

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS
FACULTAD DE INGENIERÍA
ESCUELA PROFESIONAL DE INGENIERÍA FORESTAL Y
MEDIO AMBIENTE



TESIS

“Estimación de las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *bertholletia excelsa* mediante la fusión de imágenes sentinel y Lidar espacial GEDI, Tahuamanu – Madre de Dios”

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO FORESTAL Y MEDIO AMBIENTE

AUTORES:

Bach. HUISA SÁNCHEZ, Gabriela
Celia del Carmen
Bach. LAGUADO ROBLES,
Franchesca Danay

ASESOR:

Dr. ALARCÓN AGUIRRE, Gabriel

Puerto Maldonado, Marzo de 2026

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS
FACULTAD DE INGENIERÍA
ESCUELA PROFESIONAL DE INGENIERÍA FORESTAL Y MEDIO
AMBIENTE



TESIS

“Estimación de las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *bertholletia excelsa* mediante la fusión de imágenes sentinel y Lidar espacial GEDI,

Tahuamanu – Madre de Dios”

**PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO
FORESTAL Y MEDIO AMBIENTE**

AUTORES:

Bach. HUISA SÁNCHEZ, Gabriela
Celia del Carmen

Bach. LAGUADO ROBLES,
Franchesca Danay

ASESOR:

Dr. ALARCÓN AGUIRRE, Gabriel

Puerto Maldonado, Marzo de 2026

RST-RI_Estimación de las reservas y fugas de carbono aéreo en el área de influencia de concesiones de bertholletia excelsa mediante la fusión de imágenes sentinel y Lidar espacial GEDI, Tahuamanu

INFORME DE ORIGINALIDAD

10%

INDICE DE SIMILITUD

10%

FUENTES DE INTERNET

1%

PUBLICACIONES

2%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.unamad.edu.pe Fuente de Internet	8%
2	cia.uagraria.edu.ec Fuente de Internet	1%
3	ridum.umanizales.edu.co Fuente de Internet	1%
4	Submitted to PLANESTIC-UD Trabajo del estudiante	1%

Excluir citas

Activo

Excluir coincidencias < 1%

Excluir bibliografía

Activo

Dedicatoria

Dedico esta tesis con todo cariño y gratitud a mi familia, quienes han sido mi pilar fundamental para no rendirme.

A mis padres Cesar Alejandro Huisa López y Nathi Jesica Sánchez Vera, por inculcarme con su ejemplo el esfuerzo y perseverancia, que con su apoyo constante fueron mi soporte incondicional e hicieron este recorrido más ameno.

A Nani Alberto, mi angelito de cuatro patitas, que desde el cielo me acompaña y siempre está presente para darme aliento y recordarme que no debo rendirme.

Y me dedico este logro a mí misma, por mi esfuerzo y constancia que me permitió llegar hasta aquí. Este proceso me enseñó que la perseverancia y confianza en uno mismo son la clave para alcanzar los objetivos y materializar las metas.

Gabriela Huisa

Dedico esta tesis a Dios y a mis padres, por apoyarme siempre en seguir luchando por mis sueños; siempre creyeron en mí.

A mi hijo y a mi sobrino, porque quiero enseñarles que cada esfuerzo tiene su recompensa.

A mis hermanos, por sus consejos y por estar a mi lado en este camino y demostrarme que, aunque el camino sea difícil, nunca es imposible.

Este logro no es solo mío, sino de todos los que caminaron conmigo. Hoy culmino una etapa, pero también inicio otra con la certeza de que los sueños se cumplen.

Franchesca Laguado

Agradecimientos

Agradezco en primer lugar a Dios por darme la sabiduría y fortaleza necesaria para llegar hasta aquí, por ser mi guía en cada paso de este camino y no rendirme frente a las dificultades.

Quiero expresar mi agradecimiento a mis padres y hermanos por su amor incondicional, paciencia y apoyo constante durante el proceso que llevó para culminar este proyecto.

A mi familia, docentes y asesor, quienes compartieron sus conocimientos y me encaminaron en este recorrido. Asimismo, agradezco a mis compañeros y amigos quienes con sus palabras de aliento y compañía hicieron más llevadero este camino.

Todo esto no hubiese sido posible sin el apoyo de cada uno de ustedes.

Gabriela Huisa

Agradezco en primer lugar a Dios, por darme a los padres más constantes y comprometidos, cuyo esfuerzo y sacrificio han sido el pilar fundamental de este logro.

A mi hijo y a mi sobrino, porque son la razón más grande de este logro y la inspiración que me impulsan a seguir adelante y demostrarles que siempre se puede luchar por lo nuestro.

A mis hermanos, por estar conmigo en este camino.

A mi asesor, por su conocimiento, dedicación y paciencia en esta etapa.

Franchesca Laguado

Resumen

El objetivo de este estudio fue estimar las reservas y fugas de carbono aéreo en el área de influencia de las concesiones de *Bertholletia excelsa* en Tahuamanu, Madre de Dios, utilizando datos de alta resolución de teledetección. Se generó un modelo de Random Forest (RF) utilizando datos GEDI L4B, imágenes Sentinel-1 (S1) y Sentinel-2 (S2) y un Modelo Digital de Elevación (DEM) para estimar y cuantificar la densidad de biomasa aérea (AGBD). En la eficiencia del modelo, las bandas infrarrojas de S2 (B12 y B11), y la elevación fueron las variables más importantes en el análisis, los resultados mostraron una densidad promedio de AGBD en el área de influencia de 241,66 Mg/ha y en las concesiones de 241,08 Mg/ha. El rendimiento del modelo reportó una alta eficiencia en la etapa de entrenamiento ($R^2 = 0,79$), pero los resultados de validación indicaron sobreajuste ($R^2 = 0,62$, RMSE = 65,71 Mg/ha, rRMSE = 27,07%). Estos resultados indican que el modelo no es totalmente generalizable. Las reservas aéreas de carbono se estimaron en 1,993,370,696.62 MgC para el área de influencia y 155 411 610,95 MgC para las concesiones. La densidad promedio de carbono fue de 120,54 MgC/ha, valor comparable al área de influencia (120,83 MgC/ha). Se definió un cinturón de fugas de carbono mediante un Análisis Multicriterio de Evaluación con lógica difusa, donde la deforestación y las vías principales fueron los factores que más contribuyeron al riesgo, siendo las áreas con potencial de fuga en el área de influencia alrededor de 400 468 662,72 MgC. Los resultados destacan la importancia de las concesiones de *B. excelsa* como reservorios de carbono y la necesidad de implementar estrategias de conservación que puedan ser adoptadas por políticos y gestores. Finalmente, si bien, la metodología desarrollada representa una herramienta útil para el monitoreo y planificación en el contexto de REDD+, es necesario abordar las limitaciones del modelo con la finalidad de mejorar la representatividad de los datos que correspondan correctamente la validación.

Palabras clave: Biomasa, densidad de biomasa aérea, lógica difusa, evaluación multicriterio.

Abstract

The objective of this study was to estimate aboveground carbon stocks and emissions in the area of influence of *Bertholletia excelsa* concessions in Tahuamanu, Madre de Dios, using high-resolution remote sensing data. A Random Forest (RF) model was generated using GEDI L4B data, Sentinel-1 (S1) and Sentinel-2 (S2) imagery, and a Digital Elevation Model (DEM) to estimate and quantify aboveground biomass density (AGBD). In terms of model efficiency, the S2 infrared bands (B12 and B11) and elevation were the most important variables in the analysis; the results showed an average AGBD density of 241.66 Mg/ha in the area of influence and 241.08 Mg/ha in the concessions. The model's performance showed high efficiency during the training phase ($R^2 = 0.79$), but the validation results indicated overfitting ($R^2 = 0.62$, RMSE = 65.71 Mg/ha, rRMSE = 27.07%). These results indicate that the model is not fully generalizable. Aboveground carbon stocks were estimated at 1,993,370,696.62 MgC for the area of influence and at 155 411 610.95 MgC for the concessions. The average carbon density was 120.54 MgC/ha, a value comparable to that of the area of influence (120.83 MgC/ha). A carbon leakage belt was defined using a fuzzy logic-based multicriteria evaluation analysis, with deforestation and main roads being the factors that contributed most to the risk, and the areas with leakage potential in the area of influence amounting to approximately 400 468 662.72 MgC. The results highlight the importance of *B. excelsa* concessions as carbon reservoirs and the need to implement conservation strategies that can be adopted by policymakers and managers. Finally, while the developed methodology represents a useful tool for monitoring and planning in the REDD+ context, it is necessary to address the model's limitations in order to improve data representativeness and ensure proper validation.

Key words: Biomass, aboveground biomass density, fuzzy logic, multicriteria evaluation.

Índice de contenidos

	Pág.
Dedicatoria.....	
Agradecimientos	
Resumen	
Abstract.....	
Introducción	
CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN	1
1.1 Descripción del problema	1
1.2 Formulación del problema	3
1.2.1 Problema general	3
1.2.2 Problemas específicos	3
1.3 Objetivos de la investigación	4
1.3.1 Objetivo general	4
1.3.2 Objetivos específicos	4
1.4 Variables de la investigación	5
1.4.1 Identificación de variables.....	5
1.5 Operacionalización de variables	5
1.6 Hipótesis	6
1.7 Justificación e importancia	7
1.8 Consideraciones éticas	9
CAPÍTULO II: MARCO TEÓRICO.....	10
2.1 Antecedentes de la investigación	10
2.1.1 Internacionales.....	10

2.1.2 Nacional	15
2.1.3 Local	17
2.2 Base teórica.....	19
2.2.1 Bosque.....	19
2.2.2 Densidad de biomasa aérea.....	20
2.2.3 Reservas de carbono aéreo.....	20
2.2.4 Cinturón de fugas de carbono.....	21
2.2.5 Principios básicos de la teledetección	21
2.2.6 Sensores.....	22
2.2.7 Programa Copernicus	23
2.2.8 Dinámica de Ecosistemas Globales (GEDI)	24
2.2.9 Modelo de elevación digital.....	24
2.2.10 Lógica difusa en teledetección.....	25
2.2.11 Google Earth Engine (GEE).....	25
2.2.11 Random Forest	26
2.3 Definición de términos	26
CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN	28
3.1 Tipo de estudio.....	28
3.2 Diseño del estudio.....	28
3.3 Delimitación espacial y temporal	28
3.4 Población y muestra	30
.....	31
3.5 Método y técnicas	31
3.6 Tratamiento de datos.....	35

3.6.1 Procesamiento de datos	35
3.6.3 Precisión de datos clasificados	50
3.6.4 Análisis estadístico	51
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	53
4.1 Densidad de biomasa aérea mediante un modelo basado en Random Forest en el área de influencia y concesiones de <i>Bertholletia excelsa</i> , Tahuamanu – Madre de Dios.....	53
4.2 Reservas de carbono aéreo en el área de influencia y concesiones de <i>Bertholletia excelsa</i>	62
4.3 Cinturón y fugas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i> Tahuamanu – Madre de Dios.	66
.....	67
CONCLUSIONES	69
SUGERENCIAS.....	71
REFERENCIAS BIBLIOGRÁFICAS	72
ANEXOS.....	89

Índice de Tablas

	Pág.
Tabla 1. Operacionalización de variables	5
Tabla 2. Información de datos de satélite	38
Tabla 3. Análisis Fuzzy (función difusa) de vías principales	41
Tabla 4. Análisis Fuzzy (función difusa) de vías secundarias	42
Tabla 5. Análisis Fuzzy (función difusa) de ríos navegables	43
Tabla 6. Análisis Fuzzy (función difusa) de centros poblados	44
Tabla 7. Análisis Fuzzy (función difusa) del área del proyecto (concesiones de castaña).....	44
Tabla 8. Análisis Fuzzy (función difusa) de concesiones forestales maderables	45
Tabla 9. Análisis Fuzzy (función difusa) de predios agrícolas	46
Tabla 10. Análisis Fuzzy (función difusa) de bosque	46
Tabla 11. Análisis Fuzzy (función difusa) de deforestación	47
Tabla 12. Matriz de comparación por pares (AHP)	48
Tabla 13. Pesos de las variables e índice de consistencia	49
Tabla 14. Biomasa y densidad de biomasa en el área de influencia	58
Tabla 15. Biomasa total y densidad de biomasa en el área del proyecto (concesiones de castaña).....	60
Tabla 16. Carbono y densidad de carbono aéreo en el área de influencia ..	63
Tabla 17. Carbono y densidad de carbono aéreo en el área del proyecto...	64
Tabla 18. Fugas de carbono aéreo en el área de influencia	66

Índice de Figuras

	Pág.
<i>Figura 1.</i> Ubicación de la superficie estudio: área de influencia de concesiones de <i>B. excelsa</i> de la provincia de Tahuamanu.	29
<i>Figura 2.</i> Superposición de huellas GEDI L4B con el área de referencia. ...	31
<i>Figura 3.</i> Imágenes S1; izquierda con polarización VV y derecha con polarización VH.....	38
<i>Figura 4.</i> Imágenes S2; composición R (B12) G (B8) B (B4).	39
<i>Figura 5.</i> Algoritmo de Random Forest (RF).	40
<i>Figura 6.</i> Función difusa de la vía principal.....	42
<i>Figura 7.</i> Función difusa de las vías secundarias.	42
<i>Figura 8.</i> Función difusa de ríos navegables.	43
<i>Figura 9.</i> Función difusa de centros poblados.	44
<i>Figura 10.</i> Función difusa del área del proyecto.	45
<i>Figura 11.</i> Función difusa de concesiones forestales maderables.....	45
<i>Figura 12.</i> Función difusa de predios agrícolas.	46
<i>Figura 13.</i> Función difusa de bosque.....	47
<i>Figura 14.</i> Función difusa de deforestación.	47
<i>Figura 15.</i> Pesos relativos de variables con TerrSet®.....	48
<i>Figura 16.</i> Cinturón de fugas de carbono mediante MCE; posibilidades de movilidad (rojo, con alto potencial; azul, bajo potencial).	50
<i>Figura 17.</i> Posibilidades de movilidad alto (rojo; 0,71 – 0,99).....	50
<i>Figura 18.</i> Importancia de las variables en el modelo RF.	54
<i>Figura 19.</i> Entrenamiento de datos observados y predichos.	55
<i>Figura 20.</i> Validación de datos observados y predichos.	56

<i>Figura 21.</i> Modelo de la AGBD de la fusión de datos GEDI L4B con datos S1, S2 y DEM del área de influencia.....	58
<i>Figura 22.</i> Modelo de la AGBD de la fusión de datos GEDI L4B con datos S1, S2 y DEM del área del proyecto.	61
<i>Figura 23.</i> Densidad de carbono aéreo del área de influencia.....	63
<i>Figura 25.</i> Cinturón y fugas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i>	67

Índice de anexos

	Pág.
Anexo 1. Matriz de consistencia.	90
Anexo 2. Panel fotográfico para establecer lógica difusa y jerarquía analítica.	91

Introducción

Los bosques, que cubren treintauno por ciento de la superficie terrestre mundial, desempeñan un papel fundamental en el ciclo global del carbono. En las últimas dos décadas, los bosques mundiales fueron un sumidero neto de carbono del 7,6 por ciento (Jiao et al. 2023). Estudios previos han demostrado que permitir que los bosques se recuperen de forma natural tiene el potencial de absorber hasta 8 900 millones de toneladas métricas de dióxido de carbono equivalente de la atmósfera cada año hasta 2050, lo que representa casi una cuarta parte de las emisiones globales de combustibles fósiles de la atmósfera cada año (Jiao et al. 2023; Indirabai y Nilsson 2024; Lutz et al. 2024). Para la Amazonia, se estiman que la densidad de biomasa aérea (AGBD) es de 174 toneladas métricas por hectárea (Mg/ha) o, convertida a densidad de carbono, 83,5 Mg/ha (Ngo et al. 2023).

Por lo tanto, los bosques ofrecen importantes beneficios de mitigación del clima, el seguimiento y la gestión de los bosques para el secuestro de carbono ofreciendo la oportunidad de reducir las emisiones de gases de efecto invernadero y estabilizar la temperatura de la Tierra. La información precisa sobre la cubierta forestal, el tipo de bosque y las reservas de carbono son indicadores ecológicos fundamentales para las acciones destinadas a reducir las emisiones derivadas de la deforestación y la degradación forestal (REDD+) (Jiao et al. 2023; Zhao et al. 2024). Para medir la reservas y fugas de carbono, es necesario cuantificar la AGBD de la vegetación como un indicador importante para medir la capacidad de secuestro de carbono de una región y evaluar su balance de carbono (Duncanson et al. 2022; Guo et al. 2023). Debido a que la vegetación fija el CO₂ atmosférico en forma de carbohidratos en los ecosistemas forestales a través de la fotosíntesis (Zhao et al. 2024; El Masri y Xiao 2025), esta capacidad de secuestro de carbono está estrechamente relacionada con la AGBD de la vegetación. Además, las reservas de carbono también se pueden obtener calculando la AGBD de la vegetación en la región (Zhao et al. 2024; El Masri y Xiao 2025). Por lo tanto, la medición precisa de la AGBD de la vegetación es esencial para una mejor comprensión de las funciones ecológicas, el desarrollo de los bosques de *B.*

exce/sa, el ciclo global del carbono y el calentamiento global (Dorado-Roda et al. 2021; Silva et al. 2021; Jiang et al. 2022; Zhao et al. 2024; El Masri y Xiao 2025).

Sin embargo, aunque la AGBD de las mediciones de campo es más precisa, requiere una gran cantidad de tiempo y costos de mano de obra y causa daños al área de estudio, es difícil de usar en estudios de AGBD a gran escala (Tamiminia et al. 2024; Zhao et al. 2024). La teledetección es una técnica eficaz para estimar la AGBD en grandes áreas, que se caracteriza por un gran número de observaciones, una amplia cobertura espacial, múltiples bandas y la capacidad de proporcionar una rica información estructural horizontal (Silva et al. 2019a; Silva et al. 2019b; Dubayah et al. 2020; Duncanson et al. 2020). Algunos estudios han utilizado un modelo de regresión ponderada geográficamente (Duncanson et al. 2020), un modelo de bosque aleatorio (RF) y otros métodos para establecer la relación entre las características de la imagen de teledetección y las muestras de AGBD en el campo, y luego invertir la distribución de AGBD en toda el área cubierta por la imagen (Kacic et al. 2021). Sin embargo, las imágenes de teledetección óptica pasiva no pueden obtener información estructural vertical de los árboles y están limitadas por la influencia de la cobertura de nubes en el momento de la observación (Padalia et al. 2023). Estas limitaciones darían como resultado una precisión generalmente baja de la estimación de AGBD, especialmente en las áreas de vegetación densa con alta biomasa para los espectros de imagen que tienen un fuerte efecto de saturación y tienden a perder sensibilidad (Kacic et al. 2021).

Como método de teledetección activa, el Light Detection and Ranging (LiDAR) espacial puede penetrar el dosel para obtener información estructural tridimensional de la vegetación en áreas densamente vegetadas. El instrumento Global Ecosystem Dynamics Investigation (GEDI), un sistema LiDAR espacial de nueva generación de la NASA, proporciona la primera cobertura global de datos de altimetría 3D de alta resolución destinados específicamente a mapear los bosques de la Tierra (Sothe et al. 2022; Guo et al. 2023; Schwartz et al. 2024). Las mediciones LiDAR de la estructura forestal

vertical son sensibles a una AGBD más alta y tienen poca o ninguna saturación, lo que mejora efectivamente la precisión de la inversión de la altura del dosel de vegetación y la AGBD, y se ha utilizado ampliamente en la estimación de la AGBD en bosques, pastizales y otras áreas grandes (Duncanson et al. 2022; Lang et al. 2022; Guo et al. 2023).

Las aplicaciones de LiDAR para cuantificar la biomasa aérea de los bosques y las reservas de carbono asociadas se han desarrollado en una variedad de resoluciones espaciales, tipos de bosques y ecosistemas (Duncanson et al. 2022; Lang et al. 2022; Guo et al. 2023). En la práctica, los sistemas LiDAR de huella pequeña con retorno discreto y aerotransportado son los más utilizados para la estimación de la biomasa (Duncanson et al. 2022), y proporcionan variables detalladas de la estructura forestal de árboles individuales o de áreas. Aunque esta tecnología ha demostrado su gran capacidad para evaluar la reducción de las emisiones forestales, solo se puede adoptar para áreas pequeñas debido a las limitaciones de disponibilidad de datos. Recientemente, el desarrollo del LiDAR espacial ha proporcionado una nueva solución para el mapeo de reservas de carbono a gran escala y alta frecuencia. Los conjuntos de datos clave que contienen millones de huellas LiDAR que mejoran la capacidad de caracterizar importantes procesos del ciclo del carbono (Bente et al. 2019). Además, los nuevos métodos de observación de la Tierra con múltiples sensores que combinan datos LiDAR espaciales, datos SAR y datos ópticos utilizando técnicas de aprendizaje automático brindan mediciones precisas de la AGBD y el monitoreo de las reservas de carbono para una evaluación de las fugas de emisiones forestales a gran escala, más eficiente y procesable (Shendryk 2022; Guo et al. 2023; Jiao et al. 2023; Indirabai y Nilsson 2024; Lutz et al. 2024; Tamiminia et al. 2024; El Masri y Xiao 2025).

Este estudio explora la utilización de datos de forma de onda GEDI 4B fusionados con Sentinel-1, -2 y modelo de elevación digital para la estimación de la AGBD y reservas de carbono aéreo, así como fugas de carbono aplicando técnicas de lógica difusa en el área de influencia de concesiones de *Bertholletia excelsa* en Tahuamanu, Madre de Dios.

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1 Descripción del problema

Las predicciones precisas de la biomasa aérea son útiles para comparar los atributos estructurales y funcionales del ecosistema forestal (Schneider et al. 2017; Duncanson et al. 2020; Dorado-Roda et al. 2021; Rishmawi et al. 2021; Silva et al. 2021; Jiang et al. 2022). El impacto de la pérdida de carbono debido a la deforestación y la degradación forestal y el efecto de las características funcionales del ecosistema se pueden obtener al comprender los cambios regionales y globales en la AGBD (El Masri y Xiao 2025). La información sobre la distribución espacial de AGBD puede contribuir potencialmente a la gestión forestal, a las investigaciones sobre fuentes y sumideros de carbono, y es fundamental para comprender las implicaciones del cambio climático en la estructura forestal (Jiao et al. 2023; Lutz et al. 2024; Tamiminia et al. 2024; Zhao et al. 2024). Existen varios enfoques para la estimación de AGBD, en los que las mediciones de campo son más precisas, pero es bastante desafiante debido a la falta de disponibilidad de conjuntos de datos adecuados, las localidades variables y las dificultades de accesibilidad (Shendryk 2022; Guo et al. 2023; Indirabai y Nilsson 2024; Zhao et al. 2024).

El uso de la teledetección tiene el potencial de proporcionar estimaciones rentables de la biomasa en comparación con las técnicas tradicionales, que requieren mucho trabajo, son costosas y requieren mucho tiempo (Lutz et al. 2024; El Masri y Xiao 2025). La teledetección también tiene la ventaja de cubrir áreas inaccesibles y podría ser una forma rentable de obtener estimaciones de biomasa en países de la cuenca Amazónica. Varios estudios han estimado el AGBD forestal en la Amazonia utilizando datos satelitales ópticos (Singh et al. 2024) y datos de radar de apertura sintética (SAR) (Ali y Khati 2024).

Algunos estudios han utilizado la combinación de datos ópticos y SAR para la estimación del AGBD (Shendryk 2022; Guo et al. 2023; Jiao et al. 2023; Indirabai y Nilsson 2024). Varios estudios sobre reservorios de carbono, AGBD y densidad de carbono (Indirabai y Nilsson 2024; Lutz et al. 2024; Zhao et al. 2024; El Masri y Xiao 2025) se utilizaron para informes nacionales e internacionales sobre las reservas totales de carbono en Madre de Dios. El LiDAR GEDI espacial es una técnica de teledetección que se puede utilizar para producir mapas con variables forestales estimadas, como el AGBD, en grandes áreas (Shendryk 2022; Guo et al. 2023; Jiao et al. 2023; Ali y Khati 2024). El LiDAR ya se ha utilizado en algunas regiones Amazónicas para recuperar ciertos parámetros estructurales forestales, como la altura del dosel y la AGBD (Silva et al. 2019a; Silva et al. 2019b). Varios estudios demuestran el potencial de utilizar datos de GEDI para estimar la altura de la masa forestal y AGBD (Kacic et al. 2021; Potapov et al. 2021; Silva et al. 2021; Duncanson et al. 2022; Schlund et al. 2022; Huo et al. 2023; Kacic et al. 2023; Ngo et al. 2023; Padalia et al. 2023). GEDI proporciona una densidad de muestreo sin precedentes de las propiedades estructurales de los bosques (Lutz et al. 2024; Zhao et al. 2024; El Masri y Xiao 2025). Se ha demostrado, por ejemplo, que los datos GEDI 4B se pueden utilizar para estimar AGBD a nivel de rodales con un error cuadrático medio (RMSE) inferior a 27,26 % en la Amazonia, pero las estimaciones de AGBD de GEDI fueron generalmente inferiores a las observadas en el campo (Silva et al. 2019a; Duncanson et al. 2020; Kacic y Kuenzer 2022).

Aunque los datos satelitales han ayudado con las estimaciones de biomasa y carbono para la selva amazónica, aún existe una brecha de información para áreas gestionadas bajo los regímenes de productos forestales no maderables (Sabogal et al. 2024). Las concesiones para *B. excelsa*, que son el enfoque del presente estudio, ejemplifican un enfoque de conservación económicamente sostenible que busca mantener la integridad estructural del bosque (Sabogal et al. 2024). Sin embargo, las estimaciones de carbono y la modelización del riesgo de fuga para estas áreas forestales de alta biomasa en Madre de Dios son escasas. Este estudio se centra en estas concesiones

y su área de influencia, ya que son zonas de interfaz críticas donde la presión directa de la deforestación y la degradación del bosque (fuga de carbono) representa una gran amenaza para un recurso económico fundamental y también un importante sumidero de carbono. Al integrar la precisión estructural de GEDI con la cobertura de Sentinel-1 y -2, se deriva una estimación de carbono más robusta y económica que los métodos directos (parcelas de campo o LiDAR aéreo), que son limitados en su aplicación para el monitoreo continuo de estos importantes bosques debido a barreras de accesibilidad y costo (Miguel et al. 2024; Peters et al. 2024).

Este estudio exploró la contribución de datos de forma de onda GEDI 4B fusionados con Sentinel-1, -2 y modelo de elevación digital para la estimación de la AGBD y reservas de carbono aéreo, así como fugas de carbono aplicando técnicas de lógica difusa en el área de influencia de concesiones de *Bertholletia excelsa* en Tahuamanu, Madre de Dios.

1.2 Formulación del problema

1.2.1 Problema general

¿Cuánto son las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa* mediante la fusión de imágenes Sentinel-1, -2, modelo de elevación digital (DEM) y lidar espacial GEDI 4B, Tahuamanu – Madre de Dios en el año 2025?

1.2.2 Problemas específicos

P.E.1 ¿Cuánto es la densidad de biomasa aérea mediante un modelo basado en Random Forest de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y modelo de elevación digital en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios?

P.E.2 ¿Qué cantidad es la densidad de biomasa aérea mediante un modelo basado en Random Forest de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y un DEM en concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios?

- P.E.3 ¿Cuánto son las reservas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios?
- P.E.4 ¿Qué cantidad es la reserva de carbono aéreo en concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios?
- P.E.5 ¿Cuál es el cinturón de fugas de carbono aéreo mediante técnicas de lógica difusa en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios?
- P.E.6 ¿Cuánto son las fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios?

1.3 Objetivos de la investigación

1.3.1 Objetivo general

Estimar las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa* mediante la fusión de imágenes Sentinel-1, -2, modelo de elevación digital y lidar espacial GEDI 4B, Tahuamanu – Madre de Dios, año 2025.

1.3.2 Objetivos específicos

- O.E.1 Determinar la densidad de biomasa aérea mediante un modelo basado en Random Forest de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y modelo de elevación digital (DEM) en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.
- O.E.2 Cuantificar la densidad de biomasa aérea mediante un modelo basado en Random Forest (RF) de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y un DEM en concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.
- O.E.3 Determinar las reservas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.
- O.E.4 Cuantificar las reservas de carbono aéreo en concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.

O.E.5 Determinar el cinturón de fugas de carbono aéreo mediante técnicas de lógica difusa en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.

O.E.6 Estimar las fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.

1.4 Variables de la investigación

1.4.1 Identificación de variables

- ✓ **Variable Dependiente:** Reservas de carbono aéreo y fugas de carbono en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.
- ✓ **Variable Independiente:** Los datos de entrada y el modelo (GEDI, Sentinel-1, -2, DEM, RF, Lógica Difusa) en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.

1.5 Operacionalización de variables

Las variables y su operacionalización de detallan en la Tabla 1.

Tabla 1. *Operacionalización de variables*

Definición conceptual	Definición operacional	Dimensión	Indicadores	Ítems
Variable independiente				
Fusión de datos y modelo RF: La fusión de datos espaciales GEDI 4B con Sentinel-1, -2 y un DEM en un modelo de RF permite cuantificar la densidad de biomasa y carbono aérea en el área de influencia de concesiones de <i>B. excelsa</i> , Tahuamanu – Madre de Dios, año 2025.	Aplicación de datos GEDI L4B, Sentinel-1, Sentinel-2 y DEM.	Algoritmo RF para el modelado.	RF. Densidad de biomasa aérea mínima, máxima y media (Mg/ha). Reservas de carbono aéreo (Mg C/ha).	P.E.1 P.E.2 P.E.3 P.E.4

		Métrica de validación.	Coefficiente de determinación y error cuadrático medio.	
Cinturón de fugas de carbono: El establecimiento del cinturón de fugas de carbono mediante técnicas de lógica difusa permite estimar las fugas de carbono aéreo en el área de influencia de concesiones de <i>B. excelsa</i> , Tahuamanu – Madre de Dios.	Técnica de Lógica Difusa para estimar las fugas de carbono aéreo	Variables de riesgo para fugas de carbono aéreo.	Cinturón de fugas de carbono aéreo. Fugas de carbono aéreo (Mg C/ha).	P.E.5 P.E.6
Variable dependiente				
Biomasa y carbono aéreo: Estimación de la materia orgánica y su contenido de carbono aéreo en el área de influencia de concesiones de <i>B. excelsa</i> , Tahuamanu – Madre de Dios.	Estimación de AGBD mediante el modelo RF y derivación de carbono por factor de conversión.	Densidad de biomasa y reservas de carbono.	Densidad de biomasa aérea mínima, máxima, media (Mg/ha) y reservas de carbono aéreo (Mg C/ha).	P.E.1 P.E.2 P.E.3 P.E.4 P.E.5
Cinturón de fugas de carbono: Riesgo de carbono de ser liberado debido a presiones antrópicas en el área de influencia de concesiones de <i>B. excelsa</i> , Tahuamanu – Madre de Dios.	Estimación del total de carbono contenido en las clases de fuga de alto riesgo según el Análisis MCE.	Fugas de carbono.	Cinturón de fugas de carbono total aéreo (MgC) en zonas de alto riesgo.	P.E.6

1.6 Hipótesis

Hipótesis nula (H₀): La fusión de datos espaciales GEDI 4B con Sentinel-1, -2 y un DEM en un modelo de RF no permite estimar la densidad de biomasa aérea con una precisión definida por un R² de validación superior a 0,60 y un rRMSE inferior a 27,26%, ni las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *B. excelsa*, Tahuamanu – Madre de Dios.

Hipótesis alterna (H₁): La fusión de datos espaciales GEDI 4B con Sentinel-1, -2 y un DEM en un modelo de RF permite estimar la densidad de biomasa aérea con una precisión definida por un R² de validación superior a 0,60 y un rRMSE inferior a 27,26%, ni las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *B. exce/sa*, Tahuamanu – Madre de Dios.

1.7 Justificación e importancia

Los bosques y otras formaciones vegetales proveen servicios ecosistémicos y regulan el clima. Los bosques capturan aproximadamente 2,6 Gt de CO₂ al año mediante la fotosíntesis y el crecimiento de los árboles en todo el mundo. La densidad de biomasa aérea (AGBD) en la Amazonia es de 174 toneladas métricas por hectárea (Mg/ha), equivalente a 83,5 Mg/ha de carbono. Los bosques amortiguan las temperaturas microclimáticas, apoyan la biodiversidad e influyen en los regímenes de perturbación. Se espera que el cambio climático antropogénico reduzca la diversidad y salud de la vegetación, alterando la dinámica del carbono a través de eventos como incendios forestales más frecuentes y graves. La futura gestión forestal requiere una cuantificación precisa de carbono existente, estimaciones de degradación de vegetación y cambios cartográficos en tipos funcionales de plantas debido al empeoramiento del cambio climático y sus impactos en la biodiversidad. Para garantizar la integridad de los créditos de carbono en los mercados nacionales e internacionales, los mercados de carbono necesitan estimaciones precisas de la línea de base de carbono. La confianza en el mercado que ofrece oportunidades de desarrollo sostenible se ve socavada por un seguimiento inadecuado de las reservas de carbono. Las estimaciones del carbono almacenado a escala del paisaje regional siguen siendo considerablemente inciertas.

Las estimaciones de AGBD tradicionalmente se obtienen de mediciones de campo costosas en tiempo y recursos, que son un reto logístico y se limitan a nivel de árbol o parcela. La tala de los árboles afectados es necesaria en el

muestreo destructivo para obtener estimaciones precisas. Los modelos alométricos estadísticos pueden limitar su aplicabilidad en grandes regiones debido a la naturaleza específica del lugar o de la especie. Se han utilizado técnicas de muestreo de campo no destructivas. Los métodos no destructivos incluyen mediciones indirectas de AGBD a través de LiDAR terrestre y aéreo, como drones, para caracterizar estructuras forestales tridimensionales. Los sensores LiDAR terrestres y aéreos producen estimaciones precisas, pero sus costes operativos elevados a menudo hacen que la cobertura regional no sea rentable.

Los métodos de teledetección son utilizados para caracterizar la estructura forestal a gran escala y evaluar la biomasa de los bosques de manera rentable. Esto permite supervisar los cambios de la vegetación con el clima. Se han utilizado varios sensores para cartografiar el AGBD en todo el mundo, incluyendo sensores multiespectrales pasivos, el radar de apertura sintética (SAR) y el LiDAR espacial. La fusión de sensores activos y pasivos mejora la precisión de la estructura de la vegetación y la caracterización de la biomasa, debido a las fortalezas y limitaciones únicas de cada fuente de datos, como han demostrado estudios anteriores. Los sensores ópticos pasivos como Sentinel-2 y Landsat detectan atributos bioquímicos de la vegetación a través de la reflectancia de la superficie. Los índices espectrales de los multiespectrales pueden detectar atributos de la vegetación como la biomasa verde, la densidad y la arquitectura del dosel a través de la fotosíntesis. Las bandas adicionales de borde rojo captan el estrés o el crecimiento de las plantas al ser sensibles a la clorofila.

La serie temporal más completa de datos de observación de la Tierra es proporcionada por los datos multiespectrales de Landsat. Landsat y Sentinel-2 son sensibles a la nubosidad. Sentinel-1 es un sensor SAR activo capaz de penetrar las nubes y algunas copas de árboles. Por el contrario. Los instrumentos SAR como Sentinel-1 emiten señales de microondas para determinar la estructura de la vegetación mediante la dispersión de las señales de eco de retorno.

Los sensores Landsat, Sentinel-2 y Sentinel-1 subestiman la biomasa en bosques densos y sobrestiman en bosques abiertos dispersos. El LiDAR espacial mejora la cartografía de ecosistemas a escala regional y mundial. El GEDI de la NASA es el primer LiDAR espacial dedicado al seguimiento de la estructura vertical de la vegetación, capaz de penetrar hasta el 99% de la cubierta de copas. En bosques densos, la estimación de AGBD suele ser incierta. Una capacidad técnica mejorada permite una cartografía más precisa y generalizada de AGBD y de la estructura de la vegetación. La utilización de GEDI para estimar la AGBD mejora la precisión de la cartografía de la vegetación a escala regional y, por ende, las reservas de carbono.

1.8 Consideraciones éticas

La tecnología de teledetección posee la capacidad de capturar con rapidez el estado de crecimiento de la vegetación en gran magnitud, lo que ofrece una referencia efectiva para el monitoreo y la administración de los recursos forestales. La obtención de datos acerca de la vegetación mediante la combinación de imágenes ópticas y radar con la tecnología GEDI se ha transformado en un método eficaz y común para determinar la densidad de biomasa, las reservas y las fugas de carbono aéreo. En este contexto, el estudio se enmarcó en el Reglamento de Grados y Títulos de la UNAMAD, asimismo, estuvo respaldado y orientado de manera especializada por el Centro de Teledetección para el Estudio y Gestión de los Recursos Naturales (CETEGERN) de la UNAMAD, donde los tesisistas se ajustaron a las directrices y protocolos establecidos.

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de la investigación

2.1.1 Internacionales

Ali y Khati (2024) estudiaron la AGBD del bosque para estimar el almacenamiento de carbono terrestre, el ciclo del carbono y el cambio climático. Los algoritmos basados en aprendizaje automático se pueden aplicar para estimar la AGBD del bosque utilizando datos basados en teledetección. El estudio utilizó datos del radar de apertura sintética (SAR) ALOS-2/PALSAR-2 de banda L en combinación con regresión lineal multiparamétrica (LR) y regresión de bosque aleatorio (RF) para la estimación del carbono forestal. En este estudio se utilizan seis adquisiciones totalmente polarimétricas de banda L. Los parámetros de entrada del algoritmo RF son la retrodispersión, las potencias de descomposición y la información de las especies. Se utilizó la retrodispersión multitemporal (HH1 a HH6, HV1 a HV6, VV1 a VV6) y el promedio temporal. Además, se utilizaron los parámetros de descomposición promedio de la descomposición G4U: rebote doble (Dbl), rebote impar (Odd), dispersión de volumen (Vol) y dispersión de hélice (Hlx) para las seis fechas. En el primer caso (1), el modelo se entrena para estimar únicamente la AGBD. En el segundo caso (2), el modelo se entrena para estimar la altura del bosque. En el tercer caso (3), el modelo se entrena para predecir tanto la AGBD como la altura del bosque. A diferencia del método LR, existe una mejora significativa en la estimación de la AGBD lograda con los algoritmos RF. Este estudio muestra el potencial de la recuperación combinada de la AGBD y la altura del bosque utilizando datos de retrodispersión de banda L de series temporales.

Indirabai y Nilsson (2024) cuantificaron la AGBD y su distribución espacial puede contribuir significativamente a monitorear las reservas de carbono, así como la dinámica del almacenamiento de carbono en los bosques. Para un monitoreo y manejo forestal efectivo en el caso de los bosques tropicales complejos de la India, existe la necesidad de obtener estimaciones confiables de la cantidad de secuestro de carbono a nivel regional y nacional, pero la estimación de la biomasa es bastante desafiante. El objetivo principal del estudio fue validar la utilidad de las estimaciones de AGBD en cuadrícula (ton/ha) de los datos de la Investigación de Dinámica de Ecosistemas Globales LiDAR (GEDI L4B, Versión 2) en dos bosques tropicales heterogéneos en la India, los bosques de Betul y Mudumalai. La metodología incluye, para cada área forestal, un modelo de regresión lineal que predice AGBD a partir de datos MSI de Sentinel-2 que se desarrollaron utilizando datos de referencia terrestres y comparándolos con los valores de AGBD de GEDI. El modelo AGBD para los bosques Betul en la India central tuvo un RMSE de 13,9 ton/ha, RMSE relativo = 8,7% y un R^2 de 0,88, con un sesgo de -0,28 ton/ha, y una comparación entre AGBD modelada y AGBD en cuadrícula GEDI a una resolución de 1 km muestra una correlación relativamente fuerte (0,66) y poco o ningún sesgo. También encontró que el valor de la huella AGBD de GEDI está subestimado en comparación con el AGBD según el modelo Sentinel-2. Para el bosque Mudumalai en el sur de la India, el modelo AGBD tuvo un RMSE de 29,1 ton/ha, RMSE relativo = 10,8% y un R^2 de 0,79 y un sesgo de -0,022. La correlación entre AGBD modelada y AGBD en cuadrícula GEDI fue de 0,84, y GEDI AGBD está subestimado en comparación con AGBD del modelo Sentinel-2. Los valores de campo de AGBD de Betul se encuentran entre 42,2 ton/ha y 238,8 ton/ha y para los bosques de Mudumalai, el AGBD se encuentra entre 75,9 ton/ha y 353,6 ton/ha. Los resultados indican que el AGBD en cuadrícula de GEDI subestima el AGBD y que el modelo utilizado para producir el producto AGBD en cuadrícula necesita ser ajustado para proporcionar información confiable sobre el balance de carbono y sus cambios a lo largo del tiempo para el tipo de bosques indios que existen en las dos áreas de prueba.

Lutz et al. (2024) estudiaron el uso del producto de altura del dosel GEDI para predecir AGBD leñosa en cinco tipos de vegetación en Australia Occidental: bosques altos de eucaliptos, bosques abiertos de eucaliptos, brezales bajos, sabanas tropicales de eucaliptos y pastizales de matas y montículos. Los modelos de altura del dosel se desarrollaron utilizando regresiones forestales aleatorias entrenadas en datos de puntos discretos de altura del dosel GEDI. Las variables predictoras incluyeron bandas espectrales e índices de vegetación derivados de datos de radar de apertura sintética Sentinel-1 y datos multiespectrales Landsat y Sentinel-2. AGBD se estimó posteriormente utilizando modelos de ley de potencia derivados relacionando las alturas de dosel previstas con parcelas AGBD de campo. El mapeo se realizó para 2020 y 2021. La precisión de las predicciones de la altura del dosel varió con los cuantiles de altura; los modelos subestimaron la altura de los árboles más altos y sobreestimaron la altura de los árboles más pequeños. Se observó una tendencia similar de subestimación y sobreestimación para las estimaciones de AGBD. La reserva media de carbono se estimó en $69,0 \pm 12,0$ MgCha⁻¹ en los bosques altos de eucaliptos de la región de Warren; $33,8 \pm 5,0$ MgCha⁻¹ para los bosques abiertos de eucaliptos en la región de South Jarrah; $7,1 \pm 1,4$ MgCha⁻¹ para los brezales y matorrales de la región de las llanuras arenosas de Geraldton; $43,9 \pm 4,9$ MgCha⁻¹ para la sabana de eucaliptos de Kimberley; y $3,9 \pm 1,0$ MgCha⁻¹ para los pastizales de la sabana de Kimberley. Este enfoque proporciona un marco útil para el desarrollo futuro de este proceso para la gestión de incendios y el seguimiento de la salud del hábitat.

Zhao et al. (2024) Estimaron la precisión de la AGBD de la vegetación en áreas urbanizadas es esencial para los servicios ecosistémicos urbanos. GEDI de la NASA puede obtener una estructura precisa de la vegetación terrestre, lo que resulta muy útil para la estimación de la AGBD en grandes áreas forestadas. Sin embargo, la heterogeneidad espacial y la escasa distribución de la vegetación en áreas urbanas generan una gran incertidumbre en la estimación de la AGBD. El estudio propuso un método para estimar las alturas de la vegetación fusionando las observaciones láser

de GEDI con características extraídas de imágenes ópticas. GEDI se utilizó para extraer la altura precisa del dosel de vegetación, y las imágenes ópticas se utilizan para compensar la incoherencia espacial de GEDI. La correlación entre las alturas discretas de la vegetación de las observaciones de GEDI y las características de la imagen se construyeron utilizando RF para obtener las alturas del dosel de vegetación en todas las áreas vegetadas, estimando así la AGBD. Los resultados en Xuzhou, China, utilizando observaciones GEDI y características de imágenes de los satélites Sentinel-2 y Landsat-8 indicaron que: (1) El método de combinar datos de observación láser GEDI con imágenes ópticas es eficaz para estimar AGBD, y su precisión de estimación ($R^2 = 0,58$) es mayor que la de usar solo imágenes ópticas ($R^2 = 0,45$). (2) El AGBD total en la región de vegetación más corta es mayor que los otros dos en el bosque latifoliado y el bosque de coníferas, pero el AGBD por unidad de área es el más bajo en el área de vegetación más corta a 33,60 Mg/ha, y es el más alto en el bosque de coníferas a 46,60 Mg/ha. Y el AGBD promedio más alto ocurre en octubre-diciembre a 59,55 Mg/ha en Xuzhou. (3) La banda del infrarrojo cercano tiene una mayor influencia en el AGBD invertido, seguido de las características texturales.

dos Reis et al. (2023) evaluaron la sostenibilidad de los sistemas agrícolas en los contextos económicos, ambientales y sociales complejas e intercambiables, los cuales requiere de enfoques de análisis de decisiones con múltiples criterios. Se han propuesto varios modelos para evaluar la sostenibilidad agrícola considerando estas cuestiones, basados, por ejemplo, en programas de toma de decisiones de atributos múltiples o sistemas de interferencia difusa. Sin embargo, identificaron una falta de modelos integrales aplicables a condiciones agrícolas generales en diferentes entornos y contextos socioeconómicos. Para llenar este vacío, propusieron un nuevo modelo de lógica difusa basado en indicadores para evaluar la sostenibilidad de los sistemas agrícolas. Para probar la idoneidad del modelo, realizaron veintidós estudios de caso durante la temporada de cultivo 2018/19 en la región de la frontera agrícola-forestal brasileña; las granjas elegidas representan los tres sistemas agrícolas más comunes allí: (i) agricultura de

cultivo puro (rotación de cultivos únicamente: soja - maíz), (ii) ganadería pura y (iii) agricultura integrada (cultivo - ganadería y ganadería - bosque). Se construyeron indicadores parciales para evaluar el desempeño económico, ambiental y social de esos sistemas agrícolas, luego se integraron en un índice de sostenibilidad. Los resultados muestran un desempeño más alto y más equilibrado para las granjas integradas, que mostraron los valores más altos del índice de sostenibilidad.

Guo et al. (2023) evaluaron la AGBD como indicador clave para evaluar la productividad de los ecosistemas forestales. En este estudio, desarrollaron un nuevo enfoque para integrar datos de medición de campo, GEDI LiDAR, Sentinel y datos de terreno para construir modelos de AGBD forestales basados en datos de múltiples fuentes con una resolución de 30 m. Primero, emplearon el método RFE-SVM (eliminación recursiva de características-máquina de vectores de soporte) para determinar las características sensibles a la AGBD. Segundo, utilizaron tres modelos de regresión para construir el modelo CMH como base para la estimación de la AGBD. Tercero, seleccionaron conjuntamente las características y los datos de medición de campo para construir un modelo para estimar la AGBD. Los modelos de AGBD, evaluados dentro del área de estudio, alcanzaron valores R^2 de 0,89. Cuarto, realizaron pruebas de transferibilidad para el modelo AGBD. El modelo AGBD construido con base en datos del área de estudio se aplicó a otras tres áreas de prueba, lo que dio como resultado valores R^2 de 0,66, 0,76 y 0,91, respectivamente. En general, este estudio presentó un método que utiliza datos abiertos extensos con gran potencial para mapear AGBD forestales en áreas extensas.

Kacic et al. (2023) evaluaron a través de productos y análisis fundamentados en datos de GEDI, Sentinel-1 y Sentinel-2. La evaluación de la AGBD muestra una reducción constante en Alemania desde el año 2017 (equivalente a aproximadamente 200 Mg/ha) hasta el año 2022 (equivalente a aproximadamente 165 Mg/ha).

Shendryk (2022) analizaron una metodología para generar mapas de AGBD de pared a pared que se basa exclusivamente en datos de observación de la

Tierra (EO) de acceso abierto. GEDI aerotransportados se fusionaron con el radar de apertura sintética Sentinel-1, datos multiespectrales, de elevación y de cobertura terrestre de Sentinel-2 para producir mapas de biomasa de Australia y los Estados Unidos para 2020. El marco de aprendizaje automático de refuerzo de gradiente se aplicó para predecir AGBD y su incertidumbre en las resoluciones de 100 m y 200 m. Se comparó el rendimiento de los modelos basados en (1) imágenes y cobertura terrestre de Sentinel-2 y (2) una combinación de imágenes de Sentinel-2 y Sentinel-1 con datos de elevación y cobertura terrestre. El modelo de refuerzo de gradiente más preciso se identificó utilizando una optimización de hiperparámetros bayesianos con una validación cruzada de 5 veces. El análisis de imágenes de Sentinel-2 y datos de cobertura terrestre resultó en AGBD estimado con el coeficiente de determinación (R^2) de 0,61 – 0,71, error cuadrático medio ($RMSE$) de 59 – 86 Mg/ha y error cuadrático medio relativo ($RMSE\%$) de 45 – 80%. La precisión de los modelos mejoró con la adición de Sentinel-1 y datos de elevación: estimación de AGBD con R^2 de 0,66 – 0,74, $RMSE$ de 55 – 81 Mg/ha y $RMSE\%$ de 41 – 77%. Se encontró que Sentinel-2 y los predictores derivados de la cobertura terrestre fueron los más importantes para estimar AGBD anual. El método propuesto también redujo el efecto de saturación, que es común en áreas con alta biomasa cuando se pronostica AGBD usando imágenes satelitales. Los mapas de predicción producidos en este estudio podrían servir como base para las existencias actuales de AGBD de tierras forestales equivalentes a 9,8 Pg y 37,1 Pg en Australia y los Estados Unidos, respectivamente. En general, esta investigación destaca las oportunidades metodológicas para combinar datos de EO de acceso abierto para producir mapas de AGBD más precisos y aplicables a nivel mundial a través de la fusión de datos.

2.1.2 Nacional

Programa-MAAP (2025) en su informe carbono almacenado en la Amazonía peruana: últimos datos y desafíos para su conservación, tiene como objetivo evaluar el stock total de carbono sobre y debajo del suelo en la Amazonía

peruana, priorizando la identificación de zonas más críticas para su conservación. Utilizando imágenes satelitales y modelos espaciales sofisticados, cuantifican los reservorios de carbono, estimando una pronunciada concentración al suroeste de la Amazonía, particularmente en Madre de Dios, Cusco y Ucayali, y en la Amazonía nororiental. Los resultados indican que la región almacena sobre el suelo aproximadamente 56,8 mil millones de toneladas métricas de carbono y un total de 71,5 mil millones de toneladas incluyendo debajo del suelo, con 27,8 millones de hectáreas de nivel máximo de carbono, aunque el 39% de estas áreas es altamente vulnerable a carencias de protección, particularmente en concesiones forestales y tierras no asignadas. El informe concluye afirmando que la Amazonía peruana, a pesar de seguir considerada como un sumidero carbonífero crítico, se encuentra a riesgo, exponiéndose a constantes amenazas como la deforestación y el cambio climático, por lo que es fundamental y urgente reforzar la política de protección con seguimiento activo y control de estos carbonos para impedir que la zona se convierta en emisor neto de gases de efecto invernadero.

Csillik y Asner (2020) estimaron las emisiones de carbono sobre el suelo en tiempo casi real en Perú. El estudio presenta el seguimiento más detallado del carbono aéreo a lo largo del tiempo, con estimaciones anuales, trimestrales y mensuales de las emisiones mediante el método de diferencia de reservas, enmascaradas por la capa de pérdida forestal de Global Forest Watch. Generaron un monitoreo de alta resolución espacial (1 ha) de la densidad de carbono aéreo (DCA) y las emisiones (ECA) de carbono aéreo en Perú, incorporando cientos de miles de imágenes satelitales Planet Dove, radar S1, datos topográficos y LiDAR aerotransportado, integrados en un flujo de trabajo de regresión de aprendizaje profundo mediante computación de alto rendimiento. Se obtuvieron resultados de DCA consistentes para todos los trimestres y meses analizados, con valores de R^2 de 0,75 a 0,78 y errores cuadráticos medios (RMSE) entre 20,6 y 22,0 Mg C ha⁻¹. Se estimó un total de 7,138 Pg C para Perú, con una pérdida anual de carbono (ACE) de 20,08 Tg C entre el tercer trimestre de 2017 y el de 2018, respectivamente, lo que

representa un 23,4 % más que las estimaciones de la Evaluación Mundial de los Recursos Forestales de la FAO. El análisis trimestral de la evolución espacial de la ACE reveló pérdidas de 11,5 Tg C, 6,6 Tg C, 8,6 Tg C y 10,1 Tg C entre el tercer trimestre de 2017 y el de 2018. Además, el análisis mensual para la estación seca revela la evolución de la ACE con un nivel de detalle temporal sin precedentes. Se discuten los factores ambientales que influyen en la ACE y se proporciona una herramienta espacialmente explícita para una gestión mejorada del carbono forestal a gran escala.

Quesada et al. (2010) estudiaron la variación en la biomasa y el carbono almacenado en los bosques primarios de la Amazonía peruana, en donde realizaron un análisis geoespacial de la biomasa aérea y el stock de carbono en diferentes tipos de bosques amazónicos en Perú. La metodología propuso la realización de inventarios forestales detallados y la aplicación de ecuaciones alométricas para la estimación de biomasa y carbono en parcelas representativas de diferentes tipos de vegetación. Los resultados indican que la biomasa aérea, que excede las 300 Mg/ha, es extremadamente heterogénea y el carbono almacenado también es altamente heterogéneo para un tipo y estructura de bosque determinados, confirmando la ascendencia de estas áreas como sumideros de carbono. La conclusión más importante es que la heterogeneidad ecológica y estructural de los bosques amazónicos determina su stock de carbono. Esta es la percepción necesaria para formular políticas prácticas de conservación y manejo sostenible de la silvicultura en la región.

2.1.3 Local

El informe del Programa-MAAP (2024) sobre el sistema MAAP del Programa Madre de Dios, que abarca desde 2019 hasta 2023, indica que las comunidades nativas de Barranco Chico, Puerto Luz y San José de Karene en la provincia de Manu, se estiman que contienen 9 millones de toneladas métricas de biomasa aérea y una densidad de carbono de 102 toneladas por hectárea. Esto se basa en la evaluación de biomasa aérea y datos de GEDI L4B, aplicando el criterio científico de que el 48% de la biomasa aérea es

carbono. La deforestación minera en la región ha liberado millones de toneladas de carbono debido a la pérdida de bosques, lo que representa una amenaza para la capacidad de Madre de Dios como sumidero de carbono en la Amazonía peruana. El informe también indica que el 76% de la deforestación minera reciente ocurre dentro del Corredor Minero, y el resto impacta en tierras de conservación y territorios indígenas, incluyendo la Reserva Nacional Tambopata.

El estudio de W.W.F. (2013) sobre la estimación del carbono en la biomasa aérea de los bosques de Madre de Dios, es un trabajo en conjunto de WWF-Perú con la Universidad de Leeds y la Mesa de Servicios Ambientales y REDD+ (MSAR) de Madre de Dios, con el objetivo de determinar la cantidad de carbono que se encuentra en la biomasa aérea de una de las zonas más importantes de la Amazonía en relación a biodiversidad y comunidades indígenas. Usando datos de campo de más de 600 parcelas que representan varios tipos de vegetación, se aplicó un conjunto de ecuaciones alométricas de biomasa y carbono del IPCC siguiendo las Directrices de Buenas Prácticas del IPCC. El estudio encontró que Madre de Dios promedia 114 toneladas de carbono por hectárea y almacena cerca de 0.97 petagramos de carbono en sus bosques, pero también alertó sobre la creciente deforestación agravada por la agricultura, ganadería, minería ilegal y obras de infraestructura. El estudio, por lo tanto, subraya la implementación de buenas prácticas de manejo de las áreas deforestadas a fin de reducir las emisiones de carbono globales, ya que la deforestación desenfrenada es uno de los mayores contribuyentes a las emisiones de gases de efecto invernadero.

Asner et al. (2010) evaluaron las reservas de carbono forestal y emisiones de alta resolución en la Amazonía de Madre de Dios. Mediante el uso integrado de imágenes satelitales, detección y alcance de luz aerotransportada y parcelas de campo, mapearon las reservas y emisiones de carbono sobre el suelo con una resolución de 0,1 ha en 4,3 millones de ha. Descubrieron las variaciones previamente desconocidas en el almacenamiento de carbono a múltiples escalas, según el sustrato geológico y el tipo de bosque. De 1999 a 2009, las emisiones derivadas del uso de la tierra representaron el 1,1 % del

carbono presente en toda la región, lo que se deduce un almacenamiento de carbono de alrededor de $128 \pm 14 \text{ Mg C ha}^{-1}$, indicando una alta densidad de carbono por hectárea en esta región amazónica. La degradación forestal, como la causada por la tala selectiva, incrementó las emisiones regionales de carbono en un 47 % con respecto a la deforestación por sí sola, estimándose que un área de 23,613 ha afectadas por minería de oro (2017), se liberaron aproximadamente 1,12 millones de toneladas métricas de carbono a la atmósfera debido a la deforestación y degradación forestal relacionada. Sin embargo, la regeneración secundaria compensó en un 18 % las emisiones brutas totales. La monitorización de muy alta resolución reduce la incertidumbre en las emisiones de carbono para los programas REDD al tiempo que revela controles ambientales fundamentales sobre el almacenamiento de carbono forestal y sus interacciones con el cambio de uso de la tierra.

2.2 Base teórica

2.2.1 Bosque

Los bosques se ven, definen, evalúan y valoran desde diferentes perspectivas. Desde diferentes puntos de vista, los bosques pueden considerarse una fuente de productos madereros, un ecosistema compuesto de árboles junto con una miríada de formas de diversidad biológica, un hogar para los pueblos indígenas, un depósito para el almacenamiento de carbono, una fuente de múltiples servicios ecosistémicos y como sistemas socioecológicos, o como todo lo anterior. Además, existe una distinción fundamental y comúnmente mal entendida entre las características reales de la tierra y su designación legal. Desde la perspectiva de la “cobertura terrestre”, los bosques se consideran ecosistemas o tipos de vegetación que sustentan conjuntos únicos de plantas y animales. Pero desde la perspectiva del “uso de la tierra”, los bosques son propiedades que están legalmente designadas como bosques, independientemente de su vegetación actual. Dentro de este concepto, un “bosque” legalmente designado puede en realidad estar desprovisto de árboles, al menos temporalmente. Ninguna

definición operativa única de bosque puede, o debe, incorporar todas estas dimensiones (Whitmore y Burnham 1975; FAO 2012; Chazdon et al. 2016).

2.2.2 Densidad de biomasa aérea

Se define como la masa seca de materia viva o muerta de formas de vida de árboles o arbustos (plantas leñosas), expresada típicamente como una densidad por área (por ejemplo, Mg de biomasa aérea por hectárea). Por lo tanto, esto no incluye la biomasa no leñosa o subterránea. Cuando se habla de la biomasa total de un árbol o parcela individual (no de la densidad), la definición es biomasa aérea (AGBD), mientras que, para las densidades a nivel de parcela o píxel, como se estima comúnmente en los productos mapeados, la definición es densidad de biomasa aérea, generalmente por hectárea (AGBD/ha). Bajo el suelo, los restos leñosos o la biomasa no leñosa también son componentes importantes del ciclo del carbono, pero los primeros no son directamente detectables desde los satélites de Observación de la Tierra (EO) (Ma et al. 2024).

2.2.3 Reservas de carbono aéreo

Una reserva de carbono, o depósito de carbono, es un sistema que tiene la capacidad de almacenar o liberar carbono. Un flujo de carbono se refiere a la cantidad de carbono intercambiada entre reservas de carbono durante un período de tiempo específico. En términos simples, es el movimiento de carbono entre la tierra, los océanos, la atmósfera y los seres vivos. En esta descripción general se describen los mecanismos detrás de las reservas y los flujos de carbono y se destaca su impacto en el carbono forestal (Mélières y Maréchal 2015).

Un flujo de carbono representa la transferencia de carbono entre reservas de carbono, también conocidas como depósitos de carbono. Los flujos ocurren de manera natural en todos los ecosistemas funcionales, incluidos los bosques. Sin embargo, debido a las perturbaciones relacionadas con el cambio climático, los flujos de carbono positivos (almacenamiento neto anual de vegetación) podrían disminuir y eventualmente volverse negativos. Con el tiempo, el sumidero de carbono de la vegetación podría disminuir o aumentar,

lo que demuestra la importancia de trabajar para proteger y restaurar los bosques globales, ya que son un contribuyente clave a los esfuerzos de mitigación de GEI para combatir el cambio climático. Esto subraya la importancia de los bosques y los árboles como reservas clave de carbono que deben protegerse (Mélières y Maréchal 2015).

2.2.4 Cinturón de fugas de carbono

Las fugas se definen como el aumento neto de las emisiones antropogénicas de GEI que se produce fuera de los límites del proyecto, y que puede medirse y es directamente atribuible a las actividades del proyecto. Las emisiones de fuga deben deducirse de las reducciones de emisiones generadas por el proyecto para determinar sus beneficios netos de carbono, en base a los cuales se emiten los créditos de carbono (Lagouvardou y Psaraftis 2022).

2.2.5 Principios básicos de la teledetección

La teledetección, también llamada observación de la Tierra, se refiere a la obtención de información sobre objetos o áreas en la superficie de la Tierra sin estar en contacto directo con el objeto o área. Los principios son:

- ✓ La detección y discriminación de objetos o características de la superficie significa detectar y registrar la energía radiante reflejada o emitida por objetos o material de la superficie.
- ✓ Distintos objetos devuelven distintas cantidades de energía en distintas bandas del espectro electromagnético que incide sobre ellos.
- ✓ Esto depende de la propiedad del material (estructural, química y física), la rugosidad de la superficie, el ángulo de incidencia, la intensidad y la longitud de onda de la energía radiante.
- ✓ La teledetección es básicamente una ciencia multidisciplinaria que incluye una combinación de varias disciplinas como la óptica, la espectroscopia, la fotografía, la informática, la electrónica y las telecomunicaciones, el lanzamiento de satélites, etc.

- ✓ Todas estas tecnologías se integran para actuar como un sistema completo en sí mismo, conocido como Sistema de Teledetección.
- ✓ Hay una serie de etapas en un proceso de teledetección, y cada una de ellas es importante para una operación exitosa.

En cuanto a las etapas, estas son:

- ✓ Emisión de radiación electromagnética, o EMR (emisión solar/autoemisión)
- ✓ Transmisión de energía desde la fuente hasta la superficie de la tierra, así como absorción y dispersión.
- ✓ Interacción de la radiación electromagnética con la superficie terrestre: reflexión y emisión • Transmisión de energía desde la superficie hasta el sensor remoto
- ✓ Salida de datos del sensor
- ✓ Transmisión, procesamiento y análisis de datos (Anji-Reddy 2010).

2.2.6 Sensores

Los sensores remotos recogen datos detectando la energía que se refleja desde la Tierra. Estos sensores pueden estar en satélites o montados en aeronaves (Anji-Reddy 2010; Chuvieco 2016).

Los sensores remotos pueden ser pasivos o activos. Los sensores pasivos responden a estímulos externos. Registran la energía natural que se refleja o emite desde la superficie de la Tierra. La fuente de radiación más común detectada por los sensores pasivos es la luz solar reflejada (Anji-Reddy 2010; Chuvieco 2016).

En cambio, los sensores activos utilizan estímulos internos para recopilar datos sobre la Tierra. Por ejemplo, un sistema de teledetección por rayo láser proyecta un láser sobre la superficie de la Tierra y mide el tiempo que tarda el láser en reflejarse de nuevo en su sensor (Anji-Reddy 2010; Chuvieco 2016).

2.2.7 Programa Copernicus

Copernicus es el componente de observación de la Tierra del programa espacial de la Unión Europea. Proporciona información precisa, oportuna y de fácil acceso para mejorar la gestión del medio ambiente, comprender y mitigar los efectos del cambio climático y garantizar la seguridad civil (Anji-Reddy 2010; Chuvieco 2016; Lulla et al. 2021).

Esta iniciativa está liderada por la Comisión Europea (CE) en colaboración con la Agencia Espacial Europea (ESA). La ESA coordina la entrega de datos desde más de 30 satélites. La CE, en nombre de la Unión Europea, es responsable de la iniciativa general, de establecer los requisitos y de gestionar los servicios (Anji-Reddy 2010; Chuvieco 2016; Lulla et al. 2021).

Los Sentinels son una flota de satélites de la Agencia Espacial Europea (ESA) diseñados para adquirir mediciones de múltiples tipos de sensores que proporcionarán la información necesaria para cumplir con los objetivos del programa Copernicus de Europa (Anji-Reddy 2010; Chuvieco 2016; Lulla et al. 2021).

Sentinel-1: La primera misión de la serie, la constelación Sentinel-1, incluye satélites gemelos que llevan cada uno un radar de apertura sintética (SAR) de banda C y juntos proporcionan imágenes de la superficie de la Tierra en cualquier condición climática, día y noche. Sentinel-1A se lanzó el 3 de abril de 2014 y Sentinel-1B el 25 de abril de 2016. Orbitan a 180° de distancia entre sí, y juntos toman imágenes de la Tierra cada seis días (Potin 2013).

Sentinel-2: Es una misión europea de obtención de imágenes multiespectrales de alta resolución y amplia franja de cobertura. La especificación completa de la misión, que consta de dos satélites que vuelan en la misma órbita, pero con una fase de 180°, está diseñada para ofrecer una alta frecuencia de revisita de cinco días en el Ecuador. Sentinel-2 lleva un instrumento óptico que muestrea 13 bandas espectrales: cuatro bandas a 10 m, seis bandas a 20 m y tres bandas a 60 m de resolución espacial. El ancho de la franja orbital es de 290 km (Frampton et al. 2013).

2.2.8 Dinámica de Ecosistemas Globales (GEDI)

GEDI pretende caracterizar la estructura y dinámica de los ecosistemas para permitir una cuantificación y comprensión radicalmente mejoradas del ciclo del carbono y la biodiversidad de la Tierra (Dubayah et al. 2020).

Entre los productos, el L4B proporciona estimaciones de 1 km x 1 km (1 km, en adelante) de la densidad media de biomasa aérea (AGBD) basadas en observaciones de la semana 19 de la misión, que comenzó el 18 de abril de 2019, hasta la semana 138 de la misión, que finalizó el 4 de agosto de 2021. Sin embargo, se prevé su continuación en 2024 hasta 2030 (Dubayah et al. 2020).

El producto de biomasa de huella de GEDI L4A convierte cada forma de onda de alta calidad en una predicción de AGBD, y el producto L4B utiliza la muestra presente dentro de los límites de cada celda de 1 km para inferir estadísticamente la AGBD media. El procedimiento de cuadrículado se describe en el Documento de base teórica del algoritmo GEDI L4B (ATBD). Patterson et al. (2019) describe el modo de inferencia basado en modelos híbridos utilizado en el producto L4B. Las estimaciones correspondientes de 1 km del error estándar de la media también se proporcionan en el producto L4B. La incertidumbre se debe tanto al muestreo de GEDI de un área de 1 km (en lugar de realizar observaciones de pared a pared) como al hecho de que los valores de biomasa de L4A se modelan en un proceso sujeto a errores en lugar de medirse en un proceso que se puede suponer que está libre de errores (Dubayah et al. 2020). Los datos y los archivos complementarios se pueden descargar de la siguiente dirección web: https://daac.ornl.gov/cgi-bin/dsvviewer.pl?ds_id=2017.

2.2.9 Modelo de elevación digital

Los modelos digitales de elevación (MDE) representan la elevación de la superficie terrestre en forma de una imagen digital en la que cada píxel contiene un valor de elevación del punto central del píxel. Los MDE son un insumo principal para cualquier modelado o cuantificación de procesos que involucre la topografía de la Tierra y se utilizan en varias áreas de desarrollo.

El acceso a mapas de elevación y pendiente permite a los socorristas evaluar dónde las inundaciones rellenarán el paisaje, crearán áreas inaccesibles o crearán riesgos para la salud, por ejemplo, el cólera. Los MDE también se utilizan de manera destacada en la planificación y el mapeo de infraestructuras; el diseño y la construcción de carreteras para el transporte; la planificación ambiental urbana para evaluar la construcción, el drenaje y el paisajismo verde; las estrategias de plantación y riego agrícola; el modelado ecológico para evaluar la flora y la fauna del ecosistema; y aplicaciones geológicas como el monitoreo sísmico y costero. Por lo tanto, la información precisa sobre la elevación es clave para una amplia gama de proyectos de desarrollo relacionados con la reducción de la pobreza, el desarrollo urbano, la gestión del agua y otras preocupaciones. Por lo tanto, la capacidad de diseñar y poner en funcionamiento o adquirir MDE está aumentando en relevancia en todo el mundo. Esta nota de orientación sobre DEM tiene como objetivo: (a) proporcionar información suficiente para comprender los procesos generales involucrados en la adquisición de DEM y sus usos, y (b) informar y guiar los criterios de toma de decisiones; las diferentes estrategias de diseño e implementación; y las opciones y costos que existen al adquirir DEM (Fu y Wang 2023).

2.2.10 Lógica difusa en teledetección

La lógica difusa es un enfoque de procesamiento de variables que permite procesar múltiples valores de verdad posibles a través de la misma variable. La lógica difusa intenta resolver problemas con un espectro abierto e impreciso de datos y heurísticas que permiten obtener una serie de conclusiones precisas. La lógica difusa está diseñada para resolver problemas considerando toda la información disponible y tomando la mejor decisión posible dada la entrada (Rojas et al. 2011).

2.2.11 Google Earth Engine (GEE)

GEE es un producto de Google Cloud para el análisis geoespacial a gran escala. Combina un catálogo de imágenes satelitales y conjuntos de datos

geoespaciales de varios petabytes con cálculos a escala planetaria para acelerar la investigación y las aplicaciones ambientales (Mutanga y Kumar 2019; GEE 2021).

GEE integra un amplio catálogo de datos geoespaciales con computación distribuida, accesible a través de bibliotecas de clientes. Los usuarios pueden acceder a una amplia gama de datos satelitales y ambientales, así como incorporar sus propios conjuntos de datos. La plataforma simplifica el análisis geoespacial al manejar automáticamente la proyección, el escalamiento y la composición de datos en función de los parámetros especificados por el usuario. Sus funciones analíticas permiten de manera eficiente en diferentes escalas sin requerir pasos explícitos de preparación de datos o fragmentación. Al administrar internamente el procesamiento complejo de datos y el escalamiento computacional, GEE permite a los usuarios concentrarse en el análisis en lugar de en la configuración técnica (Mutanga y Kumar 2019; GEE 2021).

2.2.11 Random Forest

También conocido como bosque aleatorio es un algoritmo de aprendizaje automático de uso común, que combina el resultado de varios árboles de decisión para llegar a un único resultado. Su facilidad de uso y flexibilidad han impulsado su adopción, ya que maneja problemas tanto de clasificación como de regresión (Tin 1995; Breiman 2001b; Kulkarni y Lowe 2016).

2.3 Definición de términos

GEDI L4B: Conjunto de datos de 1 km consta de dos archivos ráster: (a) ABGD media; y (b) el error estándar de la media, ambos en unidades de Mg ha⁻¹ (Dubayah et al. 2020).

Densidad de biomasa: Se emplea para cuantificar la función de los bosques en el ciclo del carbono (Bente et al. 2019).

Reservas de carbono aéreo: Una reserva de carbono, o depósito de carbono, es un sistema que tiene la capacidad de almacenar o liberar carbono (Mélières y Maréchal 2015).

Cinturón de fugas de carbono: Área que define el aumento neto de las emisiones carbono que se produce fuera de los límites del proyecto, y que puede medirse y es directamente atribuible a las actividades del proyecto (Lagouvardou y Psaraftis 2022).

ArcMap: Lugar donde se muestran y exploran los conjuntos de datos SIG para el área de estudio, donde se asignan símbolos y donde se crean diseños de mapas para imprimir o publicar. ArcMap también es la aplicación que se utiliza para crear y editar conjuntos de datos (Wampler et al. 2013).

ArcGIS Pro: Aplicación esencial para crear y trabajar con datos espaciales en su escritorio. Proporciona herramientas para visualizar, analizar, compilar y compartir sus datos (Wampler et al. 2013).

TerrSet: Es un sistema de software geoespacial integrado para monitorear y modelar el sistema terrestre para el desarrollo sustentable. El sistema TerrSet incorpora las herramientas de análisis GIS de IDRISI y procesamiento de imágenes de IDRISI junto con una constelación de aplicaciones verticales (Tamiru et al. 2024).

La lógica difusa: Es un enfoque de procesamiento de variables que permite procesar múltiples valores de verdad posibles a través de la misma variable (Rojas et al. 2011).

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN

3.1 Tipo de estudio

El estudio es descriptiva, correlacional y predictivo, porque estimo las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *B. exce/sa* mediante la fusión de imágenes Sentinel-1, -2, modelo de elevación digital y lidar espacial GEDI 4B, Tahuamanu – Madre de Dios, año 2025 (León y González 2020; Lozano et al. 2025).

3.2 Diseño del estudio

El estudio corresponde a un diseño no experimental Transaccional (transversal) porque estimo las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *B. exce/sa* mediante la fusión de imágenes Sentinel-1, -2, modelo de elevación digital y lidar espacial GEDI 4B, Tahuamanu – Madre de Dios, año 2025 (León y González 2020; Lozano et al. 2025).

3.3 Delimitación espacial y temporal

La investigación se realizó en la Amazonía de Madre de Dios, específicamente en las concesiones de *B. exce/sa* de la provincia de Tahuamanu y su área de influencia (11°5'24" y 12°22'46" S, 68°43'22" y 70°22'54" O), con una superficie estimada de 1 450 717,05 ha. Para definir el área de influencia se usó el criterio de impacto indirecto en la Amazonia, esta área se estima en unos 50 km a cada lado del área de estudio (Dourojeanni 2006).

La zona a estudiar cuenta con una humedad relativa que oscila entre el 63% y 90%, con una temperatura media anual entre los 25°C y 27°C, con fluctuaciones de picos elevados entre septiembre y abril, y mínimos en mayo y agosto ($\sim 10^{\circ}\text{C}$) (GOREMAD y IIAP 2009; SENAMHI 2015; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021). Los ríos Tahuamanu, Manuripe y Acre son los más importantes en el área de influencia. "La climatología es Tropical Cálida y Húmeda: Bosque Tropical Húmedo (Holdridge 1967), con una media de 2120 mm de lluvias anuales y una altitud promedio de 250 m s.n.m. (Alarcon-Aguirre et al. 2021) (Figura 1).

La evaluación temporal del estudio corresponderá al año 2025.

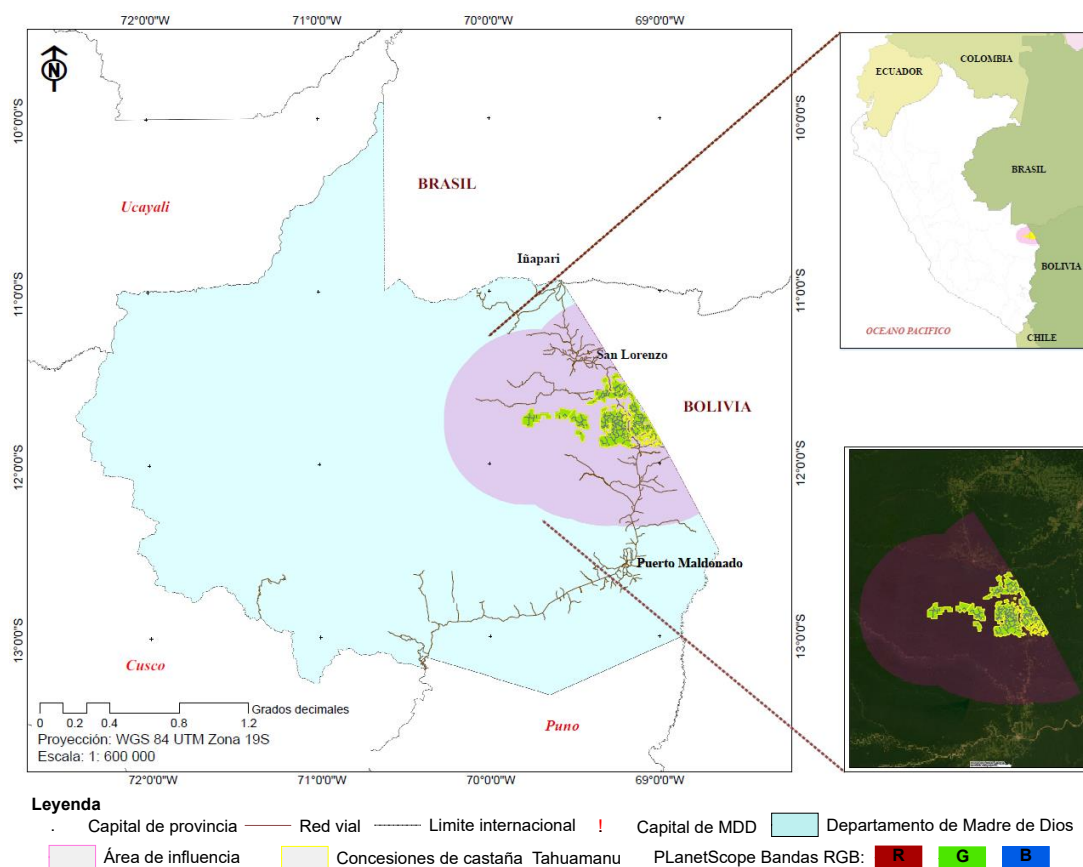


Figura 1. Ubicación de la superficie estudio: área de influencia de concesiones de *B. excelsa* de la provincia de Tahuamanu.

3.4 Población y muestra

La población de estudio está conformada por dos ámbitos espaciales: 1) el área del proyecto que está conformada por 148 concesiones de B. excelsa (castaña) de la provincia de Tahuamanu (113 181,07 ha), 2) el área de Influencia, que es circundante a estas concesiones, que abarca un total de 1 450 717,05 ha. Esta área de influencia incluye otros tipos de coberturas y unidades territoriales, tales como concesiones forestales maderables, concesiones de reforestación, y áreas de conservación, además de las concesiones de castaña.

La muestra estuvo en función a la superposición de las huellas de datos GEDI L4B con el área de influencia de las concesiones de castaña de la provincia de Tahuamanu. Las 597 huellas L4B constituyen la muestra que se encuentran dispersas dentro de todo el límite del área de influencia, lo que garantiza que el modelo de biomasa se entrene y valide con datos que representan la heterogeneidad de los distintos tipos de bosque en la región.

Con estas 597 huellas, se evaluó el modelo, que implica la fusión de datos provenientes de S1, S2, y DEM con GEDI L4B, mediante un proceso en el cual el 60% de las muestras fueron seleccionadas de forma aleatoria para ser utilizadas como datos de entrenamiento, mientras que el 40% restante fue reservado para la validación del mismo (Long et al. 2020).




Figura 2. Superposición de huellas GEDI L4B con el área de referencia.

3.5 Método y técnicas

La información recopilada a través de teledetección (GEDI, S1, S2, DEM) no fue la única fuente de información, sino que se combinó con el análisis multicriterio de evaluación (MCE) basado en factores geográficos y antrópicos (vías, centros poblados, predios agrícolas, entre otros). La confianza estadística de la estimación de biomasa se fundamenta en un modelo de fusión de múltiples sensores (LiDAR espacial, óptico y radar), una técnica que ha demostrado mejorar la precisión en la estimación de biomasa en comparación con el uso de un solo sensor, además, la fiabilidad estadística se verificó mediante métricas como el R^2 y el RMSE, utilizando software especializado (GEE, RStudio®, ArcGIS 10,8®, ArcGIS Pro 3,4® y SigmaPlot 15®), lo que asegura que el método aplicado es estadísticamente replicable y robusto dentro de sus limitaciones inherentes.

La metodología utilizada en el presente estudio se fundamenta en un enfoque innovador que fusiona métricas espectrales temporales provenientes de las imágenes de Sentinel-1 (S1) y Sentinel-2 (S2), las cuales contienen información detallada sobre los atributos estructurales de la vegetación en las

concesiones de *B. excelsa*. Estos datos se complementaron con la información proporcionada por el conjunto de datos GEDI 4B, el cual ofrece una perspectiva tridimensional de la vegetación. Todo este análisis se llevó a cabo en la época seca del año 2025 en la provincia de Tahuamanu y su área de influencia (Kacic et al. 2021; Kacic y Kuenzer 2022; Shendryk 2022; Guo et al. 2023; Kacic et al. 2023; Indirabai y Nilsson 2024; Zhao et al. 2024).

El estudio considero para el análisis la AGBD aérea, así como las reservas y fugas de carbono aéreo presentes en la zona de estudio. Para optimizar la eficiencia del procesamiento y garantizar que no se sobrepasen los límites computacionales de GEE, se emplearon únicamente los datos provenientes de las bandas de S1 y S2, así como el modelo de elevación digital (DEM) de 30 metros de la Misión Topográfica Shuttle Radar (SRTM) y las muestras de GEDI 4B dentro del área de estudio.

Con relación a la investigación, los modelos fueron construidos a partir de la siguiente estructura de variables: para la estimación de la AGBD la variable dependiente fue el producto de referencia GEDI L4B (Mg/ha) y las variables independientes fueron las métricas espaciales de los satélites S1 (bandas VV, VH), S2 (bandas espectrales y sus percentiles) y el Modelo de Elevación Digital (DEM). Luego, para la determinación del cinturón de fugas de carbono, la variable dependiente fue el mapa de riesgo potencial generado a partir de Análisis Multicriterio de Evaluación (MCE) con lógica difusa, y como variables independientes, los factores geográficos y antrópicos (Tabla3-11).

En una primera etapa, se llevó a cabo la extracción de métricas de GEDI utilizando los gránulos de datos 4B. En este proceso se consideraron las huellas GEDI simuladas y superpuestas con las concesiones forestales de la especie *B. excelsa* y su correspondiente área de influencia (Shendryk 2022; Guo et al. 2023; Jiao et al. 2023; Ali y Khati 2024; Indirabai y Nilsson 2024; Zhao et al. 2024).

Los productos de datos S1 analizados previamente corresponden de la época estacional que abarca desde junio hasta septiembre, y se incorporó en el análisis mediante el cálculo de diversas métricas espectrales temporales. Entre estas métricas se incluyen la determinación de percentiles,

específicamente los percentiles 25 y 75, con el fin de obtener un rango intercuartílico (IQR) en relación con la mediana (percentil 50). De manera similar, los productos de S2 fueron del mismo período temporal que los datos de S1 y se redujeron a métricas de percentiles (25, 75) para un análisis detallado y preciso (Silva et al. 2019a; Dubayah et al. 2020; Hofton et al. 2020; Di Tommaso et al. 2021; Dubayah et al. 2022; Lahssini et al. 2022; Shendryk 2022; Guo et al. 2023; Jiao et al. 2023; Kacic et al. 2023; Ali y Khati 2024; Indirabai y Nilsson 2024; Lutz et al. 2024; Zhao et al. 2024). Además de las métricas multitemporales de S1 y S2, se agregó a la fusión de datos el DEM obtenida de SRTM. De acuerdo al centroide de las huellas GEDI, se procedió a la extracción de los valores de píxel S1 y S2. Las muestras recolectadas por GEDI se dividieron en una proporción específica: un 60% fue destinado para el entrenamiento del modelo, mientras que el restante 40% se reservó para llevar a cabo pruebas y validar de manera independiente la eficacia del modelo, siguiendo diversos criterios de medición (Bente et al. 2019; Duncanson et al. 2020; Healey et al. 2020; Hofton et al. 2020; Adrah et al. 2021; Kacic et al. 2021; Corte et al. 2022; Hoffrén et al. 2023; Rajab Pourrahmati et al. 2023).

Para llevar a cabo la derivación de productos de la AGBD del año 2025 en concesiones *B. excelsa* y en su área de influencia, se procedió a realizar un entrenamiento utilizando el modelo de Bosques Aleatorios (Random Forest, RF) para cada uno de los atributos relevantes. El modelo de RF con atributos GEDI L4B de la estructura de la vegetación como variables de respuesta, predichas por las métricas espectrales temporales de S1 y S2, se entrenaron utilizando la configuración predeterminada establecida en GEE (Breiman 1996; Breiman 2001b; Shendryk 2022; Guo et al. 2023; Jiao et al. 2023; Kacic et al. 2023; Ali y Khati 2024; Indirabai y Nilsson 2024; Lutz et al. 2024; Zhao et al. 2024). El modelo de RF se ajustó teniendo en cuenta las mediciones espectrales temporales recopiladas por los satélites S1, S2 y DEM.

Para evaluar la precisión del modelo, se calculó varios criterios de eficiencia basados en las predicciones del modelo y muestras de prueba independientes: coeficiente de determinación (R^2 , Ecuación 1 y 2) y error

cuadrático medio general (RMSE, Ecuación 3), y el error cuadrático medio (rRMSE, Ecuación 4) (Silva et al. 2019a; Duncanson et al. 2020; Healey et al. 2020; Duncanson et al. 2022; Kacic y Kuenzer 2022; Guo et al. 2023; Jiao et al. 2023; Torresani et al. 2023; Ali y Khati 2024; Indirabai y Nilsson 2024; Singh et al. 2024; Zhao et al. 2024).

Para calcular las reservas de carbono aéreo en el bosque, se utilizó la densidad global de carbono (C) de la vegetación ($C = \text{biomasa aérea} \times 0,5 - \text{MgC/ha}$), considerando que el contenido de carbono equivale al 50% de la biomasa aérea de los árboles en existencia (Malhi et al. 2004; Li et al. 2020; Zhang et al. 2022; Hunka et al. 2024)

Para realizar el cinturón de fugas, se utilizó el Análisis de Movilidad (MCE) (Monjardin-Armenta et al. 2020). El análisis de movilidad generó un mapa que muestra el potencial de accesibilidad. En este mapa, el área que se consideró menos accesible está marcada por las zonas boscosas que son más fáciles de alcanzar, de acuerdo con las variables y criterios del análisis (Monjardin-Armenta et al. 2020; Valente et al. 2021).

Es importante señalar que el área de Influencia que delimita la población de estudio no está compuesta únicamente por bosque de *B. excelsa*, sino que incluye un mosaico de usos de suelo y unidades de gestión, por esta razón, el análisis de MCE debe considerar, además de la matriz forestal y las concesiones de *B. excelsa*, la presencia de otros agentes conductores del cambio de uso de suelo, tales como las concesiones forestales maderables, predios agrícolas y otras unidades de uso de suelo. Estas categorías territoriales son factores de riesgo esenciales para la migración de las fugas de carbono desde áreas de alto riesgo hacia el núcleo de las concesiones de *B. excelsa*.

Se realizó un análisis de agentes, conductores y causas principales de fugas de carbono, por lo general, los causantes de las fugas están relacionadas con la deforestación y por consiguiente emplearon las vías principales y secundarias para alcanzar su destino. Las variables consideradas fueron: vía principal, vías secundarias, centros poblados, ríos navegables, área del proyecto, bosque, concesiones de *B. excelsa*, concesiones maderables,

predios agrícolas y deforestación (Chávez et al. 2013; Baraloto et al. 2015; Perz et al. 2016; Klarenberg et al. 2018; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023; Alarcón-Aguirre et al. 2023).

Identificado las variables para el MCE, inicialmente se generó los mapas difusos correspondientes a cada variable (los valores oscilan entre 0 y 1, siendo 0 el más apropiado y 1 el menos apropiado) (Pir-Bavaghar et al. 2019; Kuzminov et al. 2020; dos Reis et al. 2023). En el caso de la deforestación se utilizó el valor acumulado de 2000-2025 con el objetivo de establecer los parámetros de la función difusa.

Seguidamente se estableció los pesos relativos de las variables, para ello se elaboró los pesos, proporcionando una serie de comparaciones por pares sobre la relevancia relativa de los factores en relación con la idoneidad de los píxeles para la actividad en cuestión. Se llevo a cabo la evaluación de los pesos utilizando la función "Weight" del TerrSet® (Esquivel-Martínez et al. 2023; Kodihal y Akhtar 2024), cuyo resultado sirvió como entrada para el módulo MCE (Monjardin-Armenta et al. 2020). Las escalas de consistencia oscilaron entre 0 y 1, siendo el valor más próximo a 0 el más aceptable (Monjardin-Armenta et al. 2020; Valente et al. 2021).

Finalmente, para determinar las fugas de carbono aéreo en las concesiones *de B. excelsa* y área de influencias, se cruzó información espacial con las reservas de carbono aéreo (Esquivel-Martínez et al. 2023).

3.6 Tratamiento de datos

3.6.1 Procesamiento de datos

La estimación de la AGBD y cinturón de fugas mediante la fusión de imágenes Sentinel-1, -2, modelo de elevación digital y lidar espacial GEDI 4B, Tahuamanu – Madre de Dios, año 2025, permitió determinar las reservas de y fugas de carbono aéreo en el área de influencia de concesiones de *B. excelsa*. Para ello, se siguió:

1. Como fase inicial se visualizó los datos de GEDI 4B, donde se aplicó la estadística descriptiva (máxima, media, mínima, mediana, varianza, desviación estándar y coeficiente de variabilidad).
2. En relación con la información recopilada a través de teledetección, se llevó a cabo el procesamiento de los datos provenientes del S1 Ground-Range-Detected (GRD), que cuenta con una resolución espacial de 10 metros (Tabla 2 y Figura 3). Estos datos fueron sometidos a un análisis mediante la implementación de técnicas de filtrado espacial, ajuste radiométrico del terreno y supresión de efectos de borde, siguiendo el enfoque propuesto por Mullissa et al. (2021). Además, es importante destacar que los datos obtenidos a través del satélite S1 fueron procesados y filtrados específicamente para las polarizaciones vertical-vertical (VV) y vertical-horizontal (VH). Esta selección de datos permitió obtener información del área de análisis. Los datos se incorporaron en las métricas espectrales agregadas, en base al cálculo de los percentiles 25 y 75, con el propósito de obtener un rango intercuartílico (IQR) que se fundamenta en la mediana (percentil 50). Estos registros estarán vigentes durante el período comprendido entre los meses de junio a septiembre del año 2025, como se detalla en la Tabla 3.
3. Los datos obtenidos del satélite S2 fueron procesados para obtener la reflectancia superficial (nivel 2A, utilizando el software sen2cor) según lo indicado por Hodam et al. (2022). Además, se llevó a cabo las etapas adicionales de procesamiento, las cuales incluyeron la aplicación de técnicas de enmascaramiento para identificar y eliminar nubes y sombras de nubes en las imágenes (Tabla 2 y Figura 4). En el análisis de los datos recopilados por el satélite S2, se tomarán en cuenta todas las bandas; de 10, 20 y 60 metros de resolución espacial. Los datos S2 correspondientes al año 2025 fueron obtenidos a través de un proceso de filtrado llevado a cabo durante los meses de junio y septiembre. Durante este proceso, los datos fueron transformados en métricas percentiles (25 y 75) con el fin de calcular un IQR en función de la mediana (Silva et al. 2019a; Dubayah et al. 2020; Hofton et al. 2020; Li

et al. 2020; Di Tommaso et al. 2021; Dubayah et al. 2022; Lahssini et al. 2022; Shendryk 2022; Zhang et al. 2022; Guo et al. 2023; Kacic et al. 2023; Ali y Khati 2024; Lutz et al. 2024). Todo el proceso de preprocesamiento de las imágenes del satélite Sentinel se llevaron a cabo en el entorno de computación en la nube proporcionado por GEE (Tabla 3) (GEE 2021).

4. El sensor LiDAR de forma de onda completa GEDI, que significa Global Ecosystem Dynamics Investigation, opera de manera ininterrumpida desde abril de 2019 y está conectado de forma permanente a la Estación Espacial Internacional (ISS), lo que permite realizar mediciones precisas de la estructura tridimensional de los bosques y otros ecosistemas terrestres. GEDI lleva a cabo la captura de datos de alta resolución sobre la compleja estructura de la vegetación en una amplia variedad de bosques, tanto templados como tropicales, mediante el seguimiento continuo de la órbita de la ISS. Ocho pistas terrestres resultan del diseño de muestreo, con distancias de 600 m transversales y 60 m a lo largo de cada pista, lo cual permite una cobertura extensa del área de estudio.

Existen múltiples conjuntos de datos de alta calidad que contienen muestras puntuales recopiladas por el instrumento GEDI. No obstante, en nuestra situación, para llevar a cabo una caracterización de AGBD, se optará por emplear la versión 2,0 de L4B (Dubayah et al. 2020; Duncanson et al. 2020; Li et al. 2020; Dubayah et al. 2022; Duncanson et al. 2022; Shendryk 2022; Zhang et al. 2022; Guo et al. 2023; Ali y Khati 2024; Lutz et al. 2024). La información proporcionada por GEDI de la NASA será en AGBD en megagramos por hectárea (Mg/ha) a una resolución de 1 kilómetro (km) entre las latitudes 51,6° Norte y 51,6° Sur. El proceso de filtrado temporal y espacial de alta calidad de los datos recopilados por el instrumento GEDI se llevará a cabo de manera localizada, tal como se detalla en la Tabla 2.

Tabla 2. Información de datos de satélite

Sensor	Fecha de datos	Nivel de adquisición	Nivel de procesamiento	Orbita
Sentinel-1 (A)	2025-09-07 10:13:43 - 2025-09-07 10:14:14	Interferometric Wide Swath (IW)	Level-1 GRD	Descendente
Sentinel-2 (A)	2025-09-05 15:51:11		2A	
GEDI 4B	2019-04-18 00:00:00 - 2023-03-16 23:59:59			

Las Figuras 3 (S1) y 4 (S2) representan una composición visual de la Provincia de Tahuamanu y su área de influencia, estas imágenes, por diseño, no demuestran únicamente concesiones de *B. excelsa*, sino que abarcan la matriz forestal completa y los usos de suelo circundantes, esta amplitud es metodológicamente esencial, ya que el área de influencia es la unidad de análisis principal para la estimación de reservas de carbono y la modelización del cinturón de fugas, el cual se ve afectado por la dinámica del cambio de uso de suelo en la matriz territorial que la compone.

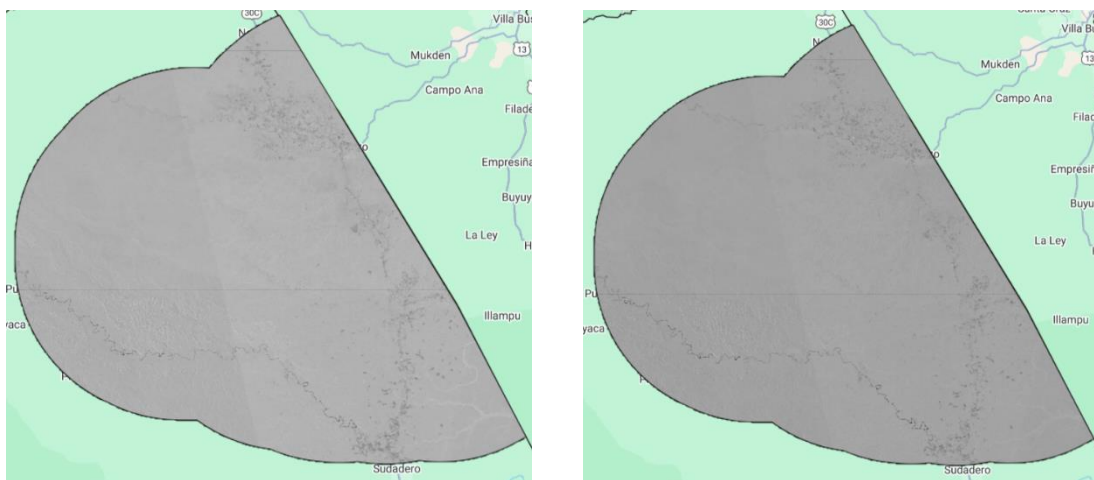


Figura 3. Imágenes S1; izquierda con polarización VV y derecha con polarización VH.




Figura 4. Imágenes S2; composición R (B12)
G (B8) B (B4).

5. El algoritmo RF fue empleado para elaborar un modelo que categorice la densidad de biomasa (Figura 5). RF es un método de aprendizaje colectivo creado por Breiman (2001a) para trabajos de clasificación y regresión, fusionando información de S1, S2, DEM y GEDI. El modelo de aprendizaje automático mejorará la exactitud al fusionar varios modelos para solucionar un problema.

La combinación de varios datos reduce la variabilidad y puede generar resultados más confiables, particularmente en situaciones de clasificadores inestables. La categoría otorgada durante el entrenamiento es la que permitirá la mayor cantidad de votos de diversos clasificadores en el modelo (Clark y Niblett 1992; Tin 1995; Islam y Amin 2020). El proceso se llevará a cabo mediante la herramienta de GEE.

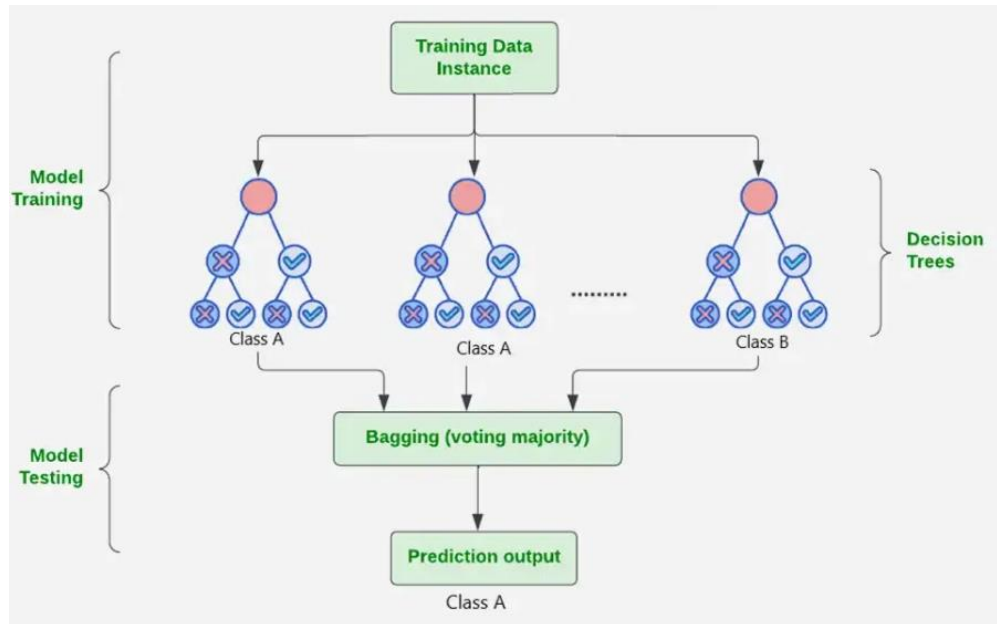


Figura 5. Algoritmo de Random Forest (RF).

Fuente: Tomado de Tin (1995)

6. Para calcular las reservas de carbono aéreo en el bosque, se utilizó la densidad global de carbono (C) de la vegetación ($C = \text{biomasa aérea} \times 0,5 \text{ MgC/ha}$), considerando que el contenido de carbono equivale al 50% de la biomasa aérea de los árboles en existencia (Malhi et al. 2004; Li et al. 2020; Zhang et al. 2022; Hunka et al. 2024).
7. La demarcación del cinturón de fugas, utilizo el Análisis de Movilidad (Análisis Multicriterio de Evaluación - MCE) (Monjardin-Armenta et al. 2020). El análisis de movilidad genero un mapa que muestra el potencial de accesibilidad. En este mapa, el área que se consideró menos accesible está marcada por las zonas boscosas que son más fáciles de alcanzar, de acuerdo con las variables y criterios del análisis (Monjardin-Armenta et al. 2020; Valente et al. 2021). Es importante señalar que el área de Influencia que delimita la población de estudio no está compuesta únicamente por bosque de *B. excelsa*, sino que incluye un mosaico de usos de suelo y unidades de gestión, por esta razón, el análisis de MCE debe considerar, además de la matriz forestal y las concesiones de *B. excelsa*, la presencia de otros agentes

conductores del cambio de uso de suelo, tales como las concesiones forestales maderables, predios agrícolas y otras unidades de uso de suelo. Estas categorías territoriales son factores de riesgo esenciales para la migración de las fugas de carbono desde áreas de alto riesgo hacia el núcleo de las concesiones de *B. excelsa*.

Se realizó un análisis de agentes, conductores y causas principales de fugas de carbono, por lo general, los causantes de las fugas están relacionadas con la deforestación y por consiguiente emplean las vías principales y secundarias para alcanzar su destino. Las variables consideradas fueron: vía principal, vías secundarias, centros poblados, ríos navegables, área del proyecto, concesiones de *B. excelsa*, concesiones maderables, predios agrícolas, bosque y deforestación (Tablas 3-11 y Figuras 3-11) (Chávez et al. 2013; Baraloto et al. 2015; Perz et al. 2016; Klarenberg et al. 2018; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023; Alarcón-Aguirre et al. 2023).

8. Identificado las variables para el MCE, se creó los mapas difusos correspondientes a cada variable (los valores oscilan entre 0 y 1, siendo 0 el más apropiado y 1 el menos apropiado, Tablas 3-10 y Figuras 6-13) (Pir-Bavaghar et al. 2019; Kuzminov et al. 2020; dos Reis et al. 2023). En el caso de la deforestación se utilizó el valor acumulado de 2000-2024 con el objetivo de establecer los parámetros de la función difusa (Tabla 11 y Figura 14).

Tabla 3. *Análisis Fuzzy (función difusa) de vías principales*

Variable	Descripción	Distancia (m)	Índice de pertenecía difusa
Vías principales	La función es definida por el usuario y se fundamenta en las repercusiones directas e indirectas de la vía interoceánica.	1000	1
		16000	0,9
		37000	0,7
		50000	0,1




Figura 6. Función difusa de la vía principal

Tabla 4. Análisis Fuzzy (función difusa) de vías secundarias

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Vías secundarias	La función es definida por el usuario y establecida por las verificaciones en campo.	0	1
		1000	0,5
		35000	0,2
		47000	0,1




Figura 7. Función difusa de las vías secundarias.

Tabla 5. *Análisis Fuzzy (función difusa) de ríos navegables*

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Ríos navegables	Categorización de función establecida por el usuario. Estos ríos son poco navegables (excepto durante la temporada de vaciado, cuando son navegables, el cauce principal es el creciente); estos ríos carecen de infraestructuras de puertos fluviales y únicamente abarcan la frontera agrícola que se extiende de 0 a 1000 metros.	0	1
		1000	0,1




Figura 8. Función difusa de ríos navegables.

Tabla 6. *Análisis Fuzzy (función difusa) de centros poblados*

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Centros poblados	Definición de función establecida por el usuario.	1000	1
		4000	0,4
		6000	0,3
		8000	0,1




Figura 9. Función difusa de centros poblados.

Tabla 7. *Análisis Fuzzy (función difusa) del área del proyecto (concesiones de castaña)*

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Área del proyecto	Esta es una categoría de función lineal decreciente monótono y se distribuye desde 0 hasta 5 km.	0	--
		5000	--




Figura 10. Función difusa del área del proyecto.

Tabla 8. Análisis Fuzzy (función difusa) de concesiones forestales maderables

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Concesiones forestales maderables	Tipo de función lineal monótonamente creciente y se distribuye de 0 km hasta 50 km (distancia máxima en que los actores de deforestación se pueden movilizar en el bosque).	0	--
		50000	--



Figura 11. Función difusa de concesiones forestales maderables.

Tabla 9. *Análisis Fuzzy (función difusa) de predios agrícolas*

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Predios agrícolas	Categorización de función establecida por el usuario. Donde se establecerá como actúan las los predios agrícolas en la deforestación.	1000	1
		4000	0,4
		6000	0,3
		8000	0,1




Figura 12. Función difusa de predios agrícolas.

Tabla 10. *Análisis Fuzzy (función difusa) de bosque*

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Bosque	Tipo de función lineal monótonamente creciente y se distribuye de 0 km hasta 50 km (distancia máxima en que los actores de deforestación se pueden movilizar en el bosque).	0	--
		50000	--




Figura 13. Función difusa de bosque.

Tabla 11. Análisis Fuzzy (función difusa) de deforestación

Variable	Descripción	Distancia (m)	Índice de pertenencia difusa
Deforestación	Categorización de función establecida por el usuario. Donde se establecerá como actúa la deforestación en la movilidad de fugas carbono.	500	1
		1000	0,4
		1500	0,3
		2000	0,1




Figura 14. Función difusa de deforestación.

9. Seguidamente se estableció los pesos relativos de las variables, para ello se elaboró los pesos, proporcionando una serie de comparaciones por pares sobre la relevancia relativa de los factores en relación con la idoneidad de los píxeles para la actividad en cuestión. Se llevo a cabo la evaluación de los pesos utilizando la función "Weight" (AHP, Proceso de Jerarquía Analítica) del TerrSet® como se muestra en la Figura 15 y Tabla 12 (Esquivel-Martínez et al. 2023; Kodihal y Akhtar 2024), cuyo resultado sirvió como entrada para el módulo MCE (Monjardin-Armenta et al. 2020). Las escalas de consistencia oscilaron entre 0 y 1, siendo el valor más próximo a 0 el más aceptable (Tabla 13) (Monjardin-Armenta et al. 2020; Valente et al. 2021).

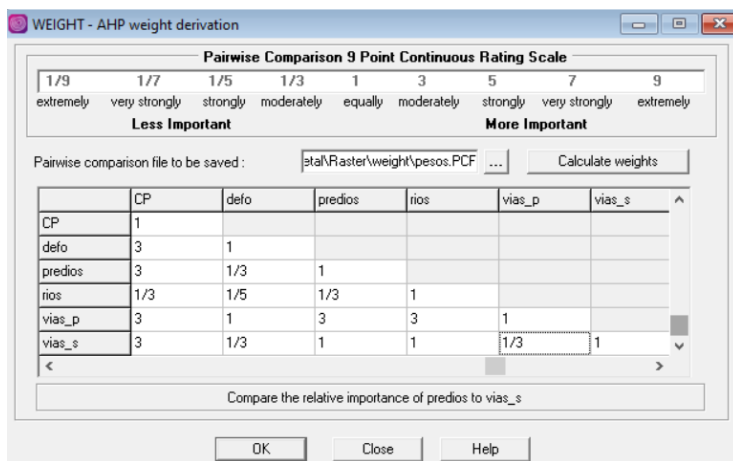


Figura 15. Pesos relativos de variables con TerrSet®.

Para todos los casos, los datos fueron procesados en el Sistema de proyección World Geodetic System 1984 (WGS 84) zona 19 S.

Tabla 12. Matriz de comparación por pares (AHP)

Variable	Bosque	Área del proyecto	Concesiones forestales maderables	Centros poblados	Deforestación	Predios Agrícolas	Ríos navegables	Vías principales	vías secundarias
Bosque	1								
Área del proyecto	1	1							
Concesiones forestales maderables	3	3	1						

Centros poblados	5	5	3	1					
Deforestación	9	9	5	3	1				
Predios Agrícolas	5	5	3	3	1/3	1			
Ríos navegables	3	3	1	3	1/5	1/3	1		
Vías principales	7	7	3	3	1	3	3	1	
Vías secundarias	5	5	1	3	1/3	1	1	1/3	1

Tabla 13. Pesos de las variables e índice de consistencia

Bosque	0,0226
Área del proyecto	0,0226
Concesiones forestales maderables	0,0598
Centros poblados	0,0972
Deforestación	0,2642
Predios Agrícolas	0,1346
Ríos navegables	0,0598
Vías principales	0,2297
Vías secundarias	0,1095
Índice de consistencia	0,05

Según la Tabla 13, el índice de consistencia está por debajo de 0,10 lo que indica que los juicios son lo suficientemente consistentes como para ser confiables.

Respecto al cinturón de fugas se estableció un umbral de posibilidades de movilidad con alto potencial de riesgo (color rojo) que vario entre 0,71 a 0,99 que representa un área aproximada de 334 331,91 ha (Figura 16 y 17).




Figura 16. Cinturón de fugas de carbono mediante MCE; posibilidades de movilidad (rojo, con alto potencial; azul, bajo potencial).




Figura 17. Posibilidades de movilidad alto (rojo; 0,71 – 0,99).

3.6.3 Precisión de datos clasificados

Para evaluar la estimación del modelo, que implique la fusión de datos provenientes de S1, S2, DEM) y GEDI L4B, se llevó a cabo un proceso en el cual el sesenta por ciento de las muestras serán seleccionadas de forma

aleatoria para ser utilizadas como datos de entrenamiento (60%) con el fin de desarrollar el modelo, mientras que el cuarenta por ciento restantes (40%) será reservado para llevar a cabo la validación del mismo. El coeficiente de determinación R^2 se empleó para evaluar la calidad del ajuste entre los valores observados y los predichos, mientras que el error cuadrático medio (RMSE) se utilizó para cuantificar la precisión de las estimaciones de los modelos propuestos en las ecuaciones 1 y 2 (Long et al. 2020). 2020). Un R^2 mayor indicará un ajuste más preciso entre el valor observado y el valor predicho en el modelo de regresión lineal. Esto significa que una mayor proporción de la variabilidad en la variable dependiente puede ser explicada por la variable independiente en el modelo. A medida que el error cuadrático medio (RMSE) disminuye, se reduce la magnitud del error de estimación del modelo de manera proporcional (Li et al. 2020; Shendryk 2022; Zhang et al. 2022; Guo et al. 2023; Ali y Khati 2024; Lutz et al. 2024).

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

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

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad (\text{Ecuación 3})$$

$$rRMSE = \frac{RMSE}{\bar{x}} \times 100 \quad (\text{Ecuación 4})$$

donde y_i son los valores medidos AGB, \hat{y}_i son los valores estimados, y n es el tamaño de la muestra.

3.6.4 Análisis estadístico

El procedimiento aplico la estadística descriptiva e inferencial, se emplearon los softwares SigmaPlot 15®, ArcGIS 10,8®, ArcGIS Pro 3,4®, RStudio®, GEE y TerrSet®.

Para el primer y segundo objetivo, sobre determinar la densidad de biomasa aérea mediante un modelo basado en Random Forest de la fusión de datos

GEDI nivel 4B con Sentinel-1, -2 y modelo de elevación digital (DEM) en el área de influencia y concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios, se procesó en la plataforma GEE, SigmaPlot 15® y se midió la fiabilidad mediante el coeficiente de determinación R^2 y el error cuadrático medio (RMSE),

El segundo y cuarto objetivo, sobre determinar las reservas de carbono aéreo en el área de influencia y concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios, se desarrolló con los softwares ArcGIS 10,8®, ArcGIS Pro 3,4® y RStudio®.

Respecto al quinto objetivo, sobre determinar el cinturón de fugas de carbono aéreo mediante técnicas de lógica difusa en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios, se aplicaron los softwares ArcGIS 10,8®, ArcGIS Pro 3,4®, TerrSet®, SigmaPlot 15®.

El sexto objetivo, sobre estimar las fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios, utilizo los softwares ArcGIS 10,8®, ArcGIS Pro 3,4®, RStudio® y SigmaPlot 15®.

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1 Densidad de biomasa aérea mediante un modelo basado en Random Forest en el área de influencia y concesiones de *Bertholletia excelsa*, Tahuamanu – Madre de Dios.

La importancia espacial de las variables de entrada para el modelo de RF (Figura 3), presenta a las barras de tonos verde más oscuros que están dominadas por la influencia de las bandas del infrarrojo de S2 (B12 y B11), así como por la elevación (DEM), las más determinantes para la predicción de la AGBD aérea. Las barras de tonos de verde más claros señalan áreas donde la influencia de las variables es menor, pero no nula, en estos casos, el modelo aún utiliza las variables de entrada, pero su peso es menor en comparación con las áreas de color verde oscuro, este comportamiento de la importancia espacial demuestra que el modelo de RF se adapta a la heterogeneidad del paisaje, seleccionando las variables más predictivas para cada píxel, donde la capacidad de ajuste es lo que le permite al modelo alcanzar una alta precisión en la estimación de la AGBD aérea en un ecosistema tan complejo como la Amazonia de Madre de Dios.

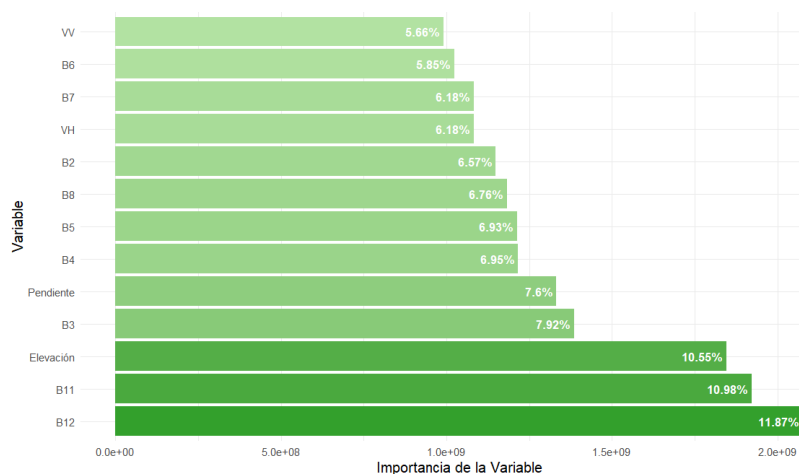


Figura 18. Importancia de las variables en el modelo RF.

Los resultados usando el modelo RF para estimar la AGBD aérea en concesiones de *B. excelsa* y su zona de influencia muestran la importancia de algunas variables en su cuantificación, siendo de mayor relevancia las bandas del infrarrojo de onda corta del satélite S2 (B12 y B11) y la elevación (DEM). La consistencia de los resultados coincide por lo propuesto por Zhao et al. (2024), quienes encontraron que la banda del infrarrojo cercano, un tipo de banda infrarroja, tiene una alta influencia en la AGBD en su evaluación de áreas urbanizadas de China, este análisis apoya la conclusión de la importancia de las bandas espectrales para capturar las características del dosel forestal. De manera similar, la capacidad de nuestro modelo para adaptarse a la heterogeneidad espacial del paisaje, muestra la importancia de variables, Shendryk (2022) demostró que los modelos que combinan datos de S1, S2 y datos de elevación tienen un rendimiento mejorado en la predicción de la AGBD, reduciendo el efecto de saturación común en áreas de alta biomasa, estos hallazgos refuerzan esta conclusión, mostrando que la fusión de múltiples fuentes de datos permite que el modelo capture las variaciones del dosel forestal de manera más precisa. Por otro lado, Lutz et al. (2024) demostraron que sus modelos subestimaron la altura de los árboles más altos, al estar calibrado con datos L4B de GEDI, genera un mejor el rango completo de biomasa. Finalmente, la capacidad de cuantificar las reservas de carbono a partir de los mapas de biomasa, como hicimos nosotros, es un método ya establecido en la literatura, los estudios de Ali y Khati (2024); Indirabai y

Nilsson (2024) y Guo et al. (2023) utilizaron algoritmos de aprendizaje automático para generar mapas de AGBD de alta precisión, los cuales sirven como una base sólida para el cálculo de reservas de carbono y el monitoreo de su dinámica.

En la Figura 19 se muestra el modelo de RF entrenado con los datos observados y predichos, donde el diagrama de dispersión representa el 60% de todos los datos. El modelo presenta un R^2 de 0,794 explicando que el 79% de la variabilidad en la biomasa aérea (AGBD) muestra una asociación entre los predictores (S1, S2 y DEM) y la variable respuesta (AGBD). La cercanía a 1 indica que las predicciones del modelo se ajustan muy bien a los valores reales, lo que sugiere que el modelo podría ser fiable para predecir los cambios de la AGBD en el área de estudio, sin embargo, debe verificarse el desempeño del desempeño en la validación. En ese mismo contexto, el RMSE de 46,80 Mg/ha indica la magnitud promedio de los errores del modelo en las unidades utilizadas y el ajuste de las predicciones a los valores reales. El rRMSE de 19,46% es una métrica comparable con otros estudios, ya que normaliza el error con la media de los datos observados, lo que podría indicar que el error promedio del modelo es un 19,46% de la media de biomasa en la zona de estudio.

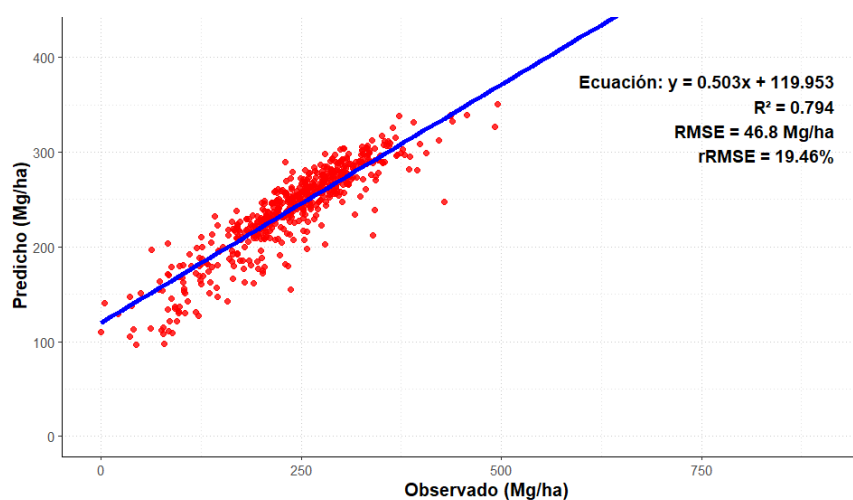


Figura 19. Entrenamiento de datos observados y predichos.

La Figura 20 presenta el diagrama de dispersión de los datos de validación, que corresponden al 40% del conjunto de datos total, las métricas de R^2 de 0,262, indica que el modelo explica el 26,2% de la variabilidad en la AGBD aérea observada. A diferencia de un valor más alto, este resultado sugiere una correlación más débil entre los predictores y la biomasa. RMSE = 65,71 Mg/ha muestra que, en promedio, las predicciones de biomasa se desvían 65,71 Mg/ha de los valores reales, mientras que rRMSE de 27,07% representa el valor medio de la biomasa en el área de estudio.

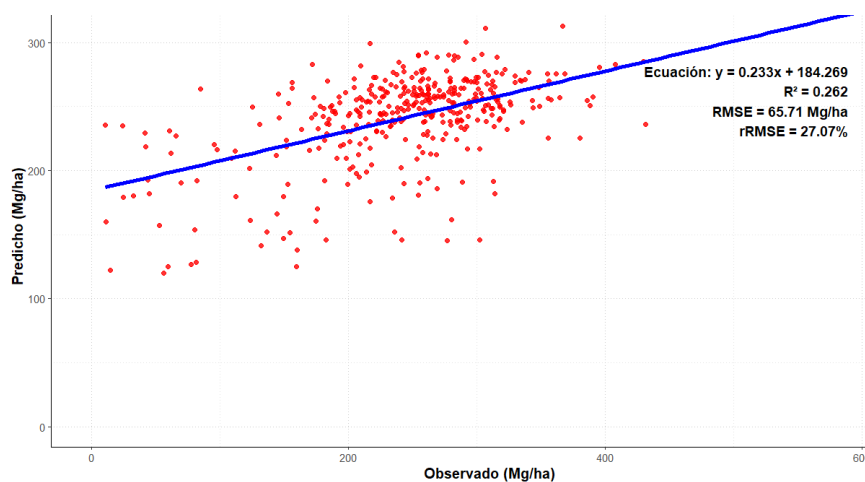


Figura 20. Validación de datos observados y predichos.

El hecho que R^2 de 0,794 en el entrenamiento y de 0,262 en la validación indica claramente que el modelo está sufriendo de sobreajuste. Un R^2 de 0,79 muestra que el modelo aprendió muy bien los patrones del 60% de los datos, es decir, se ajustó a los detalles específicos de esa porción de la información, incluyendo el ruido o las características particulares de esas muestras, desempeñándose de manera correcta. Por otro lado, la validación con un R^2 de 0,262, muestra una caída significativa en el conjunto de validación (40% de los datos) demostrando que el modelo no pudo generalizar de manera efectiva, lo que significa que los patrones que aprendió en la etapa de entrenamiento no son representativos en todo el conjunto de datos, siendo el modelo no tan robusto como parecía al principio.

Las posibles causas de este fenómeno incluyen; un conjunto de datos de entrenamiento demasiado pequeño puede no ser lo suficientemente diverso para que el modelo aprenda patrones que sean representativos de toda el área, la complejidad del ecosistema (la Amazonia de Madre de Dios) puede hacer que las relaciones entre los datos satelitales y la biomasa cambien mucho de un lugar a otro, por lo que, el modelo se ajustó a las relaciones del 60% de los datos, pero no pudo aplicarlas a las variaciones del 40% restante. Esto es posible a la naturaleza de la data de GEDI L4B, que proporciona estimaciones de biomasa en huellas o puntos de muestreo de 1 km x 1 km que están espaciados a lo largo de las trayectorias de vuelo de la Estación Espacial Internacional (ISS) que ofrece una muestra puntual de la biomasa forestal.

A pesar de la limitación por sobreajuste, la metodología de fusión de datos GEDI L4B con S1, S2 y DEM mediante RF demuestra ser ampliamente aplicable a otras regiones y estudios de biomasa. El modelo, al ser entrenado con datos de alta precisión de GEDI, es capaz de aprender las relaciones entre la estructura forestal (GEDI), las propiedades espectrales (S2), la textura y retrodispersión (S1) y topografía (DEM), por lo tanto, esta metodología podría ser replicada para generar mapas de biomasa en otras áreas de la Amazonía o en otros ecosistemas, adaptando el conjunto de datos de entrenamiento para la región de interés, en ese sentido, el modelo constituye una base metodológica valiosa que puede ser perfeccionada, con una mayor densidad de puntos de entrenamiento o con técnicas de validación más robustas y convertirse en una herramienta estandarizada y eficiente para el monitoreo forestal a gran escala.

En la Figura 21 se muestra un mapa de la distribución espacial de la AGBD aérea en el área de influencia, la variación de color en el mapa indica los lugares con diferente acumulación de AGBD, mostrando la heterogeneidad espacial que define la complejidad del ecosistema Amazónico. En la Tabla 14 se muestra el total de biomasa, que es de 3 986 741 393,24 Mg, dato esencial para cuantificar las reservas de carbono. La AGBD media es de 241,66 Mg/ha,

que expresa la densidad media de la biomasa en el área de estudio. Finalmente, la desviación estándar de 36,30 Mg/ha indica la dispersión de la biomasa en esa zona, siendo baja, lo que implica que la mayoría de los píxeles en el mapa tienen valores cercanos a la media.




Figura 21. Modelo de la AGBD de la fusión de datos GEDI L4B con datos S1, S2 y DEM del área de influencia.

Tabla 14. Biomasa y densidad de biomasa en el área de influencia

Variable	Total (Mg)	Media (Mg/ha)	Desviación estándar
AGBD (Fusión de GEDI L4B con S1, S2 y DEM)	3 986 741 393,24	241,66	36,30

Los resultados del modelo RF para estimar la AGBD aérea en el área de estudio concuerdan con las tendencias y resultados encontrados en la literatura. La media de AGBD de 241,66 Mg/ha para el área de estudio se

encuentra dentro del rango de valores de biomasa informados para bosques tropicales en estudios anteriores; Indirabai y Nilsson (2024) informaron en bosques tropicales de la India valores de AGBD entre 75,9 y 353,6 ton/ha, lo que apoya la magnitud de las estimaciones de este estudio, este enfoque, la fusión de datos GEDI L4B, S1, S2 y DEM, es una metodología robusta para la estimación de biomasa, lo que es apoyada por estudios recientes (Lutz et al. 2024; Zhao et al. 2024) que demuestran cómo la fusión de sensores ópticos, radar y LiDAR mejora la exactitud de los modelos de biomasa, lo que se ve reflejado en los resultados del modelo.

La AGBD promedio sobre el área de influencia de 241,66 Mg/ha sigue una tendencia a estudios de alta biomasa de la Amazonía peruana. Donde se han aplicado métodos directos (inventario) y métodos indirectos avanzados (LiDAR aéreo) en la región de Madre de Dios, donde se han reportado altos stocks, a menudo superiores a 200 Mg/ha (Asner 2010; Quesada et al. 2010). La proximidad cercana de los valores da fiabilidad a la capacidad de la técnica de fusión de datos GEDI/Sentinel para estimar reservas de biomasa a partir de métodos de estimación directa más costosos. También muestra que las concesiones de *B. excelsa* sostienen la densidad de biomasa dentro del umbral de los bosques Amazónicos, apoyando la noción de que su manejo sostenible ayuda a mantener la conservación estructural del bosque.

La habilidad del modelo para simular la heterogeneidad del paisaje, como se puede observar en el mapa AGBD, es esencial, ya que concuerda con la conclusión de Shendryk (2022). Este autor destacó que la combinación de datos de teledetección de libre acceso permite generar mapas de biomasa más exactos y utilizables a escala global. Esto se apoya en el presente estudio para las concesiones forestales de *B. excelsa* y zona de influencia. Los datos de AGBD muestran que las concesiones de *B. excelsa* no solo tienen valor económico, sino también ecológico como reservorios de biomasa. Además, estas concesiones proporcionan datos de referencia para el monitoreo de carbono, la planificación de la conservación y la gestión forestal sostenible.

La Figura 22 muestra el mapa de la distribución espacial de la AGBD área del área del proyecto (concesiones de *B. excelsa*), donde se visualiza las zonas con alta y baja densidad de AGBD. La cuantificación de la AGBD un total de biomasa con 310 823 221,89 Mg, con una densidad media de 241,08 Mg/ha, valor promedio que es casi idéntica a la del área de influencia (241,66 Mg/ha), este hallazgo demuestra que las concesiones de *B. excelsa* son una muestra representativa y saludable del ecosistema circundante en términos de AGBD. Asimismo, presenta una desviación estándar de 33,99 Mg/ha, lo que indica la variabilidad de la biomasa, en este un valor ligeramente menor que el del área de influencia. Estos datos argumentan que las concesiones de *B. excelsa* no solo tienen un valor económico, sino también un valor ecológico considerable como reservorios de biomasa.

Tabla 15. *Biomasa total y densidad de biomasa en el área del proyecto (concesiones de castaña)*

Variable	Total (Mg)	Media (Mg/ha)	Desviación estándar
AGBD (Fusión de GEDI L4B con S1, S2 y DEM)	310 823 221,89	241,08	33,99

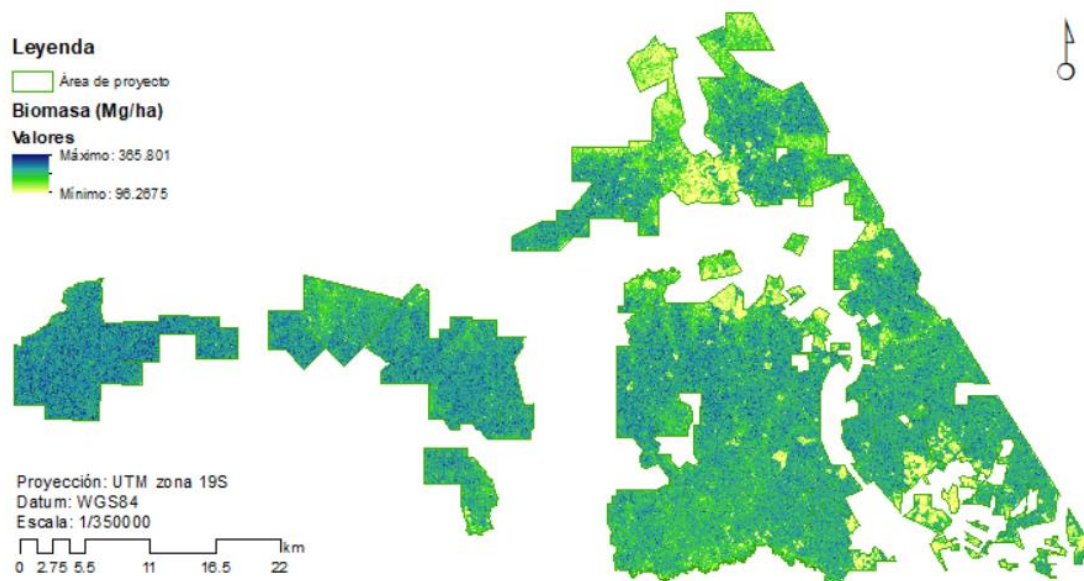


Figura 22. Modelo de la AGBD de la fusión de datos GEDI L4B con datos S1, S2 y DEM del área del proyecto.

La AGBD media de 241,08 Mg/ha del área del proyecto es coherente con los valores reportados en otros estudios; Indirabai y Nilsson (2024) encontraron rangos de AGBD de hasta 353,6 ton/ha en bosques similares, lo que valida la magnitud de nuestras estimaciones y sugiere que las concesiones de *B. exce/sa* tienen una AGBDA comparable a bosques conservados.

El uso de un modelo de RF que fusiona datos de GEDI L4B, S1, S2 y DEM demuestra ser un enfoque robusto, este método ha probado su eficacia en varios estudios previos, como los de Ali y Khati (2024); Zhao et al. (2024) y Guo et al. (2023), confirmando que la aplicación de tecnologías mediante la fusión de datos LiDAR espacial con sensores ópticos y de radar mejora el rendimiento de la fiabilidad en la estimación de la biomasa.

Es importante mencionar que los valores de AGBD (241,08 Mg/ha) en las concesiones son similares a estimaciones de biomasa (mayores a 200 Mg/ha) en los bosques primarios de Madre de Dios (Asner 2010; Quesada et al. 2010). Los estudios realizados respaldan la confianza en las estimaciones de biomasa del método mediante la fusión GEDI/Sentinel que captura los puntos

de referencia del método directo, reforzando la calidad de la metodología en comparación con los puntos de referencia locales.

Un hallazgo importante es que la AGBD en las concesiones de *B. excelsa* (241,08 Mg/ha) es casi idéntica a la del área de influencia (241,66 Mg/ha), lo que sugiere que las concesiones, a pesar de su uso para la recolección, mantienen una estructura forestal representativa y saludable del ecosistema circundante, destacando su papel en la conservación y el manejo forestal sostenible. Sin embargo, es importante abordar la limitación del modelo. A pesar de un adecuado rendimiento en el entrenamiento del modelo ($R^2= 0,79$, 60% de datos) y la caída significativa en la validación ($R^2= 0,262$) evidencia un sobreajuste, este fenómeno puede ser atribuido, en parte, a la naturaleza de los datos de GEDI L4B, que ofrecen mediciones precisas, pero no continuas, en ese sentido, el modelo, al ser entrenado con puntos espaciados, pudo tener dificultades para generalizar a la totalidad del área. Esta limitación subraya la complejidad de modelar la biomasa en ecosistemas heterogéneos y sugiere la necesidad de utilizar conjuntos de datos de entrenamiento más densos en futuras investigaciones.

4.2 Reservas de carbono aéreo en el área de influencia y concesiones de *Bertholletia excelsa*.

La distribución espacial del carbono aéreo en el área de influencia (Figura 24) presenta el mapa donde se visualiza la identificación de zonas de almacenamiento de carbono por nivel de heterogeneidad por tono de colores. La Tabla 17 presenta la cuantificación del carbono total con 1 993 370 696,62 MgC y densidad media de 120,83 MgC/ha. La desviación estándar de 18,15 MgC/ha refleja la variabilidad en la densidad de carbono dentro del área de influencia las concesiones, lo que implica que la mayoría de los píxeles en el mapa tienen valores cercanos a la media.

Tabla 16. Carbono y densidad de carbono aéreo en el área de influencia

Variable	Total (MgC)	Media (MgC/ha)	Desviación estándar
Carbono aéreo	1 993 370 696,62	120,83	18,15




Figura 23. Densidad de carbono aéreo del área de influencia.

La densidad promedio de carbono en el área de influencia fue de 120,83 MgC/ha, lo que demuestra que estos ecosistemas tienen una alta capacidad de almacenamiento de carbono.

La alta densidad de carbono de 120,83 MgC/ha se asemejan con la estimación promedio de 114 MgC/ha reportado por W.W.F. (2013) y se sitúa dentro del rango de 128 +/- 14 MgC/ha documentado por Asner (2010) para la región de Madre de Dios, bajo este contexto, los hallazgos proporcionan indicios de validez del modelo para calcular las reservas de carbono en los bosques Amazónicos, específicamente en la región de Madre de Dios con fines de generación de políticas para su manejo y conservación.

Este valor es comparable a estudios anteriores, como el de Ngo et al. (2023), que estimaron una densidad de carbono de 83,5 Mg/ha para la Amazonía. Los 120,83 MgC/ha en el área de influencia de las concesiones de *B. excelsa* indican que esta es un área con alta densidad de carbono, posiblemente debido a la presencia de bosques maduros y especies de alta biomasa. En términos de cuantificación de carbono total, que corresponde a 1 993 370 696,62 MgC, es importante mencionar el papel que tiene esta área como sumidero de carbono. Este almacenamiento es crucial para la mitigación del cambio climático y para alcanzar las metas de reducción de emisiones (REDD+), como señalan Jiao et al. (2023) y Zhao et al. (2024). El conocimiento sobre estas reservas es esencial para establecer políticas de conservación y para la toma de decisiones en la gestión forestal y la valoración de los servicios ecosistémicos de los bosques Amazónicos.

La distribución espacial de carbono aéreo (Figura 24) visualiza las zonas de almacenamiento de carbono y la heterogeneidad en base a los tonos de color que refleja las variaciones en la densidad, con áreas con mayor y menor acumulación. La Tabla 17 cuantifica el carbono total con 155 411 610,95 MgC, con una densidad media de 120,54 MgC/ha y una desviación estándar de 17,00 MgC/ha que refleja la variabilidad en la densidad de carbono dentro de las concesiones de *B. excelsa* y refleja una distribución de carbono consistente, aunque con las variaciones esperadas en un ecosistema de bosque Amazónico. Estos resultados son importantes, ya que no solo cuantifican el carbono almacenado, sino que también proporcionan una base sólida para la discusión sobre la importancia de las concesiones de *B. excelsa* en el ciclo del carbono y la conservación.

Tabla 17. *Carbono y densidad de carbono aéreo en el área del proyecto*

Variable	Total (MgC)	Media (MgC/ha)	Desviación estándar
Carbono aéreo	155 411 610,95	120,54	17,00

La densidad media de carbono de 120,54 MgC/ha en el área del proyecto (concesiones de *B. excelsa*) no es solo significativa por sí misma, sino que presenta una similitud con la densidad media del área de influencia (120,83 MgC/ha) lo que relaciona que las concesiones de *B. excelsa* mantienen una capacidad de almacenamiento de carbono del ecosistema forestal circundante, esto es crucial, ya que indica que las actividades de manejo en estas concesiones no han comprometido su función como reservorios de carbono, lo que resalta un modelo de uso sostenible. Ngo et al. (2023) estimaron 83,5 Mg/ha para la Amazonía y representa una zona con alta densidad de carbono, posiblemente por la presencia de bosques maduros y especies de alta biomasa.

El carbono total almacenado en las concesiones asciende a 155 411 610,95 MgC y representa una contribución importante a la mitigación del cambio climático. Asimismo, al comparar esta cifra con el carbono total del área de influencia (1 993 370 696,62 MgC), se pone de manifiesto la magnitud del carbono almacenado en las áreas bajo gestión específica, estos valores reafirman el papel de los bosques Amazónicos, y específicamente de las áreas bajo concesión de productos no maderables como la *B. excelsa*, en el ciclo global del carbono. La precisión de estas estimaciones, obtenidas mediante la fusión de datos GEDI L4B, S1, S2 y DEM, proporciona una base sólida para la toma de decisiones en la gestión forestal sostenible y para la implementación de estrategias de conservación que reconozcan el valor del carbono. Finalmente, la importancia ecológica y económica de las concesiones se basa en la capacidad de las concesiones para almacenar altas cantidades de carbono mediante el monitoreo de los stocks de carbono y su contribución a iniciativas como REDD+ (Jiao et al. 2023; Zhao et al. 2024).

4.3 Cinturón y fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa* Tahuamanu – Madre de Dios.

La determinación del cinturón de fugas de carbono aéreo (Figura 25 es el resultado de la aplicación de un MCE utilizando técnicas de lógica difusa, que integra diversas variables influyentes para modelar el potencial de accesibilidad y el riesgo de fuga de carbono. El estudio contempla las zonas de alto potencial, que representan áreas más críticas y vulnerables. Los colores rojos intensos (Figura 16) señalan regiones con alta accesibilidad y una fuerte influencia de los factores que impulsan la deforestación y la degradación forestal, donde interactúan variables como la proximidad a vías principales y secundarias, centros poblados, ríos navegables, predios agrícolas y la deforestación histórica, que crea un patrón espacial de. En este contexto, el riesgo de pérdida de carbono es considerable, y estas zonas constituyen el cinturón de fugas que debe ser prioritario para las intervenciones de conservación.

La estimación de las fugas de carbono (Tabla 18) reporta un carbono total de 400 468 662,72 MgC en zonas con alto potencial y posibilidad de movilidad de fuga dentro del área de influencia, esta cifra es alarmante, ya que indica una gran cantidad de movilidad de carbono y ser liberado a la atmósfera. La densidad media con 105,53 MgC/ha es ligeramente inferior a la densidad media de carbono total en el área de influencia (120,83 MgC/ha), lo que podría sugerir que las áreas con fugas ya han sufrido alguna degradación y que las zonas de mayor riesgo tienen una biomasa inicial ligeramente menor y han sido más afectadas. Se presenta una desviación estándar de 23,40 MgC/ha que muestra la variabilidad en la densidad de carbono dentro de las áreas de fuga, indicando que no todas las zonas de riesgo tienen la misma cantidad de carbono.

Tabla 18. *Fugas de carbono aéreo en el área de influencia*

Variable	Total (MgC)	Media (MgC/ha)	Desviación estándar
----------	-------------	----------------	---------------------

Carbono aéreo	400 468 662,72	105,53	23,40
---------------	----------------	--------	-------

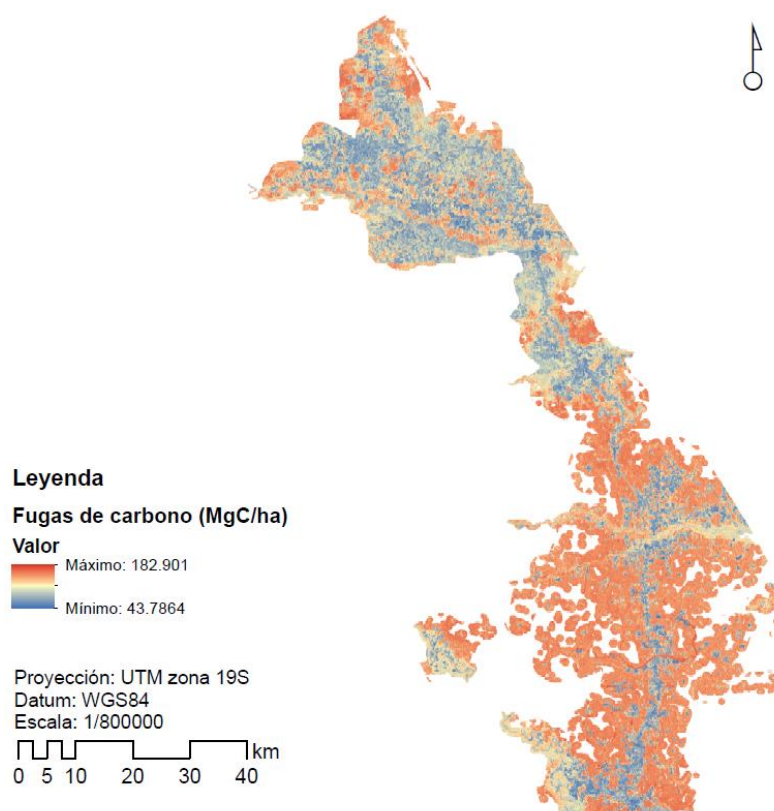


Figura 24. Cinturón y fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa*.

La información sobre identificación (Figura 25) y estimación (Tabla 18) de los cinturones de fugas de carbono son importantes para la gestión forestal y la conservación porque permite planificar la protección de los bosques Amazónicos, en especial los bosques concesionados de *B. excelsa*. La cuantificación de 400 468 662,72 MgC en riesgo en el área de influencia es alarmante, ya que evidencia la susceptibilidad de una gran parte de las reservas de carbono y la necesidad urgente de medidas de mitigación.

La metodología desarrollada en la investigación mediante la lógica difusa aplicando el MCE fue demostrada por dos Reis et al. (2023) en su estudio sobre la evaluación de la sostenibilidad, y sustenta la robustez de la metodología para abordar la complejidad y la incertidumbre inherentes a la evaluación de riesgos en ecosistemas, donde el componente fundamental en

MCE es la ponderación de las variables según su influencia en la definición del cinturón de fugas (Tabla 13); en tal sentido, se encuentra que la deforestación (0,2642) y las vías principales (0,2297) que son las variables que más influyen en la determinación del cinturón de fugas, estos hallazgos coinciden con otras investigaciones relacionadas que señalan la infraestructura vial y la expansión de la frontera agrícola como los principales causantes de degradación y deforestación en la Amazonía (Perz et al. 2013; Baraloto et al. 2015; Rutishauser et al. 2015; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023). De igual manera, estudios previos han evidenciado que la construcción de vías de acceso (principales y secundarias) ha permite el acceso en áreas forestales, intensificando la presión sobre los recursos y la deforestación (Chávez et al. 2013; Perz et al. 2016; Klarenberg et al. 2018). Con este mismo criterio, las variables; cercanía a centros poblados y predios agrícolas (con pesos de 0,0972 y 0,1346 respectivamente) resultaron determinantes, debido a que son zonas donde se expande la frontera agrícola y se desarrollan actividades que presionan al bosque (Baraloto et al. 2015; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023). La inclusión de la deforestación pasada en el modelo, la variable más importante, hace que sea un buen predictor de futuras pérdidas de carbono.

La presencia de estas zonas de alto riesgo, ya localizadas en el mapa, hace evidente la necesidad de establecer medidas de control y vigilancia en las zonas más vulnerables. Estas acciones pueden incluir el monitoreo en tiempo real de la deforestación, el fomento de prácticas agrícolas sostenibles en las zonas de amortiguamiento y el fortalecimiento de la gobernanza en las concesiones *B. excelsa* y en toda su área de influencia. Además, la investigación no solo hace posible reconocer y cuantificar fugas de carbono en concesiones de *B. excelsa* y su área de influencia, sino que también ofrece información para políticas y medidas técnicas de conservación y manejo sostenible de bosques en Tahuamanu, Madre de Dios.

CONCLUSIONES

El modelo RF generado en el entrenamiento resultó ser confiable para la estimación espacial de la biomasa aérea, determinando la AGBD media en 241,66 Mg/ha para el área de influencia. En el modelo, las bandas infrarrojas de S2 (B11 y B12) y la altitud (DEM) fueron las variables más importantes, estos hallazgos representa una base para el manejo y seguimiento del ecosistema. Sin embargo, el desempeño del modelo en la validación ($R^2 = 0,262$) indica un sobreajuste que podría comprometer su capacidad para generalizar a nuevas aplicaciones.

La AGBD media en las concesiones de *B. excelsa* fue de 241,08 Mg/ha, lo que demuestra que estas concesiones tienen un stock de biomasa similar al bosque circundante.

El área de influencia cuantifico un total de 1 993 370 696,62 MgC con una densidad media de 120,83 MgC/ha, confirmando la importancia de la zona como sumidero de carbono.

Las concesiones de *B. excelsa* cuentan con reservorios de carbono por un total de 155 411 610,95 MgC, con una densidad media de 120,54 MgC/ha, valor similar a la zona de influencia, lo que demuestra su importancia para la conservación de carbono en un contexto de manejo sustentable. El análisis multicriterio localizó el cinturón de escape de carbono en el área de influencia, donde la deforestación pasada y la cercanía a vías de acceso fueron los principales factores de riesgo.

Las fugas de carbono aéreo fueron de 400 468 662,72 MgC en zonas de riesgo, demostrando la vulnerabilidad de una porción importante de las reservas de carbono de la región y que debe alertar a los tomadores de decisiones para establecer medidas efectivas de mitigación y monitoreo.

La principal limitación proviene del diseño, la estimación del AGBD se llevó a cabo utilizando un modelo de RF, donde una de las variables GEDI L4B se utilizó como variable dependiente. Debido a que GEDI L4B es esencialmente la salida de otro modelo de estimación indirecta, esta dependencia jerárquica resulta en la propagación y acumulación de los errores intrínsecos del modelo

fuente en la salida final. En gran medida, este fenómeno metodológico explica los problemas de generalización y sobreajuste que destacan la dificultad para lograr predicciones altamente precisas a partir de síntesis de modelos dentro de ecosistemas heterogéneos. Es así, que el modelo en estudio debe entenderse como una herramienta analítica preliminar para la exploración de tendencias y zonificación, en lugar de un método de cuantificación absoluta altamente preciso.

Se acepta la hipótesis nula, donde la fusión de datos espaciales GEDI 4B con Sentinel-1, -2 y un DEM en un modelo de RF no permite estimar la densidad de biomasa aérea con una precisión definida por un R^2 de validación superior a 0,60 y un rRMSE inferior a 27,26%, ni las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *B. excelsa*, Tahuamanu – Madre de Dios. Sin embargo, el modelo debe seguir perfeccionándose, con una mayor densidad de puntos de entrenamiento o con técnicas de validación más robustas, para convertirse en una herramienta estandarizada y eficiente para el monitoreo forestal a gran escala.

SUGERENCIAS

Se sugiere que los mapas de biomasa, carbono y riesgo de fugas generados en este estudio sean utilizados como herramientas clave para la planificación territorial y la gestión sostenible en las concesiones de *B. excelsa* y en el área de influencia. Es crucial priorizar la protección de las zonas identificadas con altas reservas de carbono y, especialmente, las áreas dentro del cinturón de fugas de carbono para mitigar la deforestación y degradación. Esto informaría directamente las estrategias de conservación y los programas REDD+, asegurando la continuidad de los servicios ecosistémicos de la región.

Para futuras investigaciones, se sugiere abordar la limitación del sobreajuste del modelo de biomasa mediante la exploración de conjuntos de datos de entrenamiento más amplios y diversos, o la evaluación de algoritmos avanzados, un monitoreo temporal de las fugas de carbono también sería valioso para comprender la dinámica de la pérdida de carbono y adaptar las estrategias de manejo de manera proactiva.

REFERENCIAS BIBLIOGRÁFICAS

ADRAH, E., MOHD JAAFAR, W. S. W., BAJAJ, S., OMAR, H., LEITE, R. V., SILVA, C. A., CARDIL, A. Y MOHAN, M. Analyzing canopy height variations in secondary tropical forests of Malaysia using NASA GEDI. IOP Conference Series: Earth and Environmental Science, 2021/10/01 2021, 880(1), 012031. doi:<https://doi.org/10.1088/1755-1315/880/1/012031>

ALARCON-AGUIRRE, G., CANAHUIRE, R. R., GUEVARRA, F. M. G., RODRIGUEZ, L., GALLEGOS, L. E. Y GARATE-QUISPE, J. Dinámica de la pérdida de bosques en el sureste de la Amazonia peruana: un estudio de caso en Madre de Dios. Ecosistemas, 2021, 30(2), 2175-2175. doi:<https://doi.org/10.7818/ECOS.2175>

ALARCON-AGUIRRE, G., MAMANI MAMANI, M., CANAHUIRE-ROBLES, R. R., VASQUEZ ZAVALETA, T., PEÑA VALDEIGLESIAS, J., DIAZ REVOREDO, J., RODRÍGUEZ ACHATA, L., RAMOS ENCISO, D. Y GARATE-QUISPE, J. Forest Loss Related to Brazil Nut Production in Non-Timber Forest Product Concessions in a Micro-Watershed in the Peruvian Amazon. Remote Sensing, 2023, 15(23). doi:10.3390/rs15235438

ALARCÓN-AGUIRRE, G., SAJAMI QUISPE, E., VÁSQUEZ ZAVALETA, T., PONCE TEJADA, L. V., RAMOS ENCISO, D., RODRÍGUEZ ACHATA, L. Y GARATE-QUISPE, J. Vegetation dynamics in lands degraded by gold mining in the southeastern Peruvian Amazon. Trees, Forests and People, 2023/03/01/ 2023, 11, 100369. doi:<https://doi.org/10.1016/j.tfp.2023.100369>

ALARCÓN, G., DÍAZ, J., VELA, M., GARCÍA, M. Y GUTIÉRREZ, J. Deforestación en el sureste de la amazonia del Perú entre los años 1999-2013; caso Regional de Madre de Dios (Puerto Maldonado–Inambari). Journal of High Andean Research, 2016, 18(3), 319-330. doi:<http://dx.doi.org/10.18271/ria.2016.221>

ALI, N. Y KHATI, U. Forest Aboveground Biomass and Forest Height Estimation Over a Sub-tropical Forest Using Machine Learning Algorithm and Synthetic Aperture Radar Data. *Journal of the Indian Society of Remote Sensing*, 2024/04/01 2024, 52(4), 771-786. doi:10.1007/s12524-024-01821-5

ANJI-REDDY, M. *Geographical Information System*. 3rd Edition, BS Publication, Hyderabad, 2010.

ASNER, G. P. High-resolution forest carbon stocks and emissions in the Peruvian Amazon. *Proceedings of the National Academy of Sciences*, 2010, 107(15), 16738-16742. doi:10.1073/pnas.1004875107

ASNER, G. P., POWELL, G. V. N., MASCARO, J., KNAPP, D. E., CLARK, J. K., JACOBSON, J., KENNEDY-BOWDOIN, T., BALAJI, A., PAEZ-ACOSTA, G., VICTORIA, E., SECADA, L., VALQUI, M. Y HUGHES, R. F. High-resolution forest carbon stocks and emissions in the Amazon. *Proceedings of the National Academy of Sciences*, 2010/09/21 2010, 107(38), 16738-16742. doi:10.1073/pnas.1004875107

BARALOTO, C., ALVERGA, P., QUISPE, S. B., BARNES, G., CHURA, N. B., DA SILVA, I. B., CASTRO, W., DA SOUZA, H., DE SOUZA MOLL, I. E., DEL ALCAZAR CHILO, J., LINARES, H. D., QUISPE, J. G., KENJI, D., MARSIK, M., MEDEIROS, H., MURPHY, S., ROCKWELL, C., SELAYA, G., SHENKIN, A., SILVEIRA, M., SOUTHWORTH, J., VASQUEZ COLOMO, G. H. Y PERZ, S. Effects of road infrastructure on forest value across a tri-national Amazonian frontier. *Biological conservation*, 2015/11/01/ 2015, 191, 674-681. doi:<https://doi.org/10.1016/j.biocon.2015.08.024>

BENTE, E., SHANE, W., ZACHARY, D., PETE, D., DEMETRIOS, P., BARRY, C., PETE, M., JOHN, H., PATRICK, T., LUIS, R.-I. Y BRYAN, B. Global Ecosystem Dynamics Investigation (GEDI) instrument alignment and test. In *Proc.SPIE*. 2019, vol. 11103, p. 1110308.

BREIMAN, L. Bagging predictors. *Machine learning*, 1996/08/01 1996, 24(2), 123-140. doi:10.1007/BF00058655

BREIMAN, L. Random forest, vol. 45. *Mach Learn*, 2001a, 1. doi:10.1017/CBO9781107415324.004

BREIMAN, L. Random forests. *Machine learning*, 2001b, 45(1), 5-32. doi:<https://doi.org/10.1023/A:1010933404324>

CHÁVEZ, A., HUAMANI, L., FERNANDEZ, R., BEJAR, N., VALERA, F., PERZ, S., BROWN, I., DOMÍNGUEZ, S., PINEDO, R. Y ALARCÓN, G. Regional Deforestation Trends within Local Realities: Land-Cover Change in Southeastern Peru 1996–2011. *Land*, 2013, 2(2), 131. doi:<https://doi.org/10.3390/land2020131>

CHAZDON, R. L., BRANCALION, P. H. S., LAESTADIUS, L., BENNETT-CURRY, A., BUCKINGHAM, K., KUMAR, C., MOLL-ROCEK, J., VIEIRA, I. C. G. Y WILSON, S. J. When is a forest a forest? Forest concepts and definitions in the era of forest and landscape restoration. *Ambio*, 2016/09/01 2016, 45(5), 538-550. doi:10.1007/s13280-016-0772-y

CHUVIECO, E. *Fundamentals of satellite remote sensing: An environmental approach*. Edtion ed.: CRC press, 2016. ISBN 1498728073.

CLARK, P. Y NIBLETT, T. *Machine learning*. In.: Boston: Kluwer Academic Publishers, 1992.

CORTE, A. P., DA CUNHA NETO, E. M., REX, F. E., SOUZA, D., BEHLING, A., MOHAN, M., SANQUETTA, M. N., SILVA, C. A., KLAUBERG, C., SANQUETTA, C. R., VERAS, H. F., DE ALMEIDA, D. R., PRATA, G., ZAMBRANO, A. M., TRAUTENMÜLLER, J. W., DE MORAES, A., KARASINSKI, M. A. Y BROADBENT, E. N. High-Density UAV-LiDAR in an Integrated Crop-Livestock-Forest System: Sampling Forest Inventory or Forest

Inventory Based on Individual Tree Detection (ITD). *Drones* [Type of Work]. 2022, vol. 6, no. 2. ISSN 2504-446X. doi:10.3390/drones6020048.

CSILLIK, O. Y ASNER, G. P. Near-real time aboveground carbon emissions in Peru. *PloS one*, 2020, 15(11), e0241418. doi:10.1371/journal.pone.0241418

DI TOMMASO, S., WANG, S. Y LOBELL, D. B. Combining GEDI and Sentinel-2 for wall-to-wall mapping of tall and short crops. *Environmental Research Letters*, 2021/11/18 2021, 16(12), 125002. doi:10.1088/1748-9326/ac358c

DORADO-RODA, I., PASCUAL, A., GODINHO, S., SILVA, C. A., BOTEQUIM, B., RODRÍGUEZ-GONZÁLVEZ, P., GONZÁLEZ-FERREIRO, E. Y GUERRA-HERNÁNDEZ, J. Assessing the Accuracy of GEDI Data for Canopy Height and Aboveground Biomass Estimates in Mediterranean Forests. *Remote Sensing*, 2021, 13(12). doi:10.3390/rs13122279

DOS REIS, J. C., RODRIGUES, G. S., DE BARROS, I., DE ARAGÃO RIBEIRO RODRIGUES, R., GARRETT, R. D., VALENTIM, J. F., KAMOI, M. Y. T., MICHETTI, M., WRUCK, F. J. Y RODRIGUES-FILHO, S. Fuzzy logic indicators for the assessment of farming sustainability strategies in a tropical agricultural frontier. *Agronomy for Sustainable Development*, 2023/01/04 2023, 43(1), 8. doi:10.1007/s13593-022-00858-5

DOUROJEANNI, M. *Estudio de caso sobre la carretera interoceánica en la Amazonía Sur del Perú*. Edtion ed.: Conservación Internacional Perú, 2006.

DUBAYAH, R., ARMSTON, J., HEALEY, S. P., BRUENING, J. M., PATTERSON, P. L., KELLNER, J. R., DUNCANSON, L., SAARELA, S., STÅHL, G., YANG, Z., TANG, H., BLAIR, J. B., FATOYINBO, L., GOETZ, S., HANCOCK, S., HANSEN, M., HOFTON, M., HURTT, G. Y LUTHCKE, S. GEDI launches a new era of biomass inference from space. *Environmental Research Letters*, 2022/08/18 2022, 17(9), 095001. doi:10.1088/1748-9326/ac8694

DUBAYAH, R., BLAIR, J. B., GOETZ, S., FATOYINBO, L., HANSEN, M., HEALEY, S., HOFTON, M., HURTT, G., KELLNER, J., LUTHCKE, S., ARMSTON, J., TANG, H., DUNCANSON, L., HANCOCK, S., JANTZ, P., MARSELIS, S., PATTERSON, P. L., QI, W. Y SILVA, C. The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. *Science of Remote Sensing*, 2020/06/01/2020, 1, 100002. doi:<https://doi.org/10.1016/j.srs.2020.100002>

DUNCANSON, L., KELLNER, J. R., ARMSTON, J., DUBAYAH, R., MINOR, D. M., HANCOCK, S., HEALEY, S. P., PATTERSON, P. L., SAARELA, S., MARSELIS, S., SILVA, C. E., BRUENING, J., GOETZ, S. J., TANG, H., HOFTON, M., BLAIR, B., LUTHCKE, S., FATOYINBO, L., ABERNETHY, K., ALONSO, A., ANDERSEN, H.-E., APLIN, P., BAKER, T. R., BARBIER, N., BASTIN, J. F., BIBER, P., BOECKX, P., BOGAERT, J., BOSCHETTI, L., BOUCHER, P. B., BOYD, D. S., BURSLEM, D. F. R. P., CALVO-RODRIGUEZ, S., CHAVE, J., CHAZDON, R. L., CLARK, D. B., CLARK, D. A., COHEN, W. B., COOMES, D. A., CORONA, P., CUSHMAN, K. C., CUTLER, M. E. J., DALLING, J. W., DALPONTE, M., DASH, J., DE-MIGUEL, S., DENG, S., ELLIS, P. W., ERASMUS, B., FEKETY, P. A., FERNANDEZ-LANDA, A., FERRAZ, A., FISCHER, R., FISHER, A. G., GARCÍA-ABRIL, A., GOBAKKEN, T., HACKER, J. M., HEURICH, M., HILL, R. A., HOPKINSON, C., HUANG, H., HUBBELL, S. P., HUDAK, A. T., HUTH, A., IMBACH, B., JEFFERY, K. J., KATOH, M., KEARSLEY, E., KENFACK, D., KLJUN, N., KNAPP, N., KRÁL, K., KRŮČEK, M., LABRIÈRE, N., LEWIS, S. L., LONGO, M., LUCAS, R. M., MAIN, R., MANZANERA, J. A., MARTÍNEZ, R. V., MATHIEU, R., MEMIAGHE, H., MEYER, V., MENDOZA, A. M., MONERRIS, A., MONTESANO, P., MORSDORF, F., NÆSSET, E., NAIDOO, L., NILUS, R., O'BRIEN, M., ORWIG, D. A., PAPATHANASSIOU, K., PARKER, G., PHILIPSON, C., PHILLIPS, O. L., PISEK, J., POULSEN, J. R., PRETZSCH, H., RÜDIGER, C., SAATCHI, S., SANCHEZ-AZOFEIFA, A., SANCHEZ-LOPEZ, N., SCHOLE, R., SILVA, C. A., SIMARD, M., SKIDMORE, A., STERENÍCZAK, K., TANASE, M., TORRESAN, C., VALBUENA, R., VERBEECK, H., VRSKA, T., WESSELS, K., WHITE, J. C., WHITE, L. J. T., ZAHABU, E. Y ZGRAGGEN, C.

Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. *Remote Sensing of Environment*, 2022/03/01/ 2022, 270, 112845. doi:<https://doi.org/10.1016/j.rse.2021.112845>

DUNCANSON, L., NEUENSCHWANDER, A., HANCOCK, S., THOMAS, N., FATOYINBO, T., SIMARD, M., SILVA, C. A., ARMSTON, J., LUTHCKE, S. B., HOFTON, M., KELLNER, J. R. Y DUBAYAH, R. Biomass estimation from simulated GEDI, ICESat-2 and NISAR across environmental gradients in Sonoma County, California. *Remote Sensing of Environment*, 2020/06/01/ 2020, 242, 111779. doi:<https://doi.org/10.1016/j.rse.2020.111779>

EL MASRI, B. Y XIAO, J. Comparison of Global Aboveground Biomass Estimates From Satellite Observations and Dynamic Global Vegetation Models. *Journal of Geophysical Research: Biogeosciences*, 2025/01/01 2025, 130(1), e2024JG008305. doi:<https://doi.org/10.1029/2024JG008305>

ESQUIVEL-MARTÍNEZ, J. M., EXPÓSITO-CASTILLO, J. L., ESTELLER-ALBERICH, M. V., GÓMEZ-ALBORES, M. A., MEDINA-RIVAS, C. M. Y FONSECA-ORTIZ, C. R. Prioritization of areas for groundwater monitoring using analytic hierarchy process method in Geographic Information Systems: a case of Mexico. *International Journal of Environmental Science and Technology*, 2023/06/01 2023, 20(6), 5965-5982. doi:10.1007/s13762-022-04383-6

FAO. FRA 2015: Terms and Definitions. 2012.

FRAMPTON, W. J., DASH, J., WATMOUGH, G. Y MILTON, E. J. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2013/08/01/ 2013, 82, 83-92. doi:<https://doi.org/10.1016/j.isprsjprs.2013.04.007>

FU, S. Y WANG, L. GPU-based unresolved LBM-DEM for fast simulation of gas–solid flows. *Chemical Engineering Journal*, 2023/06/01/ 2023, 465, 142898. doi:<https://doi.org/10.1016/j.cej.2023.142898>

GEE. Google Earth Engine. In. Estados Unidos de America, 2021, vol. 2021, p. A planetary-scale platform for Earth science data & analysis - Powered by Google's cloud infrastructure.

GOREMAD Y IIAP. Macro Zonificación Ecológica Económica de Madre de Dios. In G.D.R.N.Y.M. AMBIENTE. Madre de Dios - Perú, 2009, p. 208.

GUO, Q., DU, S., JIANG, J., GUO, W., ZHAO, H., YAN, X., ZHAO, Y. Y XIAO, W. Combining GEDI and sentinel data to estimate forest canopy mean height and aboveground biomass. *Ecological Informatics*, 2023/12/01/ 2023, 78, 102348. doi:<https://doi.org/10.1016/j.ecoinf.2023.102348>

HEALEY, S. P., YANG, Z., GORELICK, N. Y ILYUSHCHENKO, S. Highly Local Model Calibration with a New GEDI LiDAR Asset on Google Earth Engine Reduces Landsat Forest Height Signal Saturation. *Remote Sensing*, 2020, 12(17). doi:10.3390/rs12172840

HODAM, H., RIENOW, A. Y JUERGENS, C. Developing and Evaluating Simplified Tools for Image Processing in a Problem-Based Learning Environment for Earth Observation. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 2022/10/01 2022, 90(5), 439-456. doi:10.1007/s41064-022-00211-1

HOFFRÉN, R., LAMELAS, M. T., DE LA RIVA, J., DOMINGO, D., MONTEALEGRE, A. L., GARCÍA-MARTÍN, A. Y REVILLA, S. Assessing GEDI-NASA system for forest fuels classification using machine learning techniques. *International Journal of Applied Earth Observation and Geoinformation*, 2023/02/01/ 2023, 116, 103175. doi:<https://doi.org/10.1016/j.jag.2022.103175>

HOFTON, M. A., BLAIR, J. B., STORY, S., TANG, H., SILVA, C. E., ARMSTON, J. D. Y DUBAYAH, R. GEDI Measurements of Topography, Height and 3D Structure Measurements. In., 2020, vol. 2020, p. B029-003.

HUNKA, N., DUNCANSON, L., ARMSTON, J., DUBAYAH, R., HEALEY, S. P., SANTORO, M., MAY, P., ARAZA, A., BOURGOIN, C., MONTESANO, P. M., NEIGH, C. S. R., GRANTHAM, H., POTAPOV, P., TURUBANOVA, S., TYUKAVINA, A., RICHTER, J., HARRIS, N., URBAZAEV, M., PASCUAL, A., SUAREZ, D. R., HEROLD, M., POULTER, B., WILSON, S. N., GRASSI, G., FEDERICI, S., SANZ, M. J. Y MELO, J. Intergovernmental Panel on Climate Change (IPCC) Tier 1 forest biomass estimates from Earth Observation. Scientific data, 2024/10/14 2024, 11(1), 1127. doi:10.1038/s41597-024-03930-9

HUO, L., STRENGBOM, J., LUNDMARK, T., WESTERFELT, P. Y LINDBERG, E. Estimating the conservation value of boreal forests using airborne laser scanning. Ecological Indicators, 2023/03/01/ 2023, 147, 109946. doi:<https://doi.org/10.1016/j.ecolind.2023.109946>

INDIRABAI, I. Y NILSSON, M. Estimation of above ground biomass in tropical heterogeneous forests in India using GEDI. Ecological Informatics, 2024/09/01/ 2024, 82, 102712. doi:<https://doi.org/10.1016/j.ecoinf.2024.102712>

ISLAM, S. Y AMIN, S. H. Prediction of probable backorder scenarios in the supply chain using Distributed Random Forest and Gradient Boosting Machine learning techniques. Journal of Big Data, 2020/08/26 2020, 7(1), 65. doi:10.1186/s40537-020-00345-2

JIANG, F., DENG, M., TANG, J., FU, L. Y SUN, H. Integrating spaceborne LiDAR and Sentinel-2 images to estimate forest aboveground biomass in Northern China. Carbon Balance and Management, 2022/09/01 2022, 17(1), 12. doi:10.1186/s13021-022-00212-y

JIAO, Y., WANG, D., YAO, X., WANG, S., CHI, T. Y MENG, Y. Forest Emissions Reduction Assessment Using Optical Satellite Imagery and Space LiDAR Fusion for Carbon Stock Estimation. *Remote Sensing* [Type of Work]. 2023, vol. 15, no. 5. ISSN 2072-4292. doi:10.3390/rs15051410.

KACIC, P., HIRNER, A. Y DA PONTE, E. Fusing Sentinel-1 and -2 to Model GEDI-Derived Vegetation Structure Characteristics in GEE for the Paraguayan Chaco. *Remote Sensing*, 2021, 13(24). doi:10.3390/rs13245105

KACIC, P. Y KUENZER, C. Forest Biodiversity Monitoring Based on Remotely Sensed Spectral Diversity—A Review. *Remote Sensing*, 2022, 14(21). doi:10.3390/rs14215363

KACIC, P., THONFELD, F., GESSNER, U. Y KUENZER, C. Forest Structure Characterization in Germany: Novel Products and Analysis Based on GEDI, Sentinel-1 and Sentinel-2 Data. *Remote Sensing*, 2023, 15(8). doi:10.3390/rs15081969

KLARENBERG, G., MUÑOZ-CARPENA, R., CAMPO-BESCÓS, M. A. Y PERZ, S. G. Highway paving in the southwestern Amazon alters long-term trends and drivers of regional vegetation dynamics. *Heliyon*, 2018/08/01/ 2018, 4(8), e00721. doi:<https://doi.org/10.1016/j.heliyon.2018.e00721>

KODIHAL, S. Y AKHTAR, M. P. Sustainable Groundwater Recharge Potential Zone Identification: An AHP-OWA Approach Integrating Future Rainfall and Land-Use Projections. *Water Resources Management*, 2024/02/01 2024, 38(3), 1079-1098. doi:10.1007/s11269-023-03710-x

KULKARNI, A. D. Y LOWE, B. Random forest algorithm for land cover classification 2016. doi:<http://hdl.handle.net/10950/341>

KUZMINOV, A., SAKHAROVA, L., STRYUKOV, M. Y ZOLNIKOV, V. Methods of assessing the effectiveness of reforestation based on the theory of fuzzy

sets. IOP Conference Series: Earth and Environmental Science, 2020/11/01 2020, 595(1), 012007. doi:10.1088/1755-1315/595/1/012007

LAGOUVARDOU, S. Y PSARAFTIS, H. N. Implications of the EU Emissions Trading System (ETS) on European container routes: A carbon leakage case study. *Maritime Transport Research*, 2022/01/01/ 2022, 3, 100059. doi:<https://doi.org/10.1016/j.martra.2022.100059>

LAHSSINI, K., BAGHDADI, N., LE MAIRE, G. Y FAYAD, I. Influence of GEDI Acquisition and Processing Parameters on Canopy Height Estimates over Tropical Forests. *Remote Sensing*, 2022, 14(24). doi:10.3390/rs14246264

LANG, N., KALISCHEK, N., ARMSTON, J., SCHINDLER, K., DUBAYAH, R. Y WEGNER, J. D. Global canopy height regression and uncertainty estimation from GEDI LIDAR waveforms with deep ensembles. *Remote Sensing of Environment*, 2022/01/01/ 2022, 268, 112760. doi:<https://doi.org/10.1016/j.rse.2021.112760>

LEÓN, R. A. H. Y GONZÁLEZ, S. C. *El proceso de investigación científica*. Edtion ed.: Editorial Universitaria (Cuba), 2020. ISBN 9591613075.

LI, C., LI, M., LI, Y. Y QIAN, P. Estimating aboveground forest carbon density using Landsat 8 and field-based data: a comparison of modelling approaches. *International journal of remote sensing*, 2020/06/02 2020, 41(11), 4269-4292. doi:10.1080/01431161.2020.1714782

LONG, J., LIN, H., WANG, G., SUN, H. Y YAN, E. Estimating the Growing Stem Volume of the Planted Forest Using the General Linear Model and Time Series Quad-Polarimetric SAR Images. *Sensors* [Type of Work]. 2020, vol. 20, no. 14. ISSN 1424-8220. doi:10.3390/s20143957.

LOZANO, N. S. M., BAQUE, D. L. Z., TERÁN, A. B. I., PARRALES, R. A. Á., ALCÍVAR, H. A. G., BRAVO, H. M. T., BRAVO, B. J. P. Y ROBLES, N. A. P.

Metodología de la Investigación Científica: Diseño de Investigaciones Cuantitativas. Editorial Internacional Alema, 2025.

LULLA, K., NELLIS, M. D., RUNDQUIST, B., SRIVASTAVA, P. K. Y SZABO, S. Mission to earth: LANDSAT 9 will continue to view the world. In.: Taylor & Francis, 2021, vol. 36, p. 2261-2263.

LUTZ, N., RODRIGUEZ-VEIGA, P. Y OLIVERAS MENOR, I. Estimating vegetation structure and aboveground carbon storage in Western Australia using GEDI LiDAR, Landsat and Sentinel data. Environmental Research: Ecology, 2024/11/08 2024, 3(4), 045004. doi:10.1088/2752-664X/ad7f5a

MA, T., ZHANG, C., JI, L., ZUO, Z., BECKLINE, M., HU, Y., LI, X. Y XIAO, X. Development of forest aboveground biomass estimation, its problems and future solutions: A review. Ecological Indicators, 2024/02/01/ 2024, 159, 111653. doi:<https://doi.org/10.1016/j.ecolind.2024.111653>

MALHI, Y., BAKER, T. R., PHILLIPS, O. L., ALMEIDA, S., ALVAREZ, E., ARROYO, L., CHAVE, J., CZIMCZIK, C. I., FIORE, A. D., HIGUCHI, N., KILLEEN, T. J., LAURANCE, S. G., LAURANCE, W. F., LEWIS, S. L., MONTOYA, L. M. M., MONTEAGUDO, A., NEILL, D. A., VARGAS, P. N., PATIÑO, S., PITMAN, N. C. A., QUESADA, C. A., SALOMÃO, R., SILVA, J. N. M., LEZAMA, A. T., MARTÍNEZ, R. V., TERBORGH, J., VINCETI, B. Y LLOYD, J. The above-ground coarse wood productivity of 104 Neotropical forest plots. Global Change Biology, 2004/05/01 2004, 10(5), 563-591. doi:<https://doi.org/10.1111/j.1529-8817.2003.00778.x>

MÉLIÈRES, M.-A. Y MARÉCHAL, C. *Climate Change: Past, Present, and Future*. Edtion ed.: John Wiley & Sons, 2015. ISBN 1118708520.

MIGUEL, S., RUIZ-BENITO, P., REBOLLO, P., VIANA-SOTO, A., MIHAI, M. C., GARCÍA-MARTÍN, A. Y TANASE, M. Forest disturbance regimes and trends in continental Spain (1985–2023) using dense landsat time series.

Environmental Research, 2024/12/01/ 2024, 262, 119802.
doi:<https://doi.org/10.1016/j.envres.2024.119802>

MONJARDIN-ARMENTA, S. A., PLATA-ROCHA, W., PACHECO-ANGULO, C. E., FRANCO-OCHOA, C. Y RANGEL-PERAZA, J. G. Geospatial Simulation Model of Deforestation and Reforestation Using Multicriteria Evaluation. *Sustainability* [Type of Work]. 2020, vol. 12, no. 24. ISSN 2071-1050. doi:10.3390/su122410387.

MULLISSA, A., VOLLRATH, A., ODONGO-BRAUN, C., SLAGTER, B., BALLING, J., GOU, Y., GORELICK, N. Y REICHE, J. Sentinel-1 SAR Backscatter Analysis Ready Data Preparation in Google Earth Engine. *Remote Sensing* [Type of Work]. 2021, vol. 13, no. 10. ISSN 2072-4292. doi:10.3390/rs13101954.

MUTANGA, O. Y KUMAR, L. Google earth engine applications. *Remote Sensing*, 2019, 11, Article No. 591. doi:<https://doi.org/10.3390/rs11050591>

NGO, Y.-N., HO TONG MINH, D., BAGHDADI, N. Y FAYAD, I. Tropical Forest Top Height by GEDI: From Sparse Coverage to Continuous Data. *Remote Sensing*, 2023, 15(4). doi:10.3390/rs15040975

PADALIA, H., PRAKASH, A. Y WATHAM, T. Modelling aboveground biomass of a multistage managed forest through synergistic use of Landsat-OLI, ALOS-2 L-band SAR and GEDI metrics. *Ecological Informatics*, 2023/11/01/ 2023, 77, 102234. doi:<https://doi.org/10.1016/j.ecoinf.2023.102234>

PERZ, S., CASTRO, W., ROJAS, R., CASTILLO, J., CHÁVEZ, A., GARCÍA, M., GUADALUPE, Ó., GUTIÉRREZ, T., HURTADO, A., MAMANI, Z., MAYNA, J., MELLO, R., PASSOS, V., REYES, J., SAAVEDRA, M., DE WIT, F., ACUÑA, N., ALARCÓN, G. Y ROJAS, D. La Amazonia como un sistema socio-ecológico: Las dinámicas de cambios complejos humanos y ambientales en una frontera trinacional. In J. POSTIGO Y K. YOUNG eds. *Naturaleza y*

sociedad: Perspectivas socio-ecológicas sobre cambios globales en América Latina. Lima-Perú: desco, IEP e INTE-PUCP, 2016, p. 444.

PERZ, S., QIU, Y., XIA, Y., SOUTHWORTH, J., SUN, J., MARSIK, M., ROCHA, K., PASSOS, V., ROJAS, D., ALARCÓN, G., BARNES, G. Y BARALOTO, C. Trans-boundary infrastructure and land cover change: Highway paving and community-level deforestation in a tri-national frontier in the Amazon. *Land Use Policy*, 2013, 34, 27-41. doi:<http://dx.doi.org/10.1016/j.landusepol.2013.01.009>

PETERS, F., KEMPE, A., KÜBLER, D., GÜNTER, S. Y NEUMEIER, S. Evaluating forest degradation, deforestation, and reforestation in Boeny and DIANA: Current efforts and future opportunities. 2024.

PIR-BAVAGHAR, M., GHAZANFARI, H. Y RAHIMI, S. Comparison of analytical hierarchy process and fuzzy method in deforestation risk zoning. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, 2019, XLII-4/W18, 851-856. doi:10.5194/isprs-archives-XLII-4-W18-851-2019

POTAPOV, P., LI, X., HERNANDEZ-SERNA, A., TYUKAVINA, A., HANSEN, M. C., KOMMAREDDY, A., PICKENS, A., TURUBANOVA, S., TANG, H., SILVA, C. E., ARMSTON, J., DUBAYAH, R., BLAIR, J. B. Y HOFTON, M. Mapping global forest canopy height through integration of GEDI and Landsat data. *Remote Sensing of Environment*, 2021/02/01/ 2021, 253, 112165. doi:<https://doi.org/10.1016/j.rse.2020.112165>

POTIN, P. Sentinel-1 user handbook. In.: European Space Agency (ESA): Paris, France, 2013.

PROGRAMA-MAAP. Deforestación minera en la Amazonía peruana sur en 2023: Informe Madre de Dios. 2024.

PROGRAMA-MAAP. Carbono almacenado en la Amazonía peruana: últimos datos y desafíos para su conservación. 2025.

QUESADA, C. A., LLOYD, J., SCHWARZ, M., PATIÑO, S., BAKER, T. R., CZIMCZIK, C. I., FYLLAS, N. M., MARTINELLI, L., NARDOTO, G., SCHMERLER, J., URIARTE, M. Y ZIMMERMAN, J. K. Variation in aboveground biomass and carbon stored in natural forests of the Peruvian Amazon. *Global Change Biology*, 2010, 16(7), 2133-2156. doi:10.1111/j.1365-2486.2010.02274.x

RAJAB POURRAHMATI, M., BAGHDADI, N. Y FAYAD, I. Comparison of GEDI LiDAR Data Capability for Forest Canopy Height Estimation over Broadleaf and Needleleaf Forests. *Remote Sensing*, 2023, 15(6). doi:10.3390/rs15061522

RISHMAWI, K., HUANG, C. Y ZHAN, X. Monitoring Key Forest Structure Attributes across the Conterminous United States by Integrating GEDI LiDAR Measurements and VIIRS Data. *Remote Sensing* [Type of Work]. 2021, vol. 13, no. 3. ISSN 2072-4292. doi:10.3390/rs13030442.

ROJAS, Y., BAHAMÓNDEZ, V., LOGUERCIO, G. A. Y NIETO, V. *Análisis de la degradación forestal en el marco de REDD+*. Edtion ed.: INFOR, 2011. ISBN 9563180410.

RUTISHAUSER, E., HÉRAULT, B., BARALOTO, C., BLANC, L., DESCROIX, L. Y SOTTA, E. D. Rapid tree carbon stock recovery in managed Amazonian forests. *Curr Biol*, 2015// 2015, 25. doi:10.1016/j.cub.2015.07.034

SABOGAL, C., KROLL, N., DE DEA, V. Y PACHECO, E. Casos de manejo sostenible de concesiones forestales maderables en la Región Madre de Dios, Perú. *Revista Forestal del Perú*, 2024, 39(2), 335-376. doi:<https://doi.org/10.21704/rfp.v39i2.1141>

SCHLUND, M., WENZEL, A., CAMARRETTA, N., STIEGLER, C. Y ERASMI, S. Vegetation canopy height estimation in dynamic tropical landscapes with TanDEM-X supported by GEDI data. *Methods in Ecology and Evolution*, 2022/07/04 2022, n/a(n/a). doi:<https://doi.org/10.1111/2041-210X.13933>

SCHNEIDER, F. D., MORSDORF, F., SCHMID, B., PETCHEY, O. L., HUENI, A., SCHIMEL, D. S. Y SCHAEPMAN, M. E. Mapping functional diversity from remotely sensed morphological and physiological forest traits. *Nature communications*, 2017/11/13 2017, 8(1), 1441. doi:10.1038/s41467-017-01530-3

SCHWARTZ, M., CIAIS, P., OTTLÉ, C., DE TRUCHIS, A., VEGA, C., FAYAD, I., BRANDT, M., FENSHOLT, R., BAGHDADI, N., MORNEAU, F., MORIN, D., GUYON, D., DAYAU, S. Y WIGNERON, J.-P. High-resolution canopy height map in the Landes forest (France) based on GEDI, Sentinel-1, and Sentinel-2 data with a deep learning approach. *International Journal of Applied Earth Observation and Geoinformation*, 2024/04/01/ 2024, 128, 103711. doi:<https://doi.org/10.1016/j.jag.2024.103711>

SENAMHI En la selva preparémonos para la llegada de los friajes 2015. doi:<https://www.senamhi.gob.pe/?p=pronostico-meteorologico>

SHENDRYK, Y. Fusing GEDI with earth observation data for large area aboveground biomass mapping. *International Journal of Applied Earth Observation and Geoinformation*, 2022/12/01/ 2022, 115, 103108. doi:<https://doi.org/10.1016/j.jag.2022.103108>

SILVA, C. A., DUNCANSON, L., HANCOCK, S., KLAUBERG, C., HUDAK, A. T. Y DUBAYAH, R. Estimating forest attributes in industrial Pinus taeda L. Forest plantations in Brazil using simulated NASA's GEDI spaceborne Lidar Data. In *Anais do XIX Simposio Brasileiro de Sensoramento Remoto*. INPE - Santos-SP, Brasil, 2019a.

SILVA, C. A., DUNCANSON, L., HANCOCK, S., NEUENSCHWANDER, A., THOMAS, N., HOFTON, M., FATOYINBO, L., SIMARD, M., MARSHAK, C. Z., ARMSTON, J., LUTCHKE, S. Y DUBAYAH, R. Fusing simulated GEDI, ICESat-2 and NISAR data for regional aboveground biomass mapping.

Remote Sensing of Environment, 2021/02/01/ 2021, 253, 112234.
doi:<https://doi.org/10.1016/j.rse.2020.112234>

SILVA, C. A., VALBUENA, R., PINAGÉ, E. R., MOHAN, M., DE ALMEIDA, D. R. A., NORTH BROADBENT, E., JAAFAR, W. S. W. M., DE ALMEIDA PAPA, D., CARDIL, A. Y KLAUBERG, C. ForestGapR: An r Package for forest gap analysis from canopy height models. *Methods in Ecology and Evolution*, 2019b, 10(8), 1347-1356.

SINGH, R. K., BIRADAR, C. M., BEHERA, M. D., PRAKASH, A. J., DAS, P., MOHANTA, M. R., KRISHNA, G., DOGRA, A., DHYANI, S. K. Y RIZVI, J. Optimising carbon fixation through agroforestry: Estimation of aboveground biomass using multi-sensor data synergy and machine learning. *Ecological Informatics*, 2024/03/01/ 2024, 79, 102408.
doi:<https://doi.org/10.1016/j.ecoinf.2023.102408>

SOTHE, C., GONSAMO, A., LOURENÇO, R. B., KURZ, W. A. Y SNIDER, J. Spatially Continuous Mapping of Forest Canopy Height in Canada by Combining GEDI and ICESat-2 with PALSAR and Sentinel. *Remote Sensing*, 2022, 14(20). doi:10.3390/rs14205158

TAMIMINIA, H., SALEHI, B., MAHDIANPARI, M. Y GOULDEN, T. State-wide forest canopy height and aboveground biomass map for New York with 10 m resolution, integrating GEDI, Sentinel-1, and Sentinel-2 data. *Ecological Informatics*, 2024/03/01/ 2024, 79, 102404.
doi:<https://doi.org/10.1016/j.ecoinf.2023.102404>

TAMIRU, B., SOROMESSA, T., WARKINEH, B. Y LEGESE, G. Modelling selected soil chemical properties using TerrSet and Random Forest: a case of Hangadi watershed, Oromia, Ethiopia. *Geology, Ecology, and Landscapes*, 2024, 1-17. doi:10.1080/24749508.2024.2429842

TIN, H. Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition* [Type of Work]. 1995, vol. 1, pp. 278-282 vol.271. doi:10.1109/ICDAR.1995.598994.

TORRESANI, M., ROCCHINI, D., ALBERTI, A., MOUDRÝ, V., HEYM, M., THOUVERAI, E., KACIC, P. Y TOMELLERI, E. LiDAR GEDI derived tree canopy height heterogeneity reveals patterns of biodiversity in forest ecosystems. *Ecological Informatics*, 2023/09/01/ 2023, 76, 102082. doi:<https://doi.org/10.1016/j.ecoinf.2023.102082>

VALENTE, R. A., DE MELLO, K., METEDIERI, J. F. Y AMÉRICO, C. A multicriteria evaluation approach to set forest restoration priorities based on water ecosystem services. *Journal of Environmental Management*, 2021/05/01/ 2021, 285, 112049. doi:<https://doi.org/10.1016/j.jenvman.2021.112049>

W.W.F. Estimación del carbono en la biomasa aérea de los bosques de Madre de Dios. 2013.

WAMPLER, P. J., REDISKE, R. R. Y MOLLA, A. R. Using ArcMap, Google Earth, and Global Positioning Systems to select and locate random households in rural Haiti. *International Journal of Health Geographics*, 2013/01/18 2013, 12(1), 3. doi:10.1186/1476-072X-12-3

WHITMORE, T. C. Y BURNHAM, C. P. *Tropical rain forests of the Far East*. Edtion ed.: Clarendon Press, 1975. ISBN 0198541279.

ZHANG, F., TIAN, X., ZHANG, H. Y JIANG, M. Estimation of Aboveground Carbon Density of Forests Using Deep Learning and Multisource Remote Sensing. *Remote Sensing*, 2022, 14(13). doi:10.3390/rs14133022

ZHAO, X., HU, W., HAN, J., WEI, W. Y XU, J. Urban Above-Ground Biomass Estimation Using GEDI Laser Data and Optical Remote Sensing Images. *Remote Sensing*, 2024, 16(7). doi:10.3390/rs16071229

ANEXOS

Anexo 1. Matriz de consistencia.

Título: Estimación de las reservas y fugas de carbono aéreo en el área de influencia de concesiones de *Bertholletia excelsa* mediante la fusión de imágenes Sentinel y lidar espacial GEDI, Tahuamanu – Madre de Dios.

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPOTESIS GENERAL	VARIABLES/INDICADORES	METODOLOGÍA
¿Cuánto son las reservas y fugas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i> mediante la fusión de imágenes Sentinel-1, -2, modelo de elevación digital (DEM) y lidar espacial GEDI 4B, Tahuamanu – Madre de Dios en el año 2025?	Estimar las reservas y fugas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i> mediante la fusión de imágenes Sentinel-1, -2, modelo de elevación digital y lidar espacial GEDI 4B, Tahuamanu – Madre de Dios, año 2025.	La fusión de datos espaciales GEDI 4B con Sentinel-1, -2 y un DEM en un modelo de RF no permite estimar eficientemente las la densidad de biomasa, reservas y fugas de carbono aéreo en el área de influencia de concesiones de <i>B. excelsa</i> , Tahuamanu – Madre de Dios.	<p>Variable Dependiente:</p> <p>Reservas de carbono aéreo y fugas de carbono en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios</p> <p>Indicadores:</p> <p>Reservas y fugas de carbono aéreo (Mg C/ha).</p> <p>Variable Independiente:</p> <p>Densidad de biomasa aérea y cinturón de fugas de carbono en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios.</p> <p>Indicadores:</p> <ol style="list-style-type: none"> Densidad de biomasa aérea mínima, máxima y media (Mg/ha). Coefficiente de determinación y error cuadrático medio. Cinturón de fugas de carbono aéreo. 	<p>Diseño: Transaccional (transversal). Tipo: descriptiva, correlacional y predictivo</p> <p>Método:</p> <ol style="list-style-type: none"> Análisis de datos GEDI 4B de 2025. Determinar la densidad de biomasa en base a un modelo de Random Forest de la fusión de datos GEDI L4B con Sentinel-1, -2 y DEM en el área de influencia y concesiones de <i>B. excelsa</i>. Precisión del modelo mediante el coeficiente de determinación, error cuadrático medio. Determinar el cinturón de fugas de carbono mediante técnicas de lógica difusa. Estimar las reservas y fugas de carbono en el área de influencia y concesiones de <i>B. excelsa</i>. <p>Población y muestra: La población estará conformada por las concesiones de <i>B. excelsa</i> de la provincia de Tahuamanu (148 concesiones con aproximadamente 113 181,07 ha) y su área de influencia (1 450 717,05 ha). El cálculo del número de muestras estará en función a la superposición de huellas de datos GEDI con el área de influencia de las concesiones de castaña de la provincia de Tahuamanu.</p>
PROBLEMAS ESPECIFICOS	OBJETIVOS ESPECÍFICOS			
<p>P.E.1 ¿Cuánto es la densidad de biomasa aérea mediante un modelo basado en Random Forest de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y modelo de elevación digital en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios?</p> <p>P.E.2 ¿Qué cantidad es la densidad de biomasa aérea mediante un modelo basado en Random Forest de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y un DEM en concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios?</p> <p>P.E.3 ¿Cuánto son las reservas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios?</p> <p>P.E.4 ¿Qué cantidad es la reserva de carbono aéreo en concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios?</p> <p>P.E.5 ¿Cuál es el cinturón de fugas de carbono aéreo mediante técnicas de lógica difusa en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios?</p> <p>P.E.6 ¿Cuánto son las fugas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios?</p>	<p>O.E.1 Determinar la densidad de biomasa aérea mediante un modelo basado en Random Forest de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y modelo de elevación digital (DEM) en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios.</p> <p>O.E.2 Cuantificar la densidad de biomasa aérea mediante un modelo basado en Random Forest (RF) de la fusión de datos GEDI nivel 4B con Sentinel-1, -2 y un DEM en concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios.</p> <p>O.E.3 Determinar las reservas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios.</p> <p>O.E.4 Cuantificar las reservas de carbono aéreo en concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios.</p> <p>O.E.5 Determinar el cinturón de fugas de carbono aéreo mediante técnicas de lógica difusa en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios.</p> <p>O.E.6 Estimar las fugas de carbono aéreo en el área de influencia de concesiones de <i>Bertholletia excelsa</i>, Tahuamanu – Madre de Dios.</p>			

Anexo 2. Panel fotográfico para establecer lógica difusa y jerarquía analítica.



Foto 1. Visita de campo de vías de acceso.



Foto 2. Áreas agrícolas



Foto 3. Concesiones de castaña.



Foto 4. Concesiones de castaña.



Foto 5. Área de influencia.



Foto 6. Áreas deforestadas.



Foto 6. Tala selectiva.



Foto 6. Tala selectiva y vía fluvial.