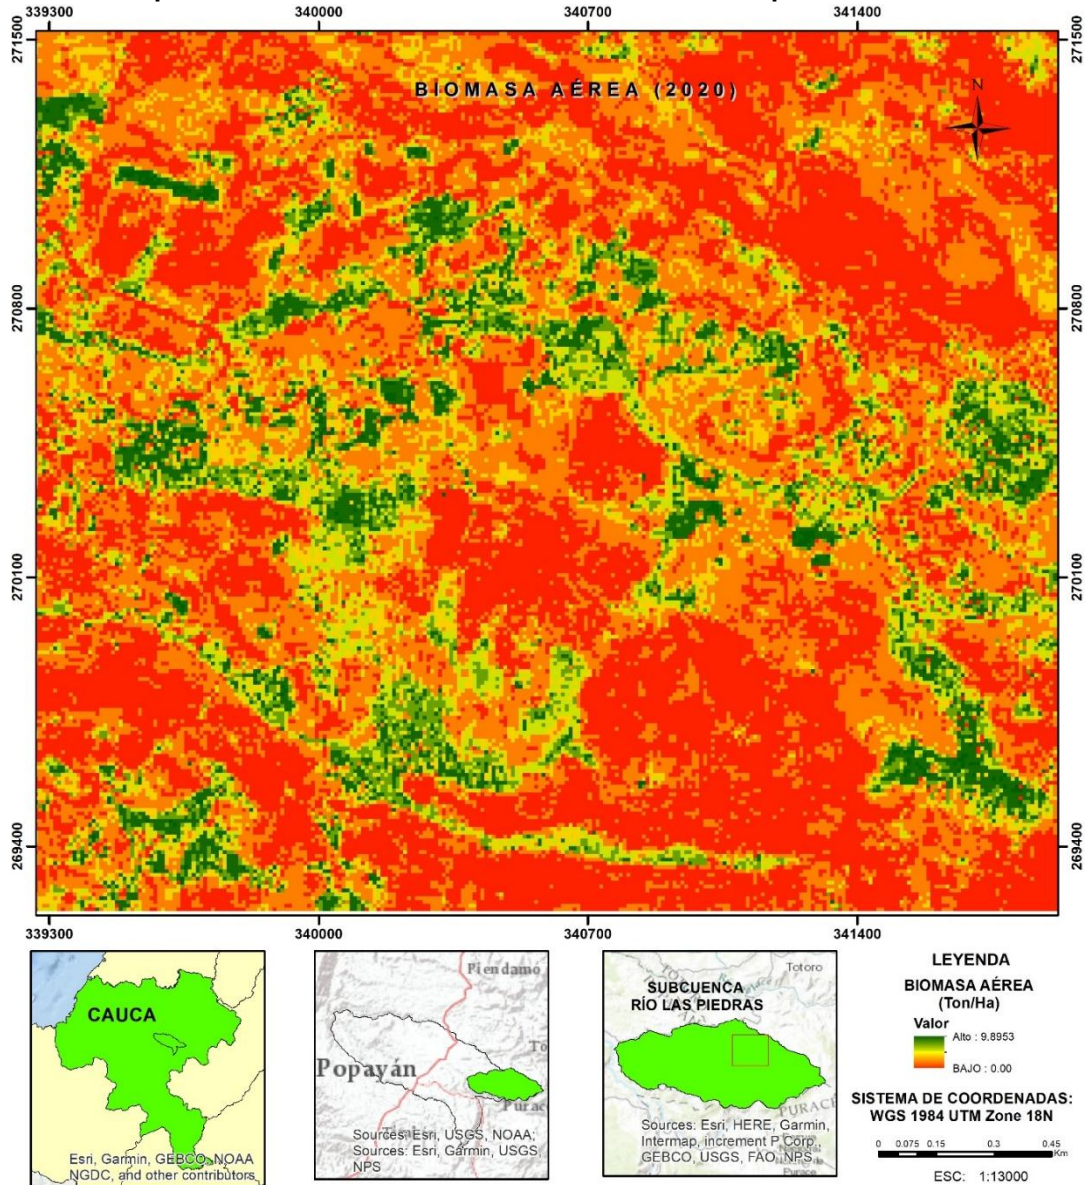
Mapa 1. Resultados de biomasa aérea usando RNA para el año 2016



Fuente: Propia

Los resultados obtenidos a partir de RNA, mostraron una biomasa aérea de 7.037 Ton/ha, en zonas de vegetación densa, diferenciando claramente esta cobertura vegetal de los pastizales y cultivos presentes en la zona causada por la ampliación de la frontera agrícola, información que fue corroborada con la imagen RGB que muestran las diferentes tonalidades naturales de las coberturas, tal y como se puede evidenciar en el siguiente mapa.

Mapa 2. Resultados de biomasa aérea usando RNA para el año 2020



Fuente: propia

Los resultados obtenidos a partir de RNA para el año 2020, mostraron una biomasa aérea de 9.89 Ton/ha, que comparada con los resultados de biomasa aérea obtenidas para el año 2016, evidencia un incremento en el valor y área de biomasa aérea, aumentando en 1.85 ton/ha durante 4 años. Esto obedece al grado de conservación del bosque natural, y su crecimiento biológico dadas las condiciones microclimáticas de la zona. Gráficamente en el mapa se puede apreciar el incremento de parches de bosques y cambios de cobertura en la zona de estudio, escenario reflejado en la imagen RGB (figura 27), que se muestra a continuación.


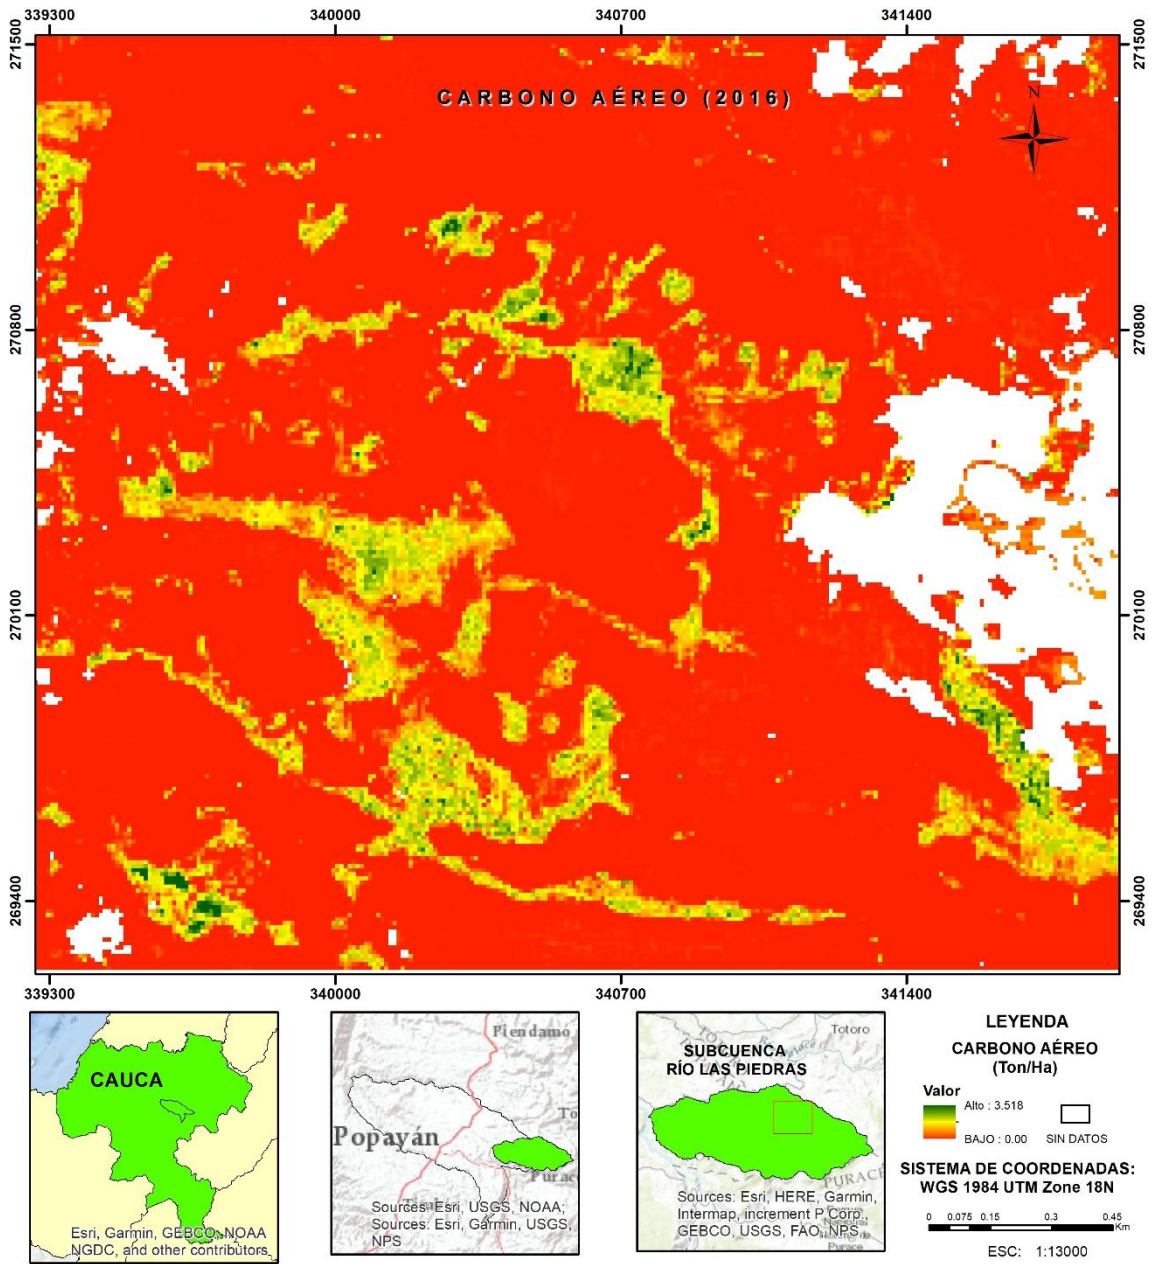


Figura 27. Comparación entre imágenes RGB para el año 2016 2020.
Fuente: Propia

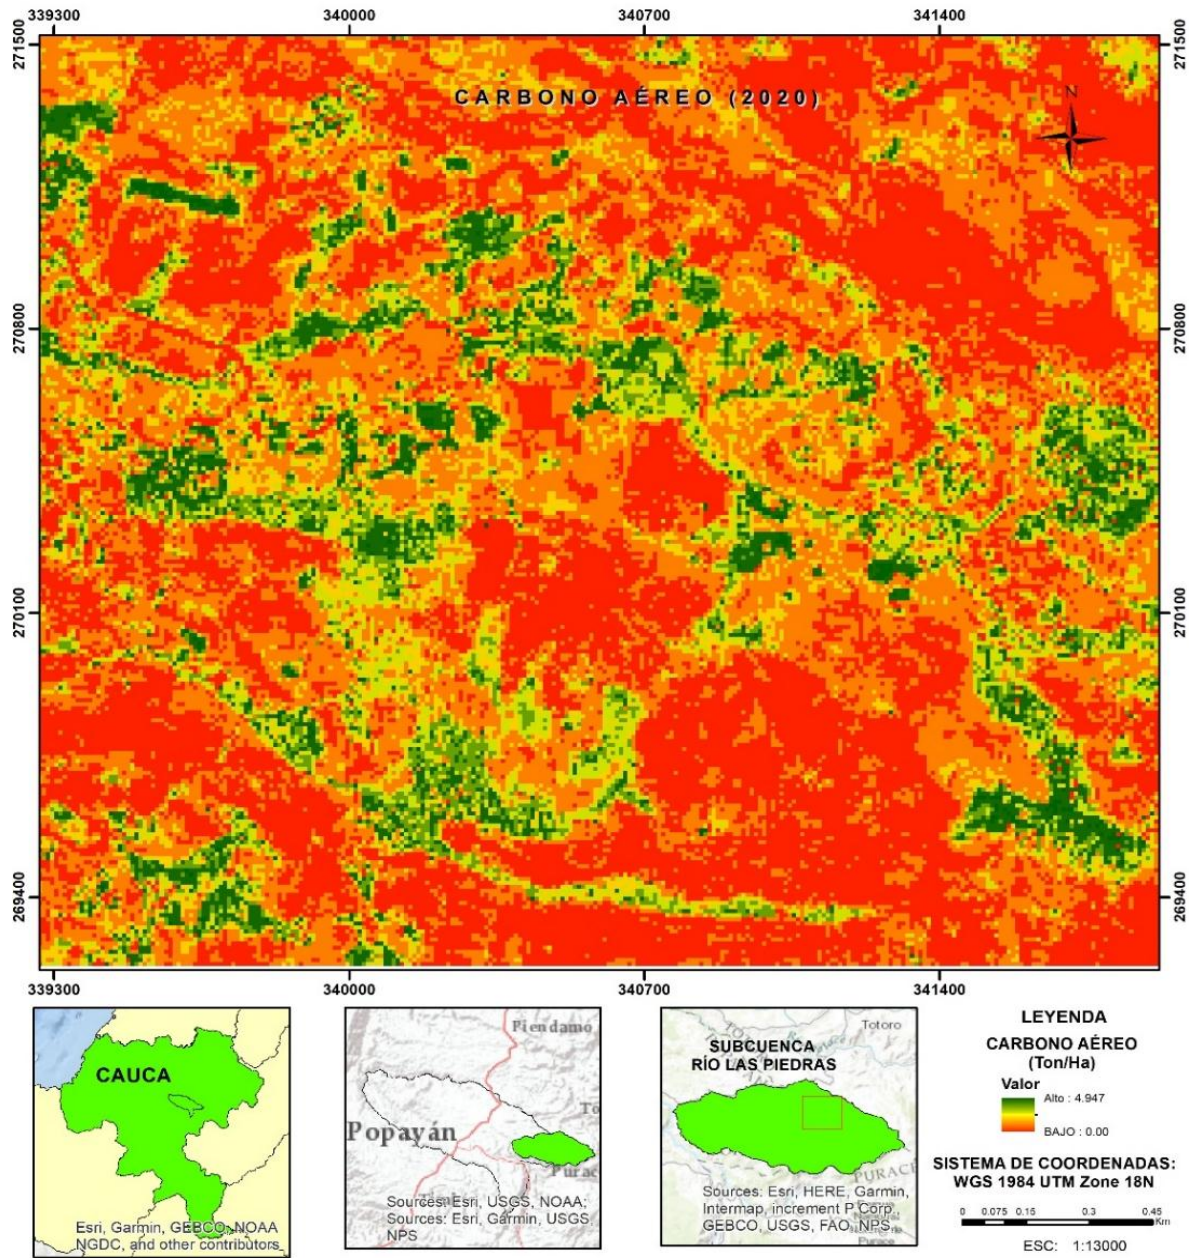
Una vez calculada la biomasa aérea, se procedió a determinar el carbono almacenado, que según (Quiceno et al. 2016, Gasparri, . y Manghi 2004), el contenido de carbono para los compartimientos por encima del suelo, debajo del suelo y en la madera muerta constituye el 50% de la biomasa de los mismos , es decir, que para estimar el contenido de carbono se multiplica el valor de la biomasa por 0,5. El valor de 0,5 corresponde al denominado factor de reducción (FR).

Mapa 3. Resultados de carbono almacenado usando RNA para el año 2016



Fuente: Propia

Mapa 4. Resultados de carbono almacenado usando RNA para el año 2020



Fuente: Propia

8. CONCLUSIONES

La determinación de la biomasa aérea y el contenido de carbono almacenado a partir de datos dasométricos en el bosque andino de la subcuenca del río Las Piedras, se desarrolló teniendo en cuenta los inventarios forestales previos, implementando el modelo establecido por Álvarez et al., (2012), el cual arrojó resultados similares a los encontrados en la literatura para ecosistemas con dinámicas naturales similares, ratificando su capacidad como sumidero de carbono y así su capacidad para amortiguar los efectos del cambio climático.

La estimación de la biomasa aérea y el contenido de carbono almacenado se logró mediante la combinación de índices espectrales seleccionados para bosque andino en la subcuenca del río Las Piedras. La selección de los índices de vegetación, es una de las actividades fundamentales en la implementación de este método, para la obtención de resultados aceptables dentro de la RNA; para el caso en estudio, los índices como NDVI GNDVI GNDVIre3n SAVI y WDRVI, fueron destacados por su habilidad para estimar la biomasa aérea, resaltándose el índice GNDVIre3n, por su ajuste con la banda de borde rojo que mejoró el modelo no paramétrico implementado.

La validación de la estimación de biomasa área y carbono almacenado se desarrolló a partir de información obtenida del sensor Sentinel 2A en relación a la cuantificación de almacenes de carbono de inventarios forestales del bosque andino, implementando métodos paramétricos (regresión lineal múltiple) y no paramétricos (red neuronal artificial) obteniendo precisiones de 0.7246 y 0.913, respectivamente, evidenciando así la superioridad en términos de precisión de la RNA sobre la regresión lineal múltiple implementada.

Los resultados obtenidos por parte del modelo estimativo propuesto (RNA), reflejan que, durante el entrenamiento de la RNA, se estableció el número óptimo de capas y neuronas ocultas, con lo cual se afirma que el comportamiento de los índices de vegetación seleccionados presenta una relación no-lineal, indicando la concordancia entre los resultados experimentales y los resultados de RNA.

A partir de la importancia en la estimación de la biomasa y carbono aéreo, el método estimativo (RNA), propone una ventaja en términos de tiempo y precisión, para la toma de decisiones orientadas a la protección de estos ecosistemas que contribuyen a mitigar el cambio climático.

Los resultados obtenidos a partir de la combinación de datos de campo y la extracción de datos del sensor Sentinel 2A, determinaron que son una técnica práctica y efectiva para la estimación de la biomasa aérea y carbono almacenado; el modelo propuesto es aplicable a bosques densos andinos usando modelos no paramétricos como la RNA.

La zona de estudio se caracteriza por estar cubierta de nubosidad gran parte del año, dicha característica fue una condición limitante para la selección de imágenes satelitales, dado que al estar cerca del volcán Puracé hace propicia la formación de los sistemas convectivos de gran extensión durante largos periodos del año, para ello, se implementó, en las imágenes del sensor Sentinel 2A, el algoritmo de árbol de decisión dada su habilidad como método no paramétrico para realizar clasificaciones de nubes y sombras.

Los resultados de biomasa y carbono aéreo en términos de la temporalidad, han evidenciado principalmente un cambio en la cobertura vegetal, especialmente en las zonas de pastizales o suelos desnudos a áreas cultivadas, como resultado de la expansión de la frontera agrícola, no obstante, en las zonas de reserva se han evidenciado un aumento de la biomasa y el carbono aéreo durante los años 2016 al 2020 en la subcuenca del río Las Piedras.

9 RECOMENDACIONES

La estimación de la biomasa para el cálculo de carbono aéreo, puede mejorarse significativamente usando productos de sensores remotos con una alta resolución espacial y espectral, no obstante, se recomienda incluir en próximos estudios información de sensores activos como el radar, dado que, esta zona se caracteriza por presentar sistemas de nubosidad convectivos durante gran parte del año.

Los resultados obtenidos a partir del inventario forestal suministrado, se podrían mejorar a partir de la recolección de otras características dasométricas, así como proporcionar valores de densidades de madera, teniendo en cuenta la especie de cada individuo, y de esta forma implementar nuevos modelos alométricos que mejoren los resultados de la estimación.

La selección de los índices de vegetación debe estar en función de las condiciones biofísicas de la zona de estudio, dado que el efecto topográfico incide sobre los resultados de la mayoría de los índices de vegetación que no presenten una diferencia normalizada, de igual forma, implementar las bandas de borde rojo dentro del NDVI y WDRVI, es una buena alternativa para mejorar la habilidad de estimación.

Para la implementación de este modelo en otros tipos de ecosistemas es importante contar con el inventario forestal y así realizar el entrenamiento con los índices de vegetación seleccionados, para la generación de resultados aceptables.

10 REFERENCIAS BIBLIOGRÁFICAS

- Aguas, Juan. 2016. "ESTIMACIÓN DE BIOMASA AÉREA FORESTAL EN BOSQUE DE ROBLEDALES DEL ALTIPLANO NORTE DE ANTIOQUIA, UTILIZANDO TELEDETECCIÓN." <http://bdigital.unal.edu.co/57516/1/1128387218.2017.pdf>.
- Agudelo, M I. 2009. "Biomasa Aérea y Contenido de Carbono En Bosques de Quercus Humboldtii y Colombobalanus Excelsa: Corredor de Conservación de Robles Guantiva – La Rusia – Iguaque (Santander – Boyacá) ." *Facultad de Ciencias Básicas Tesis de P*: 110.
- Alvares, Esteban, Juan Guillermo Saldarriaga, Alvaro Javier Duque, Kenneth Roy Cabrera, Adriana Patricia Yepes, Diego Alejandro Navarrete, and Juan Fernando Phillips. 2011. "Selección y Validación de Modelos Para La Estimación de La Biomasa Aérea En Los Bosques Naturales de Colombia." *Instituto de Hidrología, Metereologia y Estudios Ambientales - IDEAM*, 26.
- Araujo, Luciana Spinelli, João Roberto, and Yosio Edemir Shimabukuro. 2000. "Relationship Between SAVI and Biomass Data of Forest and Savanna Contact Zone in the Brazilian Amazonia." *International Archives of Photogrammetry and Remote Sensing* XXXIII (Part B7): 77–81. https://www.isprs.org/PROCEEDINGS/XXXIII/congress/part7/77_XXXIII-part7.pdf.
- Askar, Narissara Nuthammachot, Worradorn Phairuang, Pramaditya Wicaksono, and Tri Sayektiningsih. 2018. "Estimating Aboveground Biomass on Private Forest Using Sentinel-2 Imagery." *Journal of Sensors* 2018. <https://doi.org/10.1155/2018/6745629>.
- Babcock, Chad, Andrew O. Finley, Hans Erik Andersen, Robert Pattison, Bruce D. Cook, Douglas C. Morton, Michael Alonzo, et al. 2018. "Geostatistical Estimation of Forest Biomass in Interior Alaska Combining Landsat-Derived Tree Cover, Sampled Airborne Lidar and Field Observations." *Remote Sensing of Environment* 212 (May): 212–30. <https://doi.org/10.1016/j.rse.2018.04.044>.
- Balido Baloloy, Alvin, Ariel Conferido Blanco, Christian Gumbao Candido, Reginal Jay Labadisos Argamosa, John Bart Lovern Caboboy Dumalag, Lady Lee Carandang DImapilis, and Enrico Camero Paringit. 2018. "ESTIMATION of MANGROVE FOREST ABOVEGROUND BIOMASS USING MULTISPECTRAL BANDS, VEGETATION INDICES and BIOPHYSICAL VARIABLES DERIVED from OPTICAL SATELLITE IMAGERIES: RAPIDEYE, PLANETSCOPE and SENTINEL-2." *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 4 (3): 29–36. <https://doi.org/10.5194/isprs-annals-IV-3-29-2018>.
- Batanero, Carmen. 2001. *Didactica de La Estadística*. <https://doi.org/10.13140/RG.2.1.3946.7044>.
- Binkley, Dan. 2004. "A Hypothesis about the Interaction of Tree Dominance and Stand Production through Stand Development." *Forest Ecology and Management* 190 (2–3): 265–71. <https://doi.org/10.1016/j.foreco.2003.10.018>.

- Blanco, Adriana Lizeth Tovar, Iván Alberto Lizarazo Salcedo, and Nelly Rodríguez Eraso. 2020. *Estimating Aboveground Biomass of Eucalyptus Grandis and Pinus Spp Using Sentinel1A and Sentinel-2A Images in Colombia. Colombia Forestal*. Vol. 23. <https://doi.org/10.14483/2256201X.14854>.
- Blanco, Pedro Almagro. 2014. "Algoritmo de Retropropagación." *University of Pennsylvania Pinkel*.
- Bokkestijn, Albert. 2017. "Libro_Bosques_Andinos_Interactivo.Pdf."
- Bonilla M., Olmeda I., Puertas R. 2003. "Modelos Paramétricos y No Paramétricos En Problemas de Credit Scoring." *Financiación y Contabilidad XXXII*: 199–263. <https://doi.org/10.2307/j.ctv18msptf.13>.
- Bordoloi, R., B. Das, O. P. Tripathi, U. K. Sahoo, A. J. Nath, S. Deb, D. J. Das, et al. 2022. "Satellite Based Integrated Approaches to Modelling Spatial Carbon Stock and Carbon Sequestration Potential of Different Land Uses of Northeast India." *Environmental and Sustainability Indicators* 13 (December): 100166. <https://doi.org/10.1016/j.indic.2021.100166>.
- Bratsch, Sara, Howard Epstein, Marcel Buchhorn, Donald Walker, and Heather Landes. 2017. "Relationships between Hyperspectral Data and Components of Vegetation Biomass in Low Arctic Tundra Communities at Ivotuk, Alaska." *Environmental Research Letters* 12 (2). <https://doi.org/10.1088/1748-9326/aa572e>.
- Cao, Yang, Guo Long Li, Yuan Kai Luo, Qi Pan, and Shao Ying Zhang. 2020. "Monitoring of Sugar Beet Growth Indicators Using Wide-Dynamic-Range Vegetation Index (WDRVI) Derived from UAV Multispectral Images." *Computers and Electronics in Agriculture* 171 (January): 105331. <https://doi.org/10.1016/j.compag.2020.105331>.
- Castañeda-Martín, Abel Efrén, and Carmen Rosa Montes-Pulido. 2017. "Carbono Almacenado En Páramo Andino." *Entramado* 13 (1): 210–21. <https://doi.org/10.18041/entramado.2017v13n1.25112>.
- Castillo, Jose Alan A., Armando A. Apan, Tek N. Maraseni, and Severino G. Salmo. 2017. "Estimation and Mapping of Above-Ground Biomass of Mangrove Forests and Their Replacement Land Uses in the Philippines Using Sentinel Imagery." *ISPRS Journal of Photogrammetry and Remote Sensing* 134: 70–85. <https://doi.org/10.1016/j.isprsjprs.2017.10.016>.
- Castro, M., Palma, P., Ochoa, V., & Neto, C. 2014. "Servicios Ecosistémicos: Evaluación y Valoración Económica Del Secuestro de CO2 En Bosques y Áreas Protegidas Del Área de Conservación Guanacaste-ACG, Costa Rica." 14: 241–64.
- Ceceña-Sánchez, Martha Lizeth, Ricardo Eaton-González, Aurora Breceda Solís-Cámara, José Delgadillo-Rodríguez, Luciana Luna-Mendoza, and Alfredo Ortega-Rubio. 2021. "Evaluation of Changes in Vegetation Cover on Guadalupe Island with Vegetation Indices." *Madera y Bosques* 27 (1). <https://doi.org/10.21829/myb.2021.2712018>.

- Chandrakant Singh, Indian institute of technology. 2022. "Remote Sensing Based Biomass Estimation of Dry Deciduous Tropical Forest Using Machine Learning and Ensemble Analysis."
- Charris, Luis, Cesar Henriquez, Stiven Hernandez, Luis Jimeno, Oscar Guillen, and Silvia Moreno. 2018. "Análisis Comparativo de Algoritmos de Árboles de Decisión En El Procesamiento de Datos Biológicos." *Investigacion y Desarrollo En TIC*, no. 1: 10. <http://revistas.unisimon.edu.co/index.php/identific/article/view/3158/3905>.
- Chave, J., C. Andalo, S. Brown, M. A. Cairns, J. Q. Chambers, D. Eamus, H. Fölster, et al. 2005. "Tree Allometry and Improved Estimation of Carbon Stocks and Balance in Tropical Forests." *Oecologia* 145 (1): 87–99. <https://doi.org/10.1007/s00442-005-0100-x>.
- Cortés, Lorena Andrea, Shirley Camacho-Ballesteros, and Mauricio Matoma-Cardona. 2020. "Estudio de La Composición y Estructura Del Bosque Andino Localizado En Potrero Grande, Chipaque (Colombia)." *Revista U.D.C.A Actualidad & Divulgación Científica* 23 (1): 1–10. <https://doi.org/10.31910/rudca.v23.n1.2020.1483>.
- CRC. 2006. "Plan de Ordenación y Manejo de La Subcuenca Hidrográfica Del Río Las Piedras. Corporación Autónoma Regional Del Cauca."
- Cunliffe, Andrew M., Jakob J Assmann, Gergana N Daskalova, Jeffrey T. Kerby, and Isla H. Myers-Smith. 2020. "Aboveground Biomass Corresponds Strongly with Drone-Derived Canopy Height but Weakly with Greenness (NDVI) in a Shrub Tundra Landscape." *Environmental Research Letters* 15 (12). <https://doi.org/10.1088/1748-9326/aba470>.
- Das, Abhijit, Pramod, and B. S. Sunitha. 2022. "An Efficient Feature Selection Approach for Intrusion Detection System Using Decision Tree." *International Journal of Advanced Computer Science and Applications* 13 (2): 646–56. <https://doi.org/10.14569/IJACSA.2022.0130276>.
- Dorofki, Mohammad, Ahmed H Elshafie, Othman Jaafar, Othman A Karim, and Sharifah Mastura. 2012. "Comparison of Artificial Neural Network Transfer Functions Abilities to Simulate Extreme Runoff Data." *2012 International Conference on Environment, Energy and Biotechnology*, no. January: 39–44.
- Duque, Alvaro, Miguel A. Peña, Francisco Cuesta, Sebastián González-Caro, Peter Kennedy, Oliver L. Phillips, Marco Calderón-Loor, et al. 2021. "Mature Andean Forests as Globally Important Carbon Sinks and Future Carbon Refuges." *Nature Communications* 12 (1): 1–10. <https://doi.org/10.1038/s41467-021-22459-8>.
- Durán, Sandra M., and Ernesto Gianoli. 2013. "Carbon Stocks in Tropical Forests Decrease with Liana Density." *Biology Letters* 9 (4): 3–6. <https://doi.org/10.1098/rsbl.2013.0301>.
- Elmendorf, Sarah C., Gregory H.R. Henry, Robert D. Hollister, Robert G. Björk, Noémie Boulanger-Lapointe, Elisabeth J. Cooper, Johannes H.C. Cornelissen, et al. 2012. "Plot-Scale Evidence of Tundra Vegetation Change and Links to Recent Summer Warming." *Nature Climate Change* 2 (6): 453–57.

<https://doi.org/10.1038/nclimate1465>.

- Fernández, et al. 2015. “La Cobertura Periodística Del Cambio Climático y Del Calentamiento Global En El País, El Mundo y La Vanguardia.” *Revista Latina de Comunicacion Social* 70: 122–40. <https://doi.org/10.4185/RLCS-2015-1038>.
- Galidaki, Georgia, Dimitris Zianis, Ioannis Gitas, Kalliopi Radoglou, Vassilia Karathanassi, Maria Tsakiri–Strati, Iain Woodhouse, and Giorgos Mallinis. 2017. “Vegetation Biomass Estimation with Remote Sensing: Focus on Forest and Other Wooded Land over the Mediterranean Ecosystem.” *International Journal of Remote Sensing* 38 (7): 1940–66. <https://doi.org/10.1080/01431161.2016.1266113>.
- Gano, Boubacar, Joseph Sékou B. Dembele, Adama Ndour, Delphine Luquet, Gregory Beurier, Diaga Diouf, and Alain Audebert. 2021. “Using Uav Borne, Multi-Spectral Imaging for the Field Phenotyping of Shoot Biomass, Leaf Area Index and Height of West African Sorghum Varieties under Two Contrasted Water Conditions.” *Agronomy* 11 (5). <https://doi.org/10.3390/agronomy11050850>.
- Gasparri, I. y Manghi, E. 2004. “Estimación de Volumen, Biomasa y Contenido de Carbono de Las Regiones Forestales Argentinas.” ... *De Bosques*, ..., 1–26. http://www.foroiberoamericano.ambiente.gov.ar/archivos/web/UMSEF/File/volumen_biomasa_carbono.pdf.
- Girardin, Cécile A.J., William Farfan-Rios, Karina Garcia, Keneth J. Feeley, Peter M. Jørgensen, Alejandro Araujo Murakami, Leslie Cayola Pérez, et al. 2014. “Spatial Patterns of Above-Ground Structure, Biomass and Composition in a Network of Six Andean Elevation Transects.” *Plant Ecology and Diversity* 7 (1–2): 161–71. <https://doi.org/10.1080/17550874.2013.820806>.
- Gómez, Alejandro. 2018. “Estimación Del Carbono Almacenado En La Biomasa Aérea de Un Bosque Húmedo Tropical En Paimadó , Chocó Estimated Carbon Content in the Aerial Biomass of a Tropical Rainforest In” 9 (1): 18–29.
- González-Alonso, F., S. Merino-De-Miguel, A. Roldán-Zamarrón, S. García-Gigorro, and J. M. Cuevas. 2006. “Forest Biomass Estimation through NDVI Composites. The Role of Remotely Sensed Data to Assess Spanish Forests as Carbon Sinks.” *International Journal of Remote Sensing* 27 (24): 5409–15. <https://doi.org/10.1080/01431160600830748>.
- Guerini Filho, Marildo, Tatiana Mora Kuplich, and Fernando L.F.De Quadros. 2020. “Estimating Natural Grassland Biomass by Vegetation Indices Using Sentinel 2 Remote Sensing Data.” *International Journal of Remote Sensing* 41 (8): 2861–76. <https://doi.org/10.1080/01431161.2019.1697004>.
- Guevara, Isabel Cristina Suarez. 2019. “Estrategias Para La Producción Más Limpia En El Sector de Cacao y Caña Panelera En El Valle Del Cauca Bajo El Marco Del Plan Nacional de Negocios Verdes En Colombia.”, 97.
- Han, Xiao, Fangbiao Liu, Xiaoliang He, and Fenglou Ling. 2022. “Research on Rice Yield Prediction Model Based on Deep Learning” 2022.

- Hank, Tobias B., Heike Bach, and Wolfram Mauser. 2015. "Using a Remote Sensing-Supported Hydro-Agroecological Model for Field-Scale Simulation of Heterogeneous Crop Growth and Yield: Application for Wheat in Central Europe." *Remote Sensing* 7 (4): 3934–65. <https://doi.org/10.3390/rs70403934>.
- IDEAM. 2015a. "Inventario Nacional de Gases de Efecto Invernadero (GEI)."
- IDEAM. 2021. "Presentación - Resultados Del Monitoreo de Deforestación 2020."
- IPCC. 2021. "Comunicado de Prensa Del IPCC." *Grupo Intergubernamental de Expertos Sobre El Cambio Climático (IPCC)*, 1–5. https://www.ipcc.ch/site/assets/uploads/2021/08/IPCC_WGI-AR6-Press-Release-Final_es.pdf.
- IPCC, 2021: Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth, S.L. Assessment Report of the Intergovernmental Panel on Climate Change [Masson-Delmotte, V., P. Zhai, A. Pirani, J.B.R. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M.I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, and B. Zhou (eds.)]. Cambridge University Press. In Matthews, T.K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, and Press. 2020. "Climate Change 2021 The Physical Science Basis." *Bulletin of the Chinese Academy of Sciences* 34 (2): F0003–F0003. <https://doi.org/10.3724/sp.j.7103161536>.
- Jia, Kun, Shunlin Liang, Lei Zhang, Xiangqin Wei, Yunjun Yao, and Xianhong Xie. 2014. "Forest Cover Classification Using Landsat ETM+ Data and Time Series MODIS NDVI Data." *International Journal of Applied Earth Observation and Geoinformation* 33 (1): 32–38. <https://doi.org/10.1016/j.jag.2014.04.015>.
- Kattán, Gustavo., and N.Y.). Colombia Program. Wildlife Conservation Society (New York. 2003. *Bosques Andinos y Subandinos Del Departamento Del Valle Del Cauca, Colombia*.
- Korhonen, Lauri, Hadi, Petteri Packalen, and Miina Rautiainen. 2017. "Comparison of Sentinel-2 and Landsat 8 in the Estimation of Boreal Forest Canopy Cover and Leaf Area Index." *Remote Sensing of Environment* 195: 259–74. <https://doi.org/10.1016/j.rse.2017.03.021>.
- Kumar, Kilaparathi Kiran, Masahiko Nagai, Apichon Witayangkurn, Kunnaree Kritiyutanant, and Shinichi Nakamura. 2016. "Above Ground Biomass Assessment from Combined Optical and SAR Remote Sensing Data in Surat Thani Province, Thailand." *Journal of Geographic Information System* 08 (04): 506–16. <https://doi.org/10.4236/jgis.2016.84042>.
- Lakshmi, Venkat. 2016. *Remote Sensing of Hydrological Extremes. Springer Remote Sensing/Photogrammetry*. <http://link.springer.com/10.1007/978-3-319-43744-6>.
- Lezama, José Luis. 2014. "La Política Internacional Del Cambio Climático." *Sociedad y Ambiente*, no. 3: 104–17. <https://doi.org/10.31840/sya.v0i3.999>.
- Li, Long, Xisheng Zhou, Longqian Chen, Longgao Chen, Yu Zhang, and Yunqiang Liu. 2020. "Estimating Urban Vegetation Biomass from Sentinel-2A Image Data."

Forests 11 (2): 1–24. <https://doi.org/10.3390/f11020125>.

- Liakos, Konstantinos G., Patrizia Busato, Dimitrios Moshou, Simon Pearson, and Dionysis Bochtis. 2018. "Machine Learning in Agriculture: A Review." *Sensors (Switzerland)* 18 (8): 1–29. <https://doi.org/10.3390/s18082674>.
- Liu, Bing, Lu Zhi, Bing Liu, Xuchu Yu, Pengqiang Zhang, Xiong Tan, Ruirui Wang, and Lu Zhi. 2018. "Above-Ground Biomass Prediction Prediction by Sentinel-1 Multitemporal Data in Central Italy with Inetgration of ALOS2 and Sentinel." *Journal of Applied Remote Sensing* 12 (1). <https://doi.org/10.1117/1.JRS.12>.
- Liu, Hui Qing, and Alfredo Huete. 1995. "Feedback Based Modification of the NDVI to Minimize Canopy Background and Atmospheric Noise," no. 1: 1–9.
- Lizeth, Adriana, and Tovar Blanco. 2018. "Adriana Lizeth Tovar Blanco."
- López-Serrano, Pablito M., Carlos A.López Sánchez, Raúl Solís-Moreno, and José J. Corral-Rivas. 2016. "Geospatial Estimation of above Ground Forest Biomass in the Sierra Madre Occidental in the State of Durango, Mexico." *Forests* 7 (3): 1–13. <https://doi.org/10.3390/f7030070>.
- Lourakis, Manolis I.A., and Antonis A. Argyros. 2005. "Is Levenberg-Marquardt the Most Efficient Optimization Algorithm for Implementing Bundle Adjustment?" *Proceedings of the IEEE International Conference on Computer Vision II* (June 2014): 1526–31. <https://doi.org/10.1109/ICCV.2005.128>.
- Lu, Dengsheng, Paul Mausel, Eduardo Brondízio, and Emilio Moran. 2004. "Relationships between Forest Stand Parameters and Landsat TM Spectral Responses in the Brazilian Amazon Basin." *Forest Ecology and Management* 198 (1–3): 149–67. <https://doi.org/10.1016/j.foreco.2004.03.048>.
- Lv, Hailiang, Wenjie Wang, Xingyuan He, Chenhui Wei, Lu Xiao, Bo Zhang, and Wei Zhou. 2018. "Association of Urban Forest Landscape Characteristics with Biomass and Soil Carbon Stocks in Harbin City, Northeastern China." *PeerJ* 6 (October): e5825. <https://doi.org/10.7717/peerj.5825>.
- M. Acosta-Mireles, F. Carrillo-Anzures y M. Díaz Lavariega. 2008. "Determinación Del Carbono Total En Bosques Mixtos." *Terra Latinoamericana* 27 (2): 105–14.
- Marini, Fabián, and Mariana Santamaría. 2019. "Evaluación de Índices Verdes Convencionales e Índices Del 'Borde Rojo' En La Discriminación de Cultivos a Nivel Regional." *Rev.Elect.Geogr.Austral*.
- Martínez-Barrón, René, Oscar Aguirre-Calderón, Javier Jiménez-Pérez, Eduardo Treviño-Garza, and Benedicto Vargas-Larreta. 2014. "Modelación de La Dinámica Del Carbono En Bosques Del Estado de Durngo." *Universidad Autónoma de Nuevo León TESIS DE M*: 1–67. eprints.uanl.mx/4359/1/1080253734.pdf.
- Masera, Omar R., J. F. Garza-Caligaris, M. Kanninen, T. Karjalainen, J. Liski, G. J. Nabuurs, A. Pussinen, B. H.J. De Jong, and G. M.J. Mohren. 2003. "Modeling Carbon Sequestration in Afforestation, Agroforestry and Forest Management Projects: The CO2FIX V.2 Approach." *Ecological Modelling* 164 (2–3): 177–99.

[https://doi.org/10.1016/S0304-3800\(02\)00419-2](https://doi.org/10.1016/S0304-3800(02)00419-2).

- Masson. 2019. *Informe Especial Del IPCC Sobre Los Impactos Del Calentamiento Global. Intergovernmental Panel on Climate Change*.
- Matsushita, Bunkei, Wei Yang, Jin Chen, Yuyichi Onda, and Guoyu Qiu. 2007. "Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-Density Cypress Forest." *Sensors* 7 (11): 2636–51. <https://doi.org/10.3390/s7112636>.
- Melo, Omar, Nathaly Rodríguez, and Ferney Rojas. 2011. "Carbono Capturado y Acumulación de Biomasa En Cinco Especies Leñosas Nativas de La Cordillera Oriental, Utilizadas En Programas de Restauración Ecológica En La Sabana de Bogotá." *Asociación Colombiana de Ciencias Biológicas* 23 (2011): 91–102.
- Mendoza. 2018. "ESTIMACIÓN DE CARBONO EN PLANTACIONES DE Pinus Patula MEDIANTE EL ANÁLISIS ESPECTRAL DE UNA IMAGEN SATELITAL SENTINEL-2, DISTRITO DE LUYA VIEJO, AMAZONAS, 2018." *International Journal of Machine Tools and Manufacture* 5 (1): 86–96. <https://doi.org/10.1016/j.ijmactools.2009.09.004>.
- Moges, S. M., W. R. Raun, R. W. Mullen, K. W. Freeman, G. V. Johnson, and J. B. Solie. 2004. "Evaluation of Green, Red, and near Infrared Bands for Predicting Winter Wheat Biomass, Nitrogen Uptake, and Final Grain Yield." *Journal of Plant Nutrition* 27 (8): 1431–41. <https://doi.org/10.1081/PLN-200025858>.
- Montero, Roberto. 2016. "Modelos de Regresión Lineal Múltiple." *Documentos de Trabajo En Economía Aplicada*, 60. https://www.ugr.es/~montero/matematicas/regresion_lineal.pdf.
- Muhsoni, Firman Farid, A. B. Sambah, M. Mahmudi, and D. G.R. Wiadnya. 2018. "Comparison of Different Vegetation Indices for Assessing Mangrove Density Using Sentinel-2 Imagery." *International Journal of GEOMATE* 14 (45): 42–51. <https://doi.org/10.21660/2018.45.7177>.
- Muñoz, Pedro. 2013. "Apuntes de Teledetección: Índices de Vegetación." *Centro de Información de Recursos Naturales*, 15. <https://doi.org/http://bibliotecadigital.ciren.cl/bitstream/handle/123456789/26389/Tema%20Indices%20de%20vegetaci%C3%B3n%20Pedro%20Mu%C3%B1oz%20A.pdf?sequence=1&isAllowed=y>.
- Munyati, C. 2022. "Detecting the Distribution of Grass Aboveground Biomass on a Rangeland Using Sentinel-2 MSI Vegetation Indices." *Advances in Space Research* 69 (2): 1130–45. <https://doi.org/10.1016/j.asr.2021.10.048>.
- Naqa, Issam El, and Martin J Murphy. 2015. "Machine Learning in Radiation Oncology." *Machine Learning in Radiation Oncology*, 3–11. <https://doi.org/10.1007/978-3-319-18305-3>.
- Navarro. 2017. "Evaluation of Forest Fire on Madeira Island Using Sentinel-2A MSI Imagery." *International Journal of Applied Earth Observation and Geoinformation*

- 58: 97–106. <https://doi.org/10.1016/j.jag.2017.02.003>.
- Nolasco, Miguel. 2015. “ANÁLISIS DE BORDE ROJO (RED EDGE) EN LA DETERMINACIÓN DE ÍNDICES DE VEGETACIÓN,” no. December 2015. <https://doi.org/10.13140/RG.2.2.32758.42564>.
- Novales, Alfonso. 2010. “Análisis de Regresión.”
- Ontiveros, S, S Manrique, J Franco, R Díaz, and N Barranco. 2015. “Biomasa Y Stock De Carbono En La Reserva De Campo Alegre, La Caldera, Provincia De Salta.” *Avances En Energías Renovables y Medio Ambiente* 19: 6–7.
- Ordoñez, María Cristina, Juan Fernando Casanova Olaya, Leopoldo Galicia, and Apolinar Figueroa. 2020. “Soil Carbon Dynamics under Pastures in Andean Socio-Ecosystems of Colombia.” *Agronomy* 10 (4). <https://doi.org/10.3390/agronomy10040507>.
- Pattanayak, Satyajit, Chanchal Loha, Lalhmingsanga Hauchhum, and Lalsangzela Sailo. 2021. “Application of MLP-ANN Models for Estimating the Higher Heating Value of Bamboo Biomass.” *Biomass Conversion and Biorefinery* 11 (6): 2499–2508. <https://doi.org/10.1007/s13399-020-00685-2>.
- Peña M., Saldarriaga J., Montoya A. 2011. “Acumulación De Carbono Y Cambios Estructurales” 33 (95): 209–17.
- Pereira Coltri, Priscila, Jurandir Zullo, Renata Ribeiro Do Valle Goncalves, Luciana Alvim S. Romani, and Hilton Silveira Pinto. 2013. “Coffee Crop’s Biomass and Carbon Stock Estimation with Usage of High Resolution Satellites Images.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 6 (3): 1786–95. <https://doi.org/10.1109/JSTARS.2013.2262767>.
- Pinty, Author B, M M Verstraete, Source Vegetatio, No Jul, and B Pinty. 2011. “GEMI : A Non-Linear Index to Monitor Global Vegetation from Satellites GEMI : A Non-Linear Index to Monitor Global Vegetation from Satellites.” *Vegetatio* 101 (1): 15–20.
- Prabhakara, Kusuma, W. Dean Hively, and Gregory W. McCarty. 2015. “Evaluating the Relationship between Biomass, Percent Groundcover and Remote Sensing Indices across Six Winter Cover Crop Fields in Maryland, United States.” *International Journal of Applied Earth Observation and Geoinformation* 39: 88–102. <https://doi.org/10.1016/j.jag.2015.03.002>.
- Quiceno-Urbina, Nubia-Janeth, Gloria-Mónica Tangarife-Marín, and Ricardo Álvarez-León. 2016. “Estimación Del Contenido de Biomasa, Fijación de Carbono y Servicios Ambientales, En Un Área de Bosque Primario En El Resguardo Indígena Piapoco Chigüiro-Chátare de Barrancominas, Departamento Del Guainía (Colombia).” *Luna Azul* 43 (43): 171–202. <https://doi.org/10.17151/luaz.2016.43.9>.
- Räsänen, Aleks, Sari Juutinen, Mika Aurela, and Tarmo Virtanen. 2019. “Predicting Aboveground Biomass in Arctic Landscapes Using Very High Spatial Resolution Satellite Imagery and Field Sampling.” *International Journal of Remote Sensing* 40 (3): 1175–99. <https://doi.org/10.1080/01431161.2018.1524176>.

- Rodríguez, Jiménez, Pedraza. 2019. "Efectos Del Cambio Climático En La Salud de La Población Colombiana." *Duazary* 16 (2): 319–31. <https://doi.org/10.21676/2389783X.3186>.
- Rosenblatt, F. 1958. "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain." *Psychological Review* 65 (6): 386–408. <https://doi.org/10.1037/h0042519>.
- Rügnitz, M. T., M. L. Chacón, and R. Porro. 2008. *Guía Para La Determinación de Carbono En Pequeñas Propiedades Rurales. Consorcio Iniciativa Amazónica (IA) y Centro Mundial Agroforestal (ICRAF)*. [https://doi.org/ISBN: 978-92-9059-254-9](https://doi.org/ISBN:978-92-9059-254-9).
- Saadat, Hossein, Jan Adamowski, Robert Bonnell, Forood Sharifi, Mohammad Namdar, and Sasan Ale-Ebrahim. 2011. "Land Use and Land Cover Classification over a Large Area in Iran Based on Single Date Analysis of Satellite Imagery." *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (5): 608–19. <https://doi.org/10.1016/j.isprsjprs.2011.04.001>.
- Shao, Zhenfeng, and Linjing Zhang. 2016. "Estimating Forest Aboveground Biomass by Combining Optical and SAR Data: A Case Study in Genhe, Inner Mongolia, China." *Sensors (Switzerland)* 16 (6). <https://doi.org/10.3390/s16060834>.
- Sharma, Sumit K R. 2021. "Snow Avalanche Prediction Using Artificial Intelligence and Comparative Review of Algorithms" 09 (12): 11–19.
- Spracklen, D. V., and R. Righelato. 2014. "Tropical Montane Forests Are a Larger than Expected Global Carbon Store." *Biogeosciences* 11 (10): 2741–54. <https://doi.org/10.5194/bg-11-2741-2014>.
- Stephens, Britton B., Kevin R. Gurney, Pieter P. Tans, Colm Sweeney, Wouter Peters, Lori Bruhwiler, Philippe Ciais, et al. 2007. "Weak Northern and Strong Tropical Land Carbon Uptake from Vertical Profiles of Atmospheric CO₂." *Science* 316 (5832): 1732–35. <https://doi.org/10.1126/science.1137004>.
- Tauli et al. 2011. *Guía Del Cambio Climático, Segunda Edición. Journal of Chemical Information and Modeling*. Vol. 53. <https://doi.org/10.1017/CBO9781107415324.004>.
- Théau, Jérôme, Étienne Lauzier-Hudon, Lydiane Aubé, and Nicolas Devillers. 2021. "Estimation of Forage Biomass and Vegetation Cover in Grasslands Using UAV Imagery." *PLoS ONE* 16 (1 January): 1–18. <https://doi.org/10.1371/journal.pone.0245784>.
- Tilly, Nora, Helge Aasen, and George Bareth. 2015. "Fusion of Plant Height and Vegetation Indices for the Estimation of Barley Biomass." *Remote Sensing* 7 (9): 11449–80. <https://doi.org/10.3390/rs70911449>.
- Torabzadeh, H., M. Moradi, and P. Fatehi. 2019. "Estimating Aboveground Biomass in Zagros Forest, Iran, Using Sentinel-2 Data." *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-4/W18 (October)*: 1059–63. <https://doi.org/10.5194/isprs-archives-xlii-4-w18-1059-2019>.

- Torres-Torres, Jhon Jerley, Víctor Eleazar Mena-Mosquera, and Esteban Álvarez-Dávila. 2017. "Carbono Aéreo Almacenado En Tres Bosques Del Jardín Botánico Del Pacífico, Chocó, Colombia." *Entramado* 13 (1): 200–209. <https://doi.org/10.18041/entramado.2017v13n1.25110>.
- UNFCCC. 1992. "Convención Marco de Las Naciones Unidas Sobre El Cambio Climático" 62301.
- Valencia, S. 2013. "ALMACENAMIENTO DE CARBONO EN EL GRADIENTE CONSTITUTIVO (BORDE – INTERIOR) DE UN BOSQUE ANDINO EN LA CUENCA DEL RÍO LAS PIEDRAS, MUNICIPIO DE POPAYÁN, CAUCA."
- Verrelst, Jochem, Juan Pablo Rivera, Frank Veroustraete, Jordi Muñoz-Marí, Jan G.P.W. Clevers, Gustau Camps-Valls, and José Moreno. 2015. "Experimental Sentinel-2 LAI Estimation Using Parametric, Non-Parametric and Physical Retrieval Methods - A Comparison." *ISPRS Journal of Photogrammetry and Remote Sensing* 108: 260–72. <https://doi.org/10.1016/j.isprsjprs.2015.04.013>.
- Vina, Andrés, Geoffrey M. Henebry, and Anatoly A. Gitelson. 2004. "Satellite Monitoring of Vegetation Dynamics: Sensitivity Enhancement by the Wide Dynamic Range Vegetation Index." *Geophysical Research Letters*. <https://doi.org/10.1029/2003GL019034>.
- Wang, Chao, Chao Wang, Mei-chen Feng, Wu-de Yang, Guang-wei Ding, and Hui Sun. 2016. "Impact of Spectral Saturation on Leaf Area Index and above Ground Biomass Estimation of Winter Wheat Impact of Spectral Saturation on Leaf Area Index and Aboveground Biomass Estimation of Winter Wheat," no. January. <https://doi.org/10.1080/00387010.2015.1133652>.
- Wang, Liang, Jiping Liu, Shenghua Xu, Jinjin Dong, and Yi Yang. 2018. "Forest above Ground Biomass Estimation from Remotely Sensed Imagery in the Mount Tai Area Using the RBF Ann Algorithm." *Intelligent Automation and Soft Computing* 24 (2): 391–98. <https://doi.org/10.1080/10798587.2017.1296660>.
- Wei, Wei, Dawid Poap, Xiaohua Li, Marcin Woźniak, and Junzhe Liu. 2019. "Study on Remote Sensing Image Vegetation Classification Method Based on Decision Tree Classifier." *Proceedings of the 2018 IEEE Symposium Series on Computational Intelligence, SSCI 2018*, 2292–97. <https://doi.org/10.1109/SSCI.2018.8628721>.
- Xochitl, Cloe. 2021. "Mapeo de La Cobertura Vegetal Del Valle de Tehuacán-Cuicatlán."
- Ya'Acob, Norsuzila, Aziean Binti Mohd Azize, Nur Anis Mahmon, Azita Laily Yusof, Nor Farhana Azmi, and Norfazira Mustafa. 2014. "Temporal Forest Change Detection and Forest Health Assessment Using Remote Sensing." *IOP Conference Series: Earth and Environmental Science* 19 (1). <https://doi.org/10.1088/1755-1315/19/1/012017>.
- Yepes, Adriana, Johana Herrera, Juan Phillips, Edersson Cabrera, Gustavo Galindo, Edwin Granados, Álvaro Duque, Adriana Barbosa, Claudia Olarte, and María Cardona. 2015. "Contribución de Los Bosques Tropicales de Montaña En El Almacenamiento de Carbono En Colombia." *Revista de Biología Tropical* 63 (1):

69–82. <https://doi.org/10.15517/rbt.v63i1.14679>.

Yepes, Adriana, Mauricio Zapata, Jhoanata Bolivar, Alejandra Monsalve, Sandra Milena Espinosa, Paula Cristina Sierra-Correa, and Andrés Sierra. 2016. “Tree Above-Ground Biomass Allometries for Carbon Stocks Estimation in the Caribbean Mangroves in Colombia.” *Revista de Biología Tropical* 64 (2): 913–26. <https://doi.org/10.15517/rbt.v64i2.18141>.

Yue, Jibo, Guijun Yang, and Haikuan Feng. 2016. “Comparative of Remote Sensing Estimation Models of Winter Wheat Biomass Based on Random Forest Algorithm.” *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering* 32 (18): 175–82. <https://doi.org/10.11975/j.issn.1002-6819.2016.18.024>.