

**UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE
DE DIOS**

FACULTAD DE INGENIERÍA

**ESCUELA ACADÉMICO PROFESIONAL DE
INGENIERÍA FORESTAL Y MEDIO AMBIENTE**



TESIS

**“Análisis de la deforestación y degradación forestal sobre
la incertidumbre de las estimaciones de carbono
forestal en la Amazonia de Madre de Dios”**

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

AUTOR(ES):

Bach. AGUILAR CAYULLA, Flor de
Guadalupe

Bach. RAMOS FIGUEROA,
Yoshiro Fernando

ASESOR:

Dr. Gabriel Alarcón Aguirre

Puerto Maldonado, abril de 2026

**UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE
DE DIOS**

FACULTAD DE INGENIERÍA

**ESCUELA ACADÉMICO PROFESIONAL DE
INGENIERÍA FORESTAL Y MEDIO AMBIENTE**



TESIS

**“Análisis de la deforestación y degradación forestal sobre
la incertidumbre de las estimaciones de carbono
forestal en la Amazonia de Madre de Dios”**

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

AUTORES:

Bach. AGUILAR CAYULLA, Flor de
Guadalupe

Bach. RAMOS FIGUEROA,
Yoshiro Fernando

ASESOR:

Dr. Gabriel Alarcón Aguirre

Puerto Maldonado, abril de 2026

RST-RI_Análisis de la deforestación y degradación forestal sobre la incertidumbre de las estimaciones de carbono forestal en la Amazonia de Madre de Dios

INFORME DE ORIGINALIDAD

19%

INDICE DE SIMILITUD

19%

FUENTES DE INTERNET

2%

PUBLICACIONES

1%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1

repositorio.unamad.edu.pe

Fuente de Internet

19%

Excluir citas

Activo

Excluir coincidencias < 1%

Excluir bibliografía

Activo

DEDICATORIA

Dedico esta tesis a mis padres, Eustaquio Aguilar Santa Cruz y Guadalupe Cayulla Melo, por su constante apoyo, amor y ejemplo de fortaleza familiar.

A mi hermana y a la sobrina que está por nacer, quienes llenan mi vida de esperanza y motivación para seguir adelante.

Al Dr. Gabriel Alarcón Aguirre, por su valiosa guía, paciencia y compromiso durante el desarrollo de este trabajo.

Y a mis amigos y a todas aquellas personas que, de una u otra forma, creyeron en mí y en este proyecto. Gracias por estar presentes.

Flor de Guadalupe

A Dios, por otorgarme la vida, la fortaleza y la sabiduría necesarias para superar cada desafío a lo largo de este camino académico.

A mis padres, Rossemay Figueroa García y Raymundo Tinta Otoronco, y a mis hermanos, Uziel y Katheryn, por su amor incondicional, su guía constante y el apoyo invaluable que me han brindado en cada etapa de mi vida. Su ejemplo de esfuerzo, perseverancia y compromiso ha sido mi principal fuente de inspiración.

A mis docentes y mentores, por compartir generosamente sus conocimientos y por su compromiso constante a lo largo de mi formación. Su guía, paciencia y dedicación marcaron de manera especial mi paso por la universidad, y fueron fundamentales para construir no solo al profesional, sino también a la persona que hoy culmina esta etapa.

A mis amigos y compañeros, por su compañía, respaldo y por estar presentes tanto en los momentos de dificultad como en los logros alcanzados.

Y finalmente, a mí mismo, por mantenerme firme, por confiar en mis capacidades y por haber recorrido este camino con determinación, responsabilidad y pasión.

Yoshiro Fernando

AGRADECIMIENTOS

Quisiera expresar mi más sincero agradecimiento a mis padres, Eustaquio Aguilar Santa Cruz y Guadalupe Aguilar Cayulla, por su apoyo incondicional, su ejemplo de perseverancia y por haberme brindado siempre las herramientas necesarias para alcanzar mis metas.

A mi hermana, zhenida Aguilar Cayulla, por su constante respaldo, motivación y comprensión durante los momentos de mayor desafío. Su apoyo ha sido un pilar esencial en mi formación personal y profesional.

A mi asesor Dr. Gabriel Alarcón Aguirre, quien con su conocimiento y dedicación enriquecieron mi aprendizaje y contribuyeron decisivamente a la culminación de este trabajo.

Finalmente, agradezco a mis amigos y a todas las personas que, de manera directa o indirecta, colaboraron y creyeron en este proyecto.

Flor de Guadalupe

Al mirar hacia atrás y ver todo lo recorrido, no puedo evitar sentirme profundamente agradecido con quienes han sido parte de este camino. Este logro no es solo mío; es el resultado de muchas manos, palabras, silencios y gestos que me acompañaron en cada etapa.

Primero, gracias a Dios, por darme la vida y la fuerza necesarias para seguir adelante incluso en los momentos más difíciles. Sin su guía, este camino hubiera sido muy distinto.

A mis padres, Rossemay Figueroa García y Raymundo Tinta Otoronco, y a mis hermanos, Uziel y Katheryn: gracias por estar siempre ahí, por su apoyo sin condiciones, por sus consejos, por la fe que tuvieron en mí incluso cuando yo mismo dudaba. Ustedes han sido mi motor, mi ancla y mi impulso.

A mis profesores y mentores, quienes más allá de enseñar, supieron orientar. Gracias por compartir sus conocimientos con paciencia y por sembrar en mí no solo aprendizajes técnicos, sino también valores que me acompañarán toda la vida.

A mis amigos y compañeros de estudio, por las risas, las traspachadas, las frustraciones compartidas y los logros celebrados. Nadie llega solo a la meta, y tenerlos cerca hizo la diferencia.

Y a mí mismo: gracias por no rendirte. Por seguir, incluso cuando parecía que no se podía más. Por creer, aunque a veces costara. Por haberlo dado todo, con responsabilidad, pasión y coraje.

Este título es la prueba de que los sueños, cuando se trabajan con perseverancia, sí se cumplen. Y si algo aprendí en todo este proceso, es que vale la pena el esfuerzo.

Yoshiro Fernando

RESUMEN

El estudio desarrolló una metodología multimodal con el objetivo general de analizar la clasificación de la deforestación y la degradación forestal para evaluar la incertidumbre de las estimaciones de carbono forestal aéreo, este enfoque combinó datos de los satélites Sentinel-1, Sentinel-2, y del sensor GEDI, junto con datos topográficos de elevación y pendiente, en los bosques del sureste de la Amazonía de Madre de Dios durante el año 2025. Inicialmente se clasificó la cobertura del suelo mediante el Análisis de Mezcla Espectral y el Índice de Fracción de Diferencia Normalizada. La cartografía de clasificación demostró una alta precisión con una exactitud global del 83,90% y un coeficiente Kappa de 0,758, en el que la deforestación fue la perturbación predominante, afectando 164 282,65 ha mientras que la degradación forestal con 31 723,24 ha. El modelo utilizó el algoritmo Random Forest, que permitió predecir la biomasa forestal aérea, si bien el modelo mostró un rendimiento aceptable en el entrenamiento ($R^2= 0,781$), la validación ($R^2= 0,374$) presentó un sobreajuste, con un Error Cuadrático Medio de 71,83 Mg/ha. La cuantificación del carbono forestal aéreo determinó que la mayor cantidad se encuentra en el bosque intacto con 1 540 179 765,89 MgC (con una densidad de 100,08 MgC/ha), seguida de deforestación con 119 207 455,2 MgC (63,92 MgC/ha), y bosques degradados con 31 237 175,67 MgC (86,5 MgC/ha). El análisis de la incertidumbre demostró que los errores de clasificación y el sobreajuste del modelo de biomasa se acumulan, afectando la fiabilidad de las estimaciones de carbono, creando la necesidad de continuar mejorando estas metodologías para lograr un monitoreo más preciso y confiable.

Palabras clave: GEDI L4B, sensor óptico, sensor de radar, Random Forest, Biomasa forestal aérea, carbono forestal aérea.

ABSTRACT

The study developed a multimodal methodology with the overall objective of analyzing the classification of deforestation and forest degradation to assess the uncertainty of aboveground forest carbon estimates. This approach combined data from the Sentinel-1 and Sentinel-2 satellites and the GEDI sensor, along with topographic elevation and slope data, in the forests of southeastern Amazonia in Madre de Dios during 2025. Initially, land cover was classified using Spectral Mixture Analysis and the Normalized Difference Fraction Index. The classification mapping demonstrated high accuracy, with an overall accuracy of 83.90% and a Kappa coefficient of 0.758, in which deforestation was the predominant disturbance, affecting 164,282.65 ha, while forest degradation covered 31,723.24 ha. The model used the Random Forest algorithm, which allowed it to predict aboveground forest biomass; although the model showed acceptable performance during training ($R^2 = 0.781$), validation ($R^2 = 0.374$) exhibited overfitting, with a Root Mean Squared Error of 71.83 Mg/ha. The quantification of aboveground forest carbon determined that the largest amount is found in intact forest, with 1,540,179,765.89 MgC (at a density of 100.08 MgC/ha), followed by deforested areas with 119,207,455.2 MgC (63.92 MgC/ha), and degraded forests with 31,237,175.67 MgC (86.5 MgC/ha). The uncertainty analysis demonstrated that classification errors and overfitting of the biomass model accumulate, affecting the reliability of carbon estimates and creating the need to continue improving these methodologies to achieve more accurate and reliable monitoring.

Keywords: GEDI L4B, optical sensor, radar sensor, Random Forest, aboveground forest biomass, aboveground forest carbon

INTRODUCCIÓN

Los bosques de la Amazonia representan alrededor del 24-32% del carbono forestal (CF) en todos los bosques tropicales del mundo y albergan entre el 15 y el 20% de las especies terrestres, a pesar de cubrir solo el 3,7% de la tierra (Araujo et al. 2023; Rangel et al. 2023). A nivel de bosques Amazónicos, Madre de Dios representa aproximadamente 2,1-2,8% del CF (Csillik et al. 2019; Csillik y Asner 2020; Garate-Quispe et al. 2024). La deforestación, la tala selectiva, los incendios y la fragmentación han alterado enormemente los bosques en las últimas décadas en la Amazonia (Maxwell et al. 2019; Bullock et al. 2020c; Aquino et al. 2022; Rangel et al. 2023). Los bosques secundarios y degradados cubren más área hoy en día que los bosques intactos, aunque la extensión total de la degradación de los bosques Amazónicos es muy incierta (Maxwell et al. 2019; Bullock et al. 2020c; Aquino et al. 2022; Rangel et al. 2023). Asimismo, las pérdidas de carbono atribuidas a la degradación pueden ser similares o superiores a las pérdidas relacionadas con la deforestación (Baccini et al. 2012; Ferraz et al. 2018; Csillik et al. 2019; Aquino et al. 2022; Rangel et al. 2023). La incertidumbre sobre esta fuente de CF se debe en parte a la incertidumbre antes mencionada sobre el área de degradación, pero también a la variabilidad de las reservas de carbono en los bosques degradados a diferentes escalas espaciales y temporales (Baccini et al. 2012; Ferraz et al. 2018; Csillik et al. 2019; Assis et al. 2020; Csillik y Asner 2020; Aquino et al. 2022; Guo et al. 2023; Pascual et al. 2023; Rangel et al. 2023). Las consecuencias de la degradación forestal para las posibles pérdidas y ganancias futuras (a través de la regeneración) para los presupuestos de carbono, la estructura forestal y la biodiversidad siguen siendo en gran medida desconocidas (Rangel et al. 2023).

Desde finales de los años 1990, los investigadores han utilizado teledetección de resolución moderada para detectar los efectos de la tala y los incendios en los bosques de la Amazonia (Hethcoat et al. 2020; Aquino et al. 2022; Rangel et al. 2023; Indirabai y Nilsson 2024). El modelado de análisis de mezcla espectral (SMA) utilizando datos ópticos pasivos ha sido la principal herramienta para este enfoque (Allnut et al. 2013; Zhu y Woodcock 2014;

Bullock et al. 2020c). Estudios más recientes emplean una combinación de información espectral, textural e índices con aprendizaje automático (Alarcón et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

Los métodos de índice de fracción de diferencia normalizada (NDFI) propuestos en este estudio tienen el potencial de contribuir al mapeo de los bosques degradados en la Amazonia (Souza et al. 2005a; Bullock et al. 2020c). El NDFI proporciona una mayor sensibilidad para detectar daños en el dosel que los valores de fracción individuales derivados del SMA, debido a la interpretación de los datos mediante un algoritmo de clasificación contextual (CCA). El clasificador CCA utiliza la ubicación puntual de los factores de la degradación forestal para buscar áreas dañadas en el dosel (como la tala selectiva), lo que permite distinguir entre bosque intacto y degradado (Souza et al. 2005a; Bullock et al. 2020c). Asimismo, la adición de filtrado temporal a los datos espectrales permite la detección de incendios forestales del sotobosque en resoluciones variadas cuando se dispone de información temporal adecuada (Hethcoat et al. 2020; Aquino et al. 2022; Pascual et al. 2023; Rangel et al. 2023). Los trabajos recientes que identifica la degradación forestal en la Amazonia utilizando series temporales Landsat es prometedor (Bullock et al. 2020c), pero, no siempre separa los principales impulsores de la degradación (tala e incendio) ni estima los efectos de la degradación en la biomasa aérea (AGB) (Bullock et al. 2020c). El análisis textural de imágenes de muy alta resolución (VHR) se ha aplicado a estudios locales de la tala y las características estructurales de los bosques, aunque el costo de adquirir y procesar datos en grandes áreas sigue siendo un desafío (Csillik et al. 2019; Maxwell et al. 2019; Pascual et al. 2023; Rangel et al. 2023). Sin embargo, la llegada de imágenes mediana a alta resolución de alta frecuencia y más accesibles, como los datos S2, presenta mayores capacidades de procesamiento, abriendo nuevas posibilidades para la detección y el monitoreo detallados de la degradación forestal (Paulino et al. 2025).

Los bosques degradados en la Amazonia peruana son fuentes importantes de carbono para la atmósfera (Garate-Quispe et al. 2024). Las reservas de AGB se han cuantificado a través de datos de teledetección calibrados con datos

de inventario de campo aunque a una escala espacial fina, los cambios en la condición del bosque son altamente inciertos (Pascual et al. 2023; Rangel et al. 2023). La incertidumbre surge de la inconsistencia de los mapas de cobertura terrestre y la variabilidad en las estimaciones del área de cambio del suelo, que pueden tener efectos dramáticos en los resultados de los modelos que dependen de dicha información (Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023). Las estimaciones de AGB de las misiones espaciales actuales y futuras como la Investigación sobre la dinámica de los ecosistemas mundiales (GEDI; Global Ecosystem Dynamics Investigation) de la Administración Nacional de Aeronáutica y el Espacio (NASA) (Hancock et al. 2019) y la misión satelital de la Agencia Espacial Europea (ESA) diseñada para medir la AGB y el carbono almacenado en los bosques de la Tierra (ESA BIOMASS) (Zuhlke et al. 2015), pero, estas misiones solo proporcionarán una visión de la AGB durante un período relativamente cortas (5-8 años) (Pascual et al. 2023; Rangel et al. 2023). Si bien GEDI representa un avance espectacular en nuestro conocimiento de la biomasa (L4A y L4B) y otros aspectos de la estructura forestal, es una misión de muestreo que inevitablemente dejará lagunas espaciales (Ngo et al. 2023). El lidar aerotransportado ha proporcionado una alta resolución espacial e información precisa sobre la AGB para bosques intactos y degradados, pero su cobertura es escasa, por consiguiente, es necesario combinar con sensores ópticos o de radar (Shendryk 2022; Guo et al. 2023).

La gestión eficaz de la dinámica del carbono relacionada con el cambio de uso de las tierras forestales requiere una atribución precisa de las fuentes y sumideros de carbono (Rangel et al. 2023). Como se señaló anteriormente, la degradación forestal es una fuente de carbono importante y mal cuantificada, mientras que la recuperación después de la degradación es un sumidero de carbono potencial que se pasa por alto (Baccini et al. 2012; Ploton et al. 2017; Ferraz et al. 2018; Hethcoat et al. 2020; Qin et al. 2021; Aquino et al. 2022; Liang et al. 2023; Garate-Quispe et al. 2024; Ma et al. 2024; Oliveira et al. 2024). La promoción de los sumideros de CF es un enfoque potencialmente rentable para mitigar el cambio climático dentro de una estrategia general de

gestión y conservación del CF (Rangel et al. 2023). En última instancia, mejorar la capacidad de representar con precisión los cambios de AGB asociados con la deforestación y la degradación forestal requiere conocimiento de dónde y cuándo ocurrieron, la biomasa de los bosques deforestados y degradados frente a los intactos y la cuantificación de las incertidumbres estimadas (Guo et al. 2023; Liang et al. 2023; Pascual et al. 2023; Rangel et al. 2023).

La clasificación de la degradación de los bosques tropicales y la estimación de la AGB asociada siguen siendo un desafío importante porque las incertidumbres existentes en este tipo de clasificación y en la estimación de la AGB impiden la atribución precisa de las emisiones de carbono a clases específicas de bosques. En este estudio, se clasificó la deforestación y degradación forestal utilizando el enfoque de SMA sobre la incertidumbre de las estimaciones de CF aéreo mediante la combinación de datos GEDI L4B con Sentinel-1 (S1), Sentinel-2 (S2) y modelo de elevación digital (DEM) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

ÍNDICE DE CONTENIDOS

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

ABSTRACT

INTRODUCCIÓN

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN 1

1.1 Descripción del problema 1

1.2 Formulación del problema 2

1.2.1 Problema general 2

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

2.2 Base teórica..... 17

2.2.1 Bosque.....	17
2.2.2 No bosque.....	17
2.2.3 Perturbaciones forestales	18
2.2.4 Deforestación.....	18
2.2.5 Degradación forestal.....	19
2.2.6 Principios básicos de teledetección	19
2.2.7 Análisis de mezcla espectral (SMA).....	20
2.2.8 Índice de Fracción de Diferencia Normalizada (NDFI).....	21
2.2.9 Random Forest (RF)	22
2.2.10 Sentinel-2 (S2).....	22
2.2.11 Densidad de biomasa sobre el suelo a nivel de huella GEDI L4B	23
2.2.12 Modelo de elevación digital (DEM)	24
2.3 Definición de términos	25
CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN	27
3.1 Tipo de estudio	27
3.2 Diseño del estudio	27
3.3 Delimitación espacial y temporal.....	27
3.4 Población y muestra	29
3.5 Método y técnicas	31
3.6 Tratamiento de datos	33
3.6.1 Procesamiento de datos	33
3.6.2 Precisión de datos	42
3.6.4 Análisis estadístico	45
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	47
4.1 Análisis de mezcla espectral (SMA) para NDFI en los bosques del sureste de la Amazonia de Madre de Dios	47

4.2 Deforestación y degradación forestal a través del NDFI en los bosques del sureste de la Amazonia de Madre de Dios	49
4.3 Evaluación de precisión de NDFI	53
4.4 Biomasa forestal aéreo con el modelo RF mediante la combinación de datos GEDI nivel L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios	54
4.5 Carbono forestal aéreo por tipo de cobertura de suelo	59
4.6 Carbono forestal aéreo por la incertidumbre de la clasificación de cobertura del suelo	63
CONCLUSIONES	65
SUGERENCIAS.....	66
REFERENCIAS BIBLIOGRÁFICAS	67
ANEXOS.....	84

Índice de Tablas

	Pág.
Tabla 1. Operacionalización de variables	5
Tabla 2. Información de datos Sentinel-2, GEDI L4B y DEM.....	34
Tabla 3. S2; umbrales de firmas espectrales representativas de materiales puros (Endmembers)	39
Tabla 4. Valores adaptados de NDFI	40
Tabla 5. Valores del coeficiente kappa	43
Tabla 6. Precisión con datos de campo e imágenes de alta resolución frente a datos de la NDFI S2	53
Tabla 7. Biomasa forestal aéreo en el área de estudio.....	58
Tabla 8. Carbono forestal aéreo por tipo de cobertura en el área de estudio	61

Índice de Figuras

<i>Figura 1.</i> Ubicación del área de estudio.....	28
Figura 2. Distribución de muestras por estratos en el área de estudio.	30
<i>Figura 3:</i> Mosaico de imágenes S1 con polarización VV.....	34
Figura 4. Mosaico de imágenes S1 con polarización VH.....	35
<i>Figura 5.</i> Mosaico de imágenes S2.....	35
<i>Figura 6.</i> Datos GEDI L4B y superposición de puntos (533) en el área de estudio.	36
<i>Figura 7.</i> SRTM del área de estudio	36
<i>Figura 8.</i> Firmas espectrales representativas de materiales puros (Endmembers) utilizadas en imágenes S2 para GV (a), NPV (b), Suelo (c), Sombra (d) y pixel mixto (e) de 20225.....	39
<i>Figura 9.</i> Algoritmo de Random Forest (RF).....	42
<i>Figura 10.</i> Validación de la deforestación, degradación forestal y bosque mediante imágenes de PlanetScope (a) con una resolución espacial de 3 m × 3 m, Perusat-1 (c) con 0,7 m × 0,70 m y de 2,8 m × 2,8 m, y WorldView (c) de 0,38 m x 0,38.....	44
<i>Figura 11.</i> Fracciones representativas de materiales puros (Endmembers) de GV (a), NPV (b), suelo (c) y sombra (d) del área de estudio.	47
<i>Figura 12.</i> NDFI en escala de grises para el área de estudio.	48
<i>Figura 13.</i> NDFI del área de estudio.	49
<i>Figura 14.</i> Cuantificación de categorías; deforestación, degradación forestal y bosque.....	50
<i>Figura 15.</i> Importancia de las variables en el modelo RF (en puntuación y porcentaje).....	55

<i>Figura 16.</i> Entrenamiento del modelo RF de datos predichos versus observado.....	55
<i>Figura 17.</i> Validación del modelo RF de datos predichos versus observado.	56
<i>Figura 18.</i> Biomasa forestal aéreo en el área de estudio.....	58
<i>Figura 19.</i> Carbono forestal en el área de estudio.	60

Índice de anexos

Anexo 1. Matriz de consistencia.	85
Anexo 2. Puntos de muestreo por categoría en el área de estudio.	87
Anexo 3. Panel fotográfico.	96

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1 Descripción del problema

Las reservas de carbono en los bosques Amazónicos son vulnerables a los cambios en el uso de la tierra y a la degradación forestal, lo que dificulta la cuantificación de las reservas de carbono (Baccini et al. 2012; Ometto et al. 2015; Ploton et al. 2017). Se estima que estos bosques almacenan entre 60 a 80 Gt (gigatoneladas) de CF (Baccini et al. 2012). Existe una necesidad urgente de cuantificar el efecto de la degradación forestal sobre las reservas de CF en los bosques Amazónicos para apoyar REDD+ y mejorar la precisión de los presupuestos globales de carbono, siendo un componente central del Acuerdo de París (COP21) (Csillik et al. 2019; Maxwell et al. 2019; Bullock et al. 2020c).

La deforestación está transformando la extensión original de los bosques en pastizales, tierras de cultivo y minería de oro en la Amazonia del Perú, específicamente en Madre de Dios, la segunda con mayor área contigua de bosque Amazónico. La degradación del bosque amazónico ha continuado, reduciendo las reservas de CF debido a la tala selectiva, los incendios forestales y la fragmentación forestal. La degradación o deforestación repetida puede alterar las reservas de carbono en los bosques durante varias décadas debido a cambios en la estructura, composición de especies y proceso sucesional por tala e incendios del sotobosque (Alarcón et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022; Alarcon-Aguirre et al. 2023).

La teledetección satelital, las mediciones de campo y los estudios experimentales ofrecen datos clave sobre la degradación forestal en la Amazonía (Bullock et al. 2020c). Para comprender la dinámica de los bosques degradados, es fundamental realizar parcelas de inventario y experimentos de

manipulación que estudien el efecto de las actividades antropogénicas. Sin embargo, la extrapolación de los resultados de campo suele estar limitada por el pequeño número y área de las muestras, así como por el tiempo entre muestras repetidas (Hethcoat et al. 2020). El rango de impactos de la degradación en la estructura forestal y las reservas de carbono en la Amazonía sigue siendo muy incierto como resultado (Rangel et al. 2023; Campos et al. 2024; Ma et al. 2024).

En este contexto, el uso de técnicas de SMA de imágenes de mediana a alta resolución espacial (3–20 m) es suficiente para detectar cambios sutiles en la estructura forestal debido a la degradación de baja intensidad (Bullock et al. 2020c). Las mediciones basadas en satélites respaldan el mapeo de la degradación en grandes áreas, incluidas las regiones remotas (Bullock et al. 2020c; Chen et al. 2021). Las nubes en los bosques Amazónicos limitan el uso de imágenes ópticas pasivas. Asimismo, el uso de datos GEDI combinados con datos ópticos (S2) y de radar (S1) proporcionan una escala intermedia entre las mediciones de campo y las basadas en satélites (Ometto et al. 2015; Longo et al. 2016; Csillik et al. 2019; Csillik y Asner 2020). Se pueden obtener mediciones tridimensionales detalladas de la estructura forestal en miles de hectáreas, lo que facilita las evaluaciones de las reservas de CF en tipos de bosques intactos, degradados, perturbaciones de baja intensidad ya áreas deforestadas (Ometto et al. 2015; Longo et al. 2016; Csillik et al. 2019; Csillik y Asner 2020; Guo et al. 2023; Pascual et al. 2023). Los datos GEDI ofrecen el potencial de abordar los desafíos para REDD+ y la ecología de los bosques tropicales basados en la variabilidad de las reservas de CF (Pascual et al. 2023) a escalas espaciales mejor que las observaciones satelitales tradicionales de mapeo del CF.

1.2 Formulación del problema

1.2.1 Problema general

¿Cuánto y como es la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis de mezcla espectral (SMA) sobre la

incertidumbre de las estimaciones de carbono forestal aéreo mediante la combinación de datos GEDI L4B con Sentinel-1 (S1), Sentinel-2 (S2) y modelos de elevación digital (DEM) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?

1.2.2 Problemas específicos

- P.E.1 ¿Cómo es el índice de fracción de diferencia normalizada (NDFI) utilizando el método de análisis de mezcla espectral (SMA) que considera distintas coberturas como vegetación verde (GV), vegetación no fotosintética (NPV), suelo, sombra y nube en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?
- P.E.2 ¿Cuánto es la magnitud de la deforestación y degradación forestal a través del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?
- P.E.3 ¿Cuál es la precisión de la clasificación de la deforestación y degradación forestal producto del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?
- P.E.4 ¿Cuánto es la biomasa forestal aéreo con el modelo Random Forest (RF) mediante la combinación de datos GEDI nivel L4B con S1, S2 y elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?
- P.E.5 ¿Cuál es la cantidad de carbono forestal aéreo por tipo de cobertura en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?
- P.E.6 ¿Cómo es el comportamiento de la cuantificación del carbono forestal aéreo por la incertidumbre de la clasificación de la degradación forestal en la cartografía de cobertura del suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?

1.3 Objetivos de la investigación

1.3.1 Objetivo general

Analizar la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis de mezcla espectral (SMA) sobre la incertidumbre de las estimaciones de carbono forestal aéreo mediante la combinación de datos GEDI L4B con Sentinel-1 (S1), Sentinel-2 (S2) y modelos de elevación digital (DEM) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

1.3.2 Objetivos específicos

- O.E.1 Calcular el índice de fracción de diferencia normalizada (NDFI) utilizando el método de análisis de mezcla espectral (SMA) que considera distintas coberturas como vegetación verde (GV), vegetación no fotosintética (NPV), suelo, sombra y nube en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.
- O.E.2 Estimar la magnitud de la deforestación y degradación forestal a través del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.
- O.E.3 Medir la precisión de la clasificación de la deforestación y degradación forestal producto del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.
- O.E.4 Cuantificar la biomasa forestal aéreo con el modelo Random Forest (RF) mediante la combinación de datos GEDI nivel L4B con S1, S2 y elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

O.E.5 Determinar el carbono forestal aéreo por tipo de cobertura de suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

O.E.6 Analizar la cuantificación del carbono forestal aéreo por la incertidumbre de la clasificación de la degradación forestal en la cartografía de cobertura del suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

1.4 Variables de la investigación

1.4.1 Identificación de variables

Variable dependiente: incertidumbre de carbono forestal aéreo por deforestación y degradación forestal en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

Variable independiente: deforestación y degradación forestal con el SMA para NDFI y CF mediante la combinación de datos GEDI nivel L4B con S1, S2, elevación y pendiente.

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				
La aplicación de NDFI utilizando el método de, permite estimar la magnitud de la deforestación y degradación forestal en los bosques del sureste de	Estimar la deforestación y degradación forestal en los bosques del sureste de la	Magnitud de la deforestación y degradación forestal.	SMA. NDFI, deforestación y degradación forestal (ha).	P.E.1 P.E.2

la Amazonia de Madre de Dios durante el año 2025.	Amazonia de Madre de Dios.			
La aplicación de técnicas de concordancia interespecífica, permite medir la precisión de la clasificación de la deforestación y degradación forestal en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.	Medir la precisión de la clasificación de la deforestación y degradación forestal producto del NDFI.	Precisión de la deforestación y degradación forestal.	Matriz de confusión e índice de kappa (k).	P.E.3
La combinación de datos GEDI nivel L4B con S1, S2, elevación y pendiente, permiten cuantificar y determinar la AGB y CF aéreo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.	Cuantificar y determinar la AGB y CF aéreo.	Cuantificar y determinar la AGB y CF aéreo por tipo de cobertura.	AGB aéreo (Mg/h y Mg), CF aéreo (Mg C/ha y Mg C), CF aéreo en áreas de degradación forestal (ha)	P.E.4 P.E.5 P.E.5
Variable dependiente				
El análisis de la reflectancia espectral de la deforestación y degradación forestal con el SMA para NDFI y AGB mediante la combinación de datos GEDI nivel L4B con S1, S2, elevación y pendiente, permite estimar la incertidumbre de CF aéreo en áreas de degradación forestal en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.	Analizar la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis SMA sobre la incertidumbre de las estimaciones de CF aéreo mediante la combinación de datos GEDI L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios.	CF aéreo por deforestación y degradación forestal.	CF aéreo (Mg C/ha y Mg C).	P.E.1 P.E.2 P.E.3 P.E.4 P.E.5 P.E.6

1.6 Hipótesis

Hipótesis Nula (H₀): El modelo de análisis de mezcla espectral para el índice de fracción de diferencia normalizada no permite estimar con precisión la incertidumbre del carbono forestal aéreo en áreas de degradación forestal en

los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

Hipótesis Alternativa (H₁): el modelo de análisis de mezcla espectral para el índice de fracción de diferencia normalizada permite estimar con precisión la incertidumbre del carbono forestal aéreo en áreas de degradación forestal en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.

1.7 Justificación e importancia

Analizar la clasificación detallada de la deforestación y la degradación forestal a través del SMA se convierte en un aspecto esencial para minimizar las posibles incertidumbres presentes en las estimaciones del CF aéreo almacenado en los bosques, particularmente en la región del sureste Amazónico de Madre de Dios. Esta área se destaca por su significativa relevancia en términos ecológicos, sociales y económicos. A través de la combinación de los datos L4A obtenidos por el satélite GEDI, que brindan mediciones detalladas de la estructura vertical de las formaciones boscosas, con las imágenes de S2, las cuales suministran información espectral de alta resolución, este método posibilita una diferenciación precisa entre áreas de bosque en buen estado de conservación, degradadas ya reas deforestadas.

Desde una perspectiva académica y científica, esta investigación representa un avance significativo en nuestro conocimiento y comprensión de la compleja dinámica del CF en los diversos ecosistemas de la Amazonia, lo cual aporta de manera sustancial a la gama y multidisciplinario campo de las ciencias medioambientales y los estudios relacionados con el fenómeno del cambio climático, que es uno de los desafíos más apremiantes de nuestra era actual.

Además, en este documento se ofrece un detallado marco metodológico que permite la integración y combinación de datos provenientes de diversas fuentes de teledetección, lo cual contribuye significativamente a estimular la creatividad y el progreso en el ámbito del análisis geoespacial. Desde una

perspectiva científica rigurosa, la implementación de una clasificación más detallada de los diversos estados que pueden presentar los bosques contribuye significativamente a mejorar la exactitud de las estimaciones de las existencias de CF aéreo, las cuales desempeñan un papel fundamental en la elaboración de los modelos climáticos a escala global, en la gestión del balance de carbono y en la verificación de los programas REDD+.

Desde una perspectiva social más amplia y profunda, el análisis brinda un sólido respaldo a las diversas comunidades locales e indígenas al proporcionar información detallada y precisa sobre las prácticas sostenibles de utilización de la tierra. Esto, a su vez, fortalece de manera significativa las iniciativas destinadas a la preservación de los bosques y a la protección de la rica biodiversidad que resulta fundamental para la perpetuación de los valiosos servicios ecosistémicos y la salvaguarda del invaluable patrimonio cultural que nos define como sociedad.

Desde un punto de vista económico, las estimaciones más detalladas y precisas de las emisiones de carbono desempeñan un papel fundamental en el fomento de la creación y consolidación de mercados de compensación de carbono. Estos mercados son esenciales para la implementación de mecanismos financieros que promuevan la conservación de los bosques y la promoción de un desarrollo sostenible. La realización de este exhaustivo análisis en el año 2025 resulta sumamente pertinente y oportuna, dado que se alinea de manera precisa con los ambiciosos objetivos climáticos a nivel global. Además, brinda valiosa información detallada acerca de la magnitud de las consecuencias derivadas de la deforestación y la progresiva degradación forestal en una región que se ve cada vez más asediada por la desenfrenada expansión de la actividad agrícola, la descontrolada tala de árboles, minería de oro y los preocupantes efectos del cambio climático. Este enfoque multidisciplinar y holístico tiende un puente sólido y robusto entre la investigación académica de vanguardia, la innovación científica de alto impacto, la equidad social tan necesaria en nuestros tiempos y la viabilidad económica a largo plazo, garantizando de esta manera que los valiosos resultados obtenidos contribuyan de forma significativa a la resiliencia

climática, a la formulación de políticas públicas efectivas y a la gestión sostenible y responsable de uno de los ecosistemas más vitales y complejos del mundo.

1.8 Consideraciones éticas

Los tesisistas siguieron de manera estricta lo estipulado en el Reglamento de Grados y títulos de la Universidad Nacional Amazónica de Madre de Dios (UNAMAD). Asimismo, la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis SMA sobre la incertidumbre de las estimaciones de carbono forestal mediante la combinación de datos GEDI L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025 se ejecutará con estricto rigor científico y para ello, se contará con el soporte técnico y científico del Centro de Teledetección para el Estudio y Manejo de Recursos Naturales (CETEGERN) de la UNAMAD.

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de la investigación

Liang et al. (2023) plantearon una metodología de fusión de datos que fusiona el GEDI Lidar de la NASA con datos ópticos del Landsat con el objetivo de medir las pérdidas de biomasa vinculadas a la degradación forestal por carbón vegetal durante un lapso de 10 años. Los índices de Landsat del periodo de estrés hídrico limitado (LHS) son las variables predictivas empleadas en modelos de aprendizaje automático. Desde 2007 hasta 2019, se elaboraron mapas anuales de AGB forestal en el distrito de Mabalane en el sur de Mozambique, donde el ecosistema de bosque seco se hallaba en una degradación activa vinculada al carbón vegetal. Desde 2008, se ha utilizado el modelo RF de mejor desempeño para los compuestos Landsat LHS anuales estabilizados por LandTrendr. Mediante el uso de un conjunto de datos cruzados de 10 veces, el modelo RF logró un valor RMSE de 7,05 Mg/ha (RMSE% = 42%) y un valor R^2 de 0,64. En un lapso de 10 años, estimaron una pérdida total de AGB de $2,12 \pm 0,06$ Megatoneladas (Mt), lo que representa únicamente un $6,35 \pm 2,56\%$ menos que la pérdida total calculada usando datos de campo publicados anteriormente para la misma región y periodo. Elaboraron mapas anuales de AGB con el objetivo de describir las alteraciones y la recuperación, así como cuantificar la pérdida biomasa. La combinación de datos GEDI y Landsat mediante modelos predictivos puede medir la dinámica del AGBD forestal en bosques con baja biomasa, tal como evidencia nuestro esquema de trabajo. En selvas con escasez de biomasa. El método basado en satélites respalda las actividades de monitoreo y valoración de REDD+ en zonas con información restringida. Posee capacidad para examinar varios sucesos de perturbación.

Pascual et al. (2023) evaluaron el rendimiento de los modelos de densidad de biomasa aérea de la huella GEDI L4A de la NASA utilizando datos del Inventario Forestal Nacional y de escaneo láser aéreo en ecosistemas forestales mediterráneos. El impacto de la generalización del modelo L4A sobre el dominio de predicción más grueso es consistente con los hallazgos reportados anteriormente, pero el desarrollo de modelos L4A para dominios espaciales más específicos está limitado por la disponibilidad de datos de referencia. Por lo tanto, es necesario ampliar el tamaño del FSBD de GEDI para i) poblar más áreas geográficas subrepresentadas en el FSBD real de GEDI y ii) permitir la división de PFT individuales en escalas más pequeñas donde las diferencias entre los atributos estructurales del bosque puedan capturarse mejor, mejorando la estimación general de AGBD para el producto de la misión GEDI L4A. Todavía se necesitan más estudios sobre conjuntos de datos de entrenamiento más grandes para probar si las nuevas variables predictoras podrían tener un mayor impacto en el rendimiento del modelo GEDI L4A, además de la expansión de la base de datos de entrenamiento GEDI FSBD. Desde la óptica de la misión GEDI, los datos agregados de NFI en geografías jurisdiccionales como provincias, regiones o tipos de bosques espacialmente continuos son un recurso valioso para evaluar los datos GEDI en órbita sin la restricción del error de geolocalización a nivel de huella. El ejercicio es especialmente relevante para evaluar y mejorar el producto de cuadrícula de 1 km de GEDI L4B, un esfuerzo alineado con las iniciativas de armonización global sobre el uso de productos de teledetección para apoyar los programas de NFI.

Rangel et al. (2023) analizaron los efectos de la clasificación de la degradación forestal sobre la incertidumbre de las estimaciones de carbono sobre el suelo en la Amazonia. En este estudio, utilizaron métricas texturales derivadas de imágenes PlanetScope para implementar un marco de clasificación probabilística para identificar bosques intactos, talados y quemados en tres sitios amazónicos. También estimaron la biomasa para estas clases de bosques utilizando lidar aerotransportado y compararon las incertidumbres de biomasa utilizando las estimaciones derivadas de lidar únicamente con las

incertidumbres de biomasa considerando también la clasificación de degradación forestal. El método de clasificación alcanzó una precisión general de 0,86, con una precisión en sitios individuales que varió de 0,69 a 0,93. Los bosques talados mostraron cambios variables en la biomasa, mientras que los bosques quemados mostraron una pérdida promedio de carbono del 35%. Descubrieron que incluir la incertidumbre en la clasificación de la degradación forestal aumentó significativamente la incertidumbre y disminuyó las estimaciones de la densidad media de carbono en dos de los tres sitios de prueba. Nuestros hallazgos indican que la atribución de los cambios en la biomasa a las clases de degradación forestal debe tener en cuenta la incertidumbre en la clasificación de la degradación forestal. Al combinar imágenes de muy alta resolución con datos lidar, podríamos atribuir los cambios en las reservas de carbono a vías específicas de degradación forestal. Este enfoque también permite cuantificar las incertidumbres de las emisiones de carbono asociadas con la degradación forestal a través de la tala y los incendios. Tanto la atribución como la cuantificación de la incertidumbre proporcionan información crítica para los inventarios nacionales de gases de efecto invernadero.

Campbell et al. (2021) investigaron un método para relacionar la AGB de los bosques medidos en terreno con los datos de ALS, y la AGB modelada por ALS con datos satelitales, empleando bosques de piñones y enebros en el sureste de Utah como ejemplo de caso. Evaluaron la eficacia de esta metodología de escalado empleando dos sensores satelitales, Landsat OLI y GEDI. Pusieron en práctica un método para diseminar la incertidumbre a través de un marco analítico multiescala anidado, empleando la variabilidad en los árboles de decisión de un bosque aleatorio. Las previsiones realizadas a nivel local se emplean como datos de entrada para el modelo a nivel regional. Examinamos diversos tamaños de huellas de GEDI para valorar su influencia en la exactitud del modelo AGB de ALS-GEDI, a causa de la incertidumbre posicional presente en las huellas. El modelo predictivo de campo-ALS calculó AGB con un RMSE de 14 Mg/ha y un MAE de 11,09 Mg/ha, lo que explica el 74% de la variabilidad en AGB. El modelo predictivo

más eficiente se logró al fusionar Landsat y GEDI, siendo Landsat solo y GEDI solo los siguientes. El estudio regional evidenció que la mezcla de ambos generó un R^2 de 0,68, RMSE de 12,71 Mg/ha y MAE de 9,40 Mg/ha. Landsat solo registró un R^2 de 0,66, con una RMSE de 13,08 Mg/ha y una MAE de 9,71 Mg/ha, en contraste con GEDI que solo mostró un R^2 de 0,49, con una RMSE de 16,01 Mg/ha y una MAE de 12,14 Mg/ha. En ambientes forestales con cubiertas de copas bajas y árboles de bajo tamaño, Landsat podría ser más apropiado que GEDI para calcular AGB, basándose en estos hallazgos. Restringen la habilidad para describir con exactitud la estructura de la vegetación en datos lidar de gran tamaño. Las huellas simuladas de mayor tamaño generaron mayor exactitud en el modelo GEDI. No obstante, incrementar los radios de las huellas por encima de los 30 m no mejora de manera significativa la exactitud del modelo. Esta investigación ofrece un caso de prueba inicial para la utilización de los datos GEDI en el mapa de la AGB de los bosques, lo que constituye un progreso significativo en nuestra habilidad para trazar de forma fiable la AGB de los bosques.

Qin et al. (2021) evaluaron la dinámica espacio-temporal de la biomasa aérea (AGB) y la superficie forestal que afectan el ciclo del carbono, el clima y la biodiversidad en la Amazonia brasileña. Descubrieron que la pérdida bruta de superficie forestal fue mayor en 2019 que en 2015, posiblemente debido a la reciente flexibilización de las políticas de protección forestal. Sin embargo, la pérdida neta de AGB fue tres veces menor en 2019 que en 2015. Durante el período 2010-2019, la Amazonia brasileña tuvo una pérdida bruta acumulada de 4,45 Pg C frente a una ganancia bruta de 3,78 Pg C, lo que dio como resultado una pérdida neta de AGB de 0,67 Pg C. La degradación forestal (73%) contribuyó tres veces más a la pérdida bruta de AGB que la deforestación (27%), dado que la extensión superficial de la degradación supera la de la deforestación. Esto indica que la degradación forestal se ha convertido en el mayor proceso que impulsa la pérdida de carbono y debería convertirse en una mayor prioridad política.

Bullock et al. (2020c) se monitoreo el deterioro de los bosques tropicales mediante el uso de SMA y el estudio de series de tiempo Landsat. La degradación y la deforestación se registraron con una precisión del usuario del 88,0% y 93,3%, respectivamente, y del productor del 68,1% y 85,3%. Se calcularon zonas de degradación y deforestación con márgenes de error del 13,9% y 5,3%, respectivamente. Los procedimientos de teledetección poseen una habilidad restringida para identificar el deterioro forestal, a pesar de los avances en la calidad de los datos. En Rondônia, la reducción de la deforestación tras 2004 se alinea con un incremento en la degradación, siendo este el único método práctico para supervisar alteraciones forestales en extensas zonas. Se emplean datos Landsat para determinar el NDFI, transformando las miembros finales en fracciones espectrales. Se emplearon datos no mezclados espectralmente para supervisar alteraciones y clasificar la cobertura de la Tierra. Para estratificar el área de estudio, se emplearon mapas de deforestación y degradación. Se obtuvieron datos de muestra y se utilizaron estimadores neutrales para elaborar estimaciones de las zonas de degradación y deforestación desde 1990 hasta 2013. La perspectiva abarca los estudios anteriores en SMA para detectar la degradación forestal en el dominio temporal.

Bullock et al. (2020e) analizaron los datos Landsat desde 1995 hasta 2017 con el objetivo de trazar un mapa de la deforestación, degradación y alteraciones naturales en la ecorregión amazónica. Emplearon un mapa para categorizar el área de investigación y asignarle etiquetas de referencia a las unidades de muestra, basándose en su cobertura terrestre y registro histórico de alteraciones. Utilizaron un estimador estadístico neutral a la muestra de observaciones de referencia con el objetivo de lograr estimaciones de área e incertidumbre en periodos temporales bien definidos. La tala de árboles desde 1995 hasta 2017 ha impactado en una amplia zona de la ecorregión amazónica, así como en la degradación y alteración natural durante periodos de sequía intensa. Se calcula que hasta 2017, el 17% del área forestal original ha sufrido alteraciones, lo que se traduce en $1.036.800 \pm 24.800 \text{ km}^2$ con un intervalo de confianza del 95%. La zona de bosque alterado en la Amazonía

supera el 44% y el 60% de lo estimado previamente, lo que señala una fuente no registrada de emisiones de carbono y un perjuicio extendido a los ecosistemas forestales, de acuerdo con nuestros hallazgos.

Csillik y Asner (2020) analizaron las emisiones de carbono en la superficie de la explotación minera de oro en la región amazónica de Perú. Estimaron las reservas de carbono en el terreno y las emisiones derivadas de la minería de oro en 2017 y 2018 mediante el uso de teledetección satelital, LiDAR aerotransportado y modelos de aprendizaje profundo. En un área de aproximadamente 750 000 ha, la densidad de carbono en el suelo (ACD) experimentó una variación considerable, registrando valores promedio de 84,6 ($\pm 36,4$) Mg C ha⁻¹ en 2017 y 83,9 ($\pm 36,0$) Mg C ha⁻¹ en 2018. En un único año, se registraron preocupantes emisiones de 1,12 Tg C que impactaron a 23 613 ha, abarcando áreas protegidas y sus áreas de amortiguación ecológica. Se desarrolló un sistema automatizado para supervisar las emisiones de carbono forestal de alta resolución, fundamentado en técnicas y descubrimientos anteriores. Esto respaldará medidas para disminuir los efectos ambientales de la extracción de oro y otras actividades perjudiciales para el medio ambiente.

Maxwell et al. (2019) demostraron que entre 2000 y 2013, la tala directa de áreas de bosques tropicales intactos representó el 3,2% de las emisiones brutas de carbono de toda la deforestación en los pantrópicos. Sin embargo, la contabilidad completa del carbono requiere la consideración del secuestro de carbono perdido, la tala selectiva, los efectos de borde y la defaunación. Cuando se consideraron estos factores, el impacto neto del carbono resultante de la pérdida de bosques tropicales intactos entre 2000 y 2013 aumentó en un factor de 6 (626%), de 0,34 (0,37 a 0,21) a 2,12 (2,85 a 1,00) petagramos de carbono (equivalente a aproximadamente 2 años de emisiones globales del cambio de uso de la tierra). Por lo tanto, el valor de mitigación del clima que supone conservar los 549 millones de hectáreas de bosque tropical que permanecen intactos es significativo, pero pronto disminuirá si su ritmo de pérdida continúa acelerándose.

Rappaport et al. (2018) combinaron temporales anuales de imágenes Landsat y datos lidar aéreos de alta densidad para caracterizar la variabilidad, la magnitud y la persistencia de los impactos de la degradación forestal amazónica en la densidad de carbono sobre el suelo y la estructura del dosel (1984-2016). En promedio, los bosques degradados contenían el 45,1% de las reservas de carbono de los bosques intactos, y las diferencias persistían incluso después de 15 años de regeneración. En comparación con la tala, los incendios del sotobosque dieron lugar a las diferencias más grandes y duraderas en la ACD. La heterogeneidad en la estructura del bosque quemado varió según la gravedad y la frecuencia de los incendios. Los bosques con un historial de uno, dos y tres o más incendios conservaron solo el 54,4%, el 25,2% y el 7,6% de la ACD intacta, respectivamente, cuando se midió después de un año de regeneración. A diferencia del impacto aditivo de los incendios sucesivos, la tala selectiva antes de la quema no explicó la variabilidad adicional en la pérdida y recuperación de ACD modelada de los bosques quemados. El lidar aéreo también proporciona medidas cuantitativas de la estructura del hábitat que pueden ayudar a la estimación de los cobeneficios de la degradación evitada. En particular, las reservas de carbono forestal se recuperaron más rápido que los atributos de la estructura del dosel que son críticos para la biodiversidad en los bosques tropicales, incluida la abundancia de árboles altos. Proporcionamos la primera tabla de consulta integral de factores de emisión para vías de degradación específicas a intervalos de informe estándar en la Amazonia. Las trayectorias estimadas de pérdida y recuperación de carbono proporcionan una base importante para evaluar las contribuciones a largo plazo de la degradación forestal al ciclo regional del carbono y hacen avanzar nuestra comprensión del estado actual de los bosques fronterizos.

Silva-Junior et al. (2018) utilizaron un enfoque de teledetección para estimar las pérdidas de carbono impulsadas por el efecto de borde en la Amazonia durante el período de 2001 a 2015. Encontraron que las pérdidas de carbono asociadas con el efecto de borde (947 Tg C) correspondieron a un tercio de las pérdidas por deforestación (2592 Tg C). A pesar de una notable tendencia

negativa de 7 Tg C año⁻¹ en las pérdidas de carbono por deforestación, las pérdidas de carbono por efecto de borde se mantuvieron sin cambios, con un promedio de 63 ± 8 Tg C año⁻¹. Las pérdidas de carbono causadas por el efecto de borde son, por lo tanto, un flujo adicional no cuantificado que puede contrarrestar las emisiones de carbono evitadas al reducir la deforestación, comprometiendo los objetivos audaces del Acuerdo de París.

2.2 Base teórica

2.2.1 Bosque

Área de tierra que se extiende por más de 0,5 hectáreas con una cubierta de copas arbóreas (o un nivel equivalente de población) de más del 10 por ciento con árboles con potencial para alcanzar una altura mínima de 2 a 5 metros en la madurez in situ. Las definiciones reales pueden variar de un país a otro, ya que el Protocolo de Kyoto permite a los países especificar la definición precisa dentro de estos parámetros que se utilizarán para la contabilidad nacional de emisiones (Whitmore y Burnham 1975; FAO 2012).

2.2.2 No bosque

Terrenos que no entran en la definición de terreno forestal. Se trata de terrenos que (1) nunca han albergado bosques (por ejemplo, yermos, tundra alpina), (2) eran antiguamente forestales, pero se han convertido a una clase de superficie no forestal (por ejemplo, pastizales, tierras de cultivo), o (3) cumplen actualmente los requisitos de población de los terrenos forestales, pero la actividad humana en el lugar impedirá la sucesión natural de la masa (desarrollo residencial) (Whitmore y Burnham 1975; Asner et al. 2009; FAO 2012).

2.2.3 Perturbaciones forestales

Desde un punto de vista conceptual, es difícil elaborar una definición concisa de perturbación o daño forestal. Es tentador decir simplemente que estas palabras se refieren a cualquier proceso o agente que impida el desarrollo óptimo o previsto de los bosques. Sin embargo, el término “óptimo” está cargado de valores y depende de los resultados que se deseen optimizar (por ejemplo, la conservación de la biodiversidad, la producción de madera o el secuestro de carbono). Además, la presencia endémica de ciertos procesos de perturbación puede ser compatible o incluso necesaria para la salud de los bosques. Sin embargo, el término “saludable” es problemático en sus connotaciones de valor. Desde un punto de vista práctico, existe un buen consenso sobre lo que constituye la perturbación y el daño forestal. Se trata de procesos o agentes que afectan significativamente a los bosques a través de la mortalidad de los árboles y la reducción del crecimiento (FAO 2020).

2.2.4 Deforestación

La deforestación alude a la reducción global de las superficies forestales destinadas a otras aplicaciones, tales como suelos destinados a la agricultura, la urbanización o las operaciones mineras. La deforestación, que ha sido intensificada en gran medida por las acciones humanas desde 1960, ha ejercido un impacto adverso sobre los ecosistemas naturales, la biodiversidad y el clima. La Organización de las Naciones Unidas para la Alimentación y la Agricultura proyecta que la tasa anual de deforestación asciende a aproximadamente 1,3 millones de km² cada década. Diversos factores, tanto antropogénicos como naturales, son los causantes de la deforestación (FAO 2020).

Si bien los desastres naturales como los incendios forestales y algunas de las enfermedades de los parásitos que provocan la deforestación se consideran elementos naturales, la deforestación a nivel global antropogénicamente se clasifica como una de las principales. Según la FAO (2020), la actividad agrícola y su expansión han provocado aproximadamente 80% de la

deforestación mundial. Las principales otras causas de la deforestación son la construcción de infraestructuras como carreteras o presas, la actividad minera y la expansión urbana.

2.2.5 Degradación forestal

Es definida como los ecosistemas forestales que han perdido su capacidad de proporcionar bienes y servicios importantes a las personas (como la protección de las cuencas hidrográficas) y a la naturaleza (como el hábitat de la vida silvestre). Sin embargo, desde 2020, cada país decide qué significa un bosque degradado dentro de sus propios paisajes, y aquí es donde las cosas se complican. Definir la degradación forestal es difícil porque es gradual y puede permanecer invisible durante mucho tiempo, como cuando la caza ilegal vacía un bosque de su vida silvestre. “Al igual que nosotros, los bosques pueden estar enfermos y no ser saludables, o prósperos y productivos”, por lo que, La calidad del bosque importa tanto como la cantidad (Asner et al. 2009; FAO 2020).

En los últimos 10 años, las investigaciones en la Amazonia han demostrado que la degradación forestal causada por la fragmentación forestal, la silvicultura insostenible y los incendios que dañaron los árboles, generó tres veces más emisiones de carbono que la deforestación. Si comparamos dos áreas de bosque de tamaño similar, la deforestada generará más emisiones que la degradada, pero la degradación forestal tiende a ocurrir a una escala mucho mayor (Asner et al. 2009; FAO 2020).

2.2.6 Principios básicos de teledetección

La teledetección, o bien la teledetección, es la obtención de la información sobre la superficie sin tener contacto ni sobre esta superficie ni sobre el objetivo. Sus principios son:

- ✓ La localización y la localización superficial son los que requieren la compra y el registro de la energía visible radiante y la materia que los objetos de la superficie.
- ✓ Todos los objetos radian de forma diferente y de diferente magnitud.
- ✓ Esta variable depende de la composición de la materia, las propiedades de la materia, la química y la energía de la superficie.
- ✓ Existen varios pasos en las operaciones de teledetección y pasos en la fase, que son pasos que son pasos que son pasos que son pasos, que son pasos, que son pasos, que son pasos.

Cada proceso se divide en diferentes pasos, que incluyen los siguientes:

- ✓ Emisión única (también autoemisión solar y emisión solar).
- ✓ Absorción y dispersión en la transferencia de energía de la fuente a la superficie terrestre, incluyendo:
- ✓ Reflexión y emisión de la radiación solar interactiva de la superficie terrestre.
- ✓ El sensor remoto recibe energía de la superficie de la Tierra.
- ✓ Salida de datos del sensor.
- ✓ Transmisión y procesamiento (Anji-Reddy 2010; Chuvieco 2016).

2.2.7 Análisis de mezcla espectral (SMA)

El SMA es importante en la espectroscopia de imágenes de teledetección, porque esencialmente el espectro de cualquier píxel de una escena natural es una mezcla. SMA intenta responder dos preguntas: (a) ¿Cuáles son los espectros de los materiales individuales? (b) ¿Cuáles son las proporciones de los materiales individuales? Nos centramos en la mezcla lineal debido a su relativa simplicidad analítica y computacional y porque funciona satisfactoriamente en muchas aplicaciones prácticas. Analizamos los aspectos físicos del modelo de mezcla lineal, las interpretaciones geométricas y los algoritmos, y el análisis estadístico utilizando la teoría de la estimación

de mínimos cuadrados. Las principales aplicaciones de SMA están en las áreas de interpretación de imágenes hiperespectrales y detección de objetivos de subpíxeles (Salih 2023).

La SMA convierte los datos de radiación o reflectancia en fragmentos de unos pocos endmembers dominantes, los cuales constituyen elementos físicos esenciales de la escena y no constituyen en sí mismos una combinación de otros elementos. Las representaciones gráficas de fracciones simbolizan las proporciones de mezcla de dichos espectros. La SMA usualmente conlleva tres etapas: a) la evaluación de la dimensionalidad o la cantidad de materiales reflectantes singulares en un paisaje para obtener los endmembers; b) la identificación de la naturaleza física de cada endmember dentro de un píxel; c) la determinación de las magnitudes de cada endmember en cada píxel (Salih 2023).

2.2.8 Índice de Fracción de Diferencia Normalizada (NDFI)

Para una detección óptima de la alteración del dosel forestal, se utilizan primero las bandas de reflectancia de la superficie del S2 para modelar fracciones de subpíxel (endmembers) de vegetación verde (GV), vegetación no fotosintética (NPV), suelo desnudo y sombra. Para ello se emplea un SMA (Souza y Roberts 2005). Para la modelización precisa de las fracciones de los miembros finales de los píxeles en bosques degradados, es imprescindible una identificación óptima de los espectros de entrenamiento puros (100% GV, NPV, suelo desnudo o sombra). Por lo general, se usa la biblioteca espectral desarrollada específicamente para miembros finales en paisajes forestales degradados (Souza y Roberts 2005).

Para mejorar la sensibilidad de esta información hacia la degradación forestal, se sintetizaron fracciones de subpíxel de endmembers en el NDFI, que se utiliza con éxito para la detección de la degradación de la selva tropical (Souza y Roberts 2005; Souza et al. 2005a; Souza et al. 2005b).

2.2.9 Random Forest (RF)

Un RF es un clasificador de aprendizaje automático supervisado que comprende una estructura de árbol, un vector independiente único y una entrada para la clase más famosa de x . En RF, para producir cada árbol individual, se siguen los siguientes pasos. En la prueba bootstrap, en N número de conjuntos de datos de preparación, se examinan N número de registros sin rumbo fijo mediante la sustitución de los datos originales (Breiman 2001). Esta es la primera etapa para desarrollar el árbol. En caso de que haya M factores de entrada, se elige un número $m \ll M$ con el objetivo de que, en cada nodo, se elijan m factores al azar de M , y la mejor división de estos m créditos se utilice para formar parte del nodo. La estimación de m se mantiene constante durante el desarrollo del bosque. Cada árbol se desarrolla hasta el mayor grado de división. De esta manera, se activan varios árboles en el bosque; la cantidad de árboles está preseleccionada por el límite N_{tree} . El número de factores (m) elegidos en cada nodo también se denomina m_{try} o k en la literatura (Breiman 2001).

La profundidad del árbol puede limitarse mediante un tamaño de nodo límite (por ejemplo, el número de ocurrencias en el nodo de hoja), que generalmente se establece en 1. Cuando el bosque se prepara o se trabaja como se explicó anteriormente, para organizar otro evento, se tropieza con todos los árboles desarrollados en el bosque. Cada árbol se divide en varias instancias que se registran como un voto. Los votos de todos los árboles se acumulan y la clase que tiene el número máximo de votos se asigna como la agrupación de la nueva instancia (Breiman 2001).

2.2.10 Sentinel-2 (S2)

La misión óptica S2 ofrece una combinación sin precedentes de cobertura global sistemática de superficies terrestres, una alta frecuencia de revisita y una alta resolución espacial. Todos estos requisitos se cumplen con dos satélites idénticos S2. El primero (S2A) se lanzó el 23 de junio de 2015, mientras que el S2B, idéntico al S2A, se lanzó el 6 de marzo de 2017. Este

último se colocó en la misma órbita, pero a 180 grados de distancia del S2A (lado opuesto de la órbita) para reducir el tiempo entre visitas a una zona geográfica determinada. Como constelación, el mismo punto sobre el ecuador se visita cada 5 días, y esto es aún más rápido en latitudes más altas (Mpakairi et al. 2020).

Cada satélite, que pesa 1 140 kg (incluido el combustible), ha sido diseñado para una vida útil mínima de al menos 7,25 años en una órbita heliosincrónica planificada de 786 km con una inclinación de 98,5 grados con respecto al ecuador y con un km de la costa, todas las islas de más de 100 km², todas las islas de la UE, el mar Mediterráneo y todos los mares cerrados (por ejemplo, el mar Caspio). En cuanto a las aplicaciones, S2 monitorea la variabilidad del cambio climático en la superficie terrestre, la respuesta a emergencias y los dominios de seguridad. S2 está diseñado para proporcionar imágenes que se puedan usar para distinguir entre diferentes tipos de cultivos y datos sobre numerosos índices de plantas, como el índice de área foliar, el contenido de clorofila en las hojas y el contenido de agua en las hojas, todos los cuales son esenciales para monitorear con precisión el crecimiento de las plantas. Con sus 13 canales espectrales, el novedoso sensor de imágenes de la misión puede capturar parámetros de calidad del agua como la concentración de clorofila en la superficie, detectar floraciones de algas dañinas y medir la turbidez (o claridad del agua), brindando una indicación clara de los niveles de salud y contaminación (Mpakairi et al. 2020).

2.2.11 Densidad de biomasa sobre el suelo a nivel de huella GEDI L4B

Este producto L4B de GEDI proporciona estimaciones de 1 km x 1 km (1 km en adelante) de la densidad media de biomasa aérea (AGBD) basadas en observaciones realizadas desde la semana 19 de la misión, que comenzó el 18 de abril de 2019, hasta la semana 138 de la misión, que terminó el 4 de agosto de 2021. El producto Biomasa de Huella 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 cuadrícula se

describe en el Documento de Fundamentos Teóricos del Algoritmo GEDI L4B (ATBD). El producto L4B también proporciona las estimaciones correspondientes de 1 km del error estándar de la media. 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 L4A se modelan en un proceso sujeto a errores en lugar de medirse en un proceso que puede asumirse como libre de errores. El instrumento GEDI produce observaciones de alta resolución mediante telemetría láser de la estructura tridimensional de la Tierra. GEDI se lanzó el 5 de diciembre de 2018 y está acoplado a la Estación Espacial Internacional (EEI). GEDI recopila datos a nivel mundial entre las latitudes 51,6° N y 51,6° S con la mayor resolución y el muestreo más denso de cualquier instrumento de detección y telemetría de luz (lidar) en órbita hasta la fecha. El instrumento GEDI consta de tres láseres que producen un total de ocho transectos terrestres de haz, que consisten en muestras de huella de unos 25 m, espaciadas aproximadamente cada 60 m a lo largo de la trayectoria. Los transectos de haz de GEDI están espaciados aproximadamente a 600 m sobre la superficie terrestre en dirección transversal a la trayectoria, con un ancho transversal de aproximadamente 4,2 km.

Este conjunto de datos incluye 10 archivos de datos en formato GeoTIFF (*.tif) optimizado para la nube. Cada archivo proporciona estimaciones de 1 km de la densidad media de biomasa aérea, también se incluyen dos archivos complementarios en formato de documento portátil (*.pdf) (Pascual et al. 2023).

2.2.12 Modelo de elevación digital (DEM)

La Misión Topográfica Radar del Transbordador Espacial (SRTM) se realizó a bordo del Endeavour entre el 11 y 22 de febrero del 2000. En conjunto, la NASA y la NGA llevaron a cabo un proyecto internacional en la cual se recolectaron datos de radar para la elaboración de la primera base cartográfica con datos de casi el total de la tierra en 2000 (Rangel et al. 2023).

Los datos de la elevación digital SRTM son un modelo de elevación digital de casi alcance global. Este producto SRTM del JPL de la NASA tiene una resolución de 1 segundo de arco (30 metros). Este producto ha sido completado mediante la utilización de datos de libre acceso (ASTER GDEM2, GMTED2010 y NED), a diferencia de otras versiones que han sido completadas con fuentes comerciales y presentan datos vacíos. Se ha desarrollado una página para obtener más detalles que tiene que ver con las diferentes versiones (Rangel et al. 2023).

2.3 Definición de términos

Perturbación forestal: se refiere a procesos o entidades que ejercen un impacto considerable en los bosques mediante la mortalidad arbórea y la disminución del crecimiento (FAO 2012; FAO 2020).

Deforestación: se refiere a la incineración intencionada de terrenos bosques. Este fenómeno se manifiesta cuando se realiza la limpieza de terrenos destinados a la agricultura o la ganadería, y se emplea madera como fuente de energía, material de construcción o producto de manufactura (FAO 2012; FAO 2020).

Degradación forestal: se refiere a la reducción de la cobertura arbórea, la disminución de la biodiversidad en los bosques o la transición hacia una condición inferior de la estructura forestal (Asner et al. 2009).

Vegetación Fotosintética (GV): se refiere a las características espectrales vinculadas a los pigmentos utilizados en la respiración fotosintética de las hojas y al contenido acuoso en el dosel (Asner et al. 2009).

Vegetación no fotosintética (NPV): se compone de plantas envejecidas o muertas, hojarasca, pastos recolectados, residuos de la explotación forestal intensiva, y otros materiales superficiales brillantes con características específicas vinculadas a compuestos de carbono seco (Asner et al. 2009).

Suelo desnudo (S): área desprovista de cobertura sobre la superficie del terreno (Asner et al. 2009).

Biomasa forestal: es la cantidad de biomasa de un bosque es el resultado de la diferencia entre la producción mediante la fotosíntesis y el consumo mediante los procesos de respiración y cosecha. Por lo tanto, es una medida útil para evaluar los cambios en la estructura forestal. Los cambios en la densidad de biomasa forestal son provocados por la sucesión natural; actividades humanas como la silvicultura, la cosecha y la degradación; e impactos naturales como los incendios forestales y el cambio climático (Liang et al. 2023; Rangel et al. 2023).

Carbono forestal: los bosques sanos conservan el carbono en su biomasa (madera y vegetación) y en el suelo, lo que evita las emisiones a la atmósfera. La conservación de las tierras forestales promueve la salud del aire, el agua y el suelo y ayuda a combatir el cambio climático. La conservación a largo plazo garantiza que estos servicios naturales esenciales permanezcan intactos (Qin et al. 2021).

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN

3.1 Tipo de estudio

El estudio es descriptivo, correlacional y predictivo, porque analizó la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis de SMA para NDFI sobre la incertidumbre de las estimaciones de carbono forestal aéreo mediante la combinación de datos GEDI L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el 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 analizó la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis de SMA para NDFI sobre la incertidumbre de las estimaciones de carbono forestal aéreo mediante la combinación de datos GEDI L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025 (León y González 2020; Lozano et al. 2025).

3.3 Delimitación espacial y temporal

El estudio se llevó a cabo en los bosques del sureste de la Amazonia de Madre de Dios, con una extensión de 1 606 548,91 ha y comprende parte de los distritos de Huepetuhe, Madre de Dios, Inambari, Laberinto y Tambopata (Figura 1). Abarca desde los 12°6'59" a 13°7'24" de latitud sur hasta los 68°56'41" a 70°57'32" de longitud oeste, y se extiende en un rango altitudinal que va desde los 200 hasta los 550 metros sobre el nivel del mar (GOREMAD

y IIAP 2009; SENAMHI 2015; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021). El clima de la región se distingue por su marcada condición tropical cálida y húmeda, con temperaturas que oscilan en alrededor de los 36°C en sus momentos más calurosos y una mínima de 10°C durante épocas de friaje. La temperatura media oscila en aproximadamente 26°C (SENAMHI 2015).

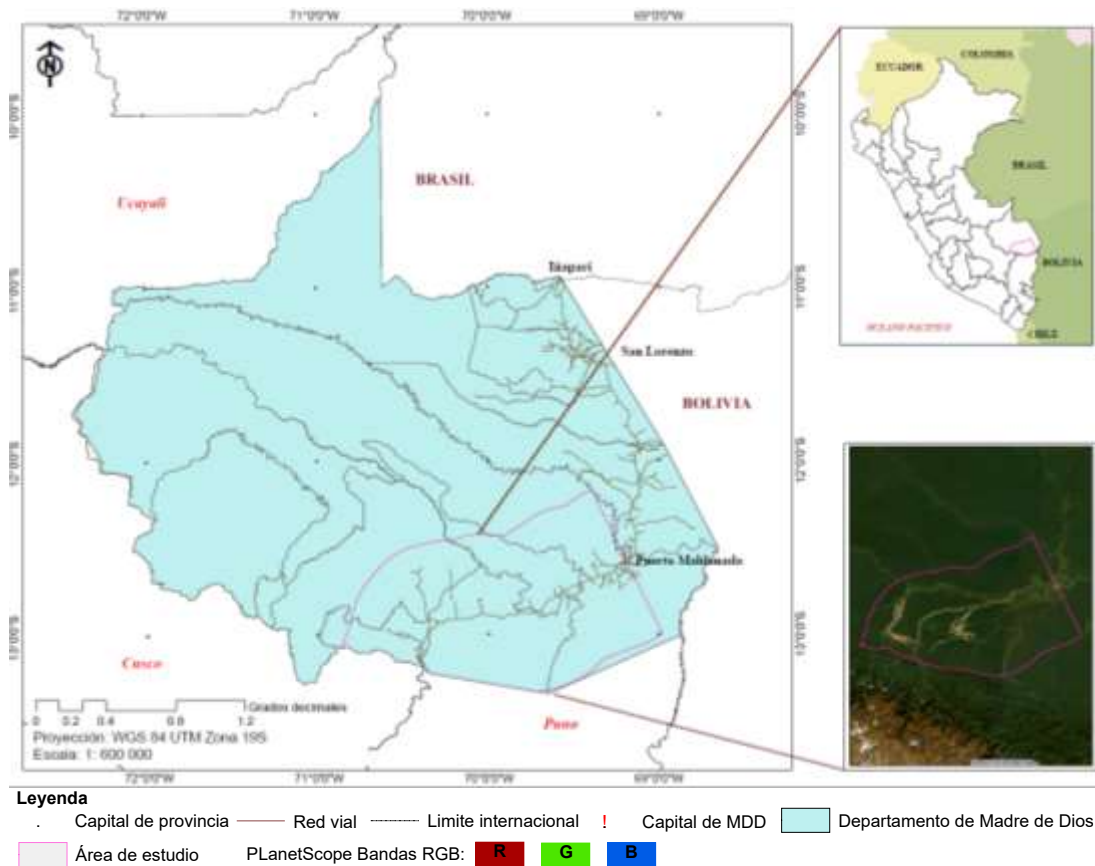


Figura 1. Ubicación del área de estudio.

De acuerdo con la clasificación de las zonas de vida, se cataloga específicamente como Tropical Cálido y Húmedo, lo que implica una constante presencia de altos niveles de humedad y una temperatura media anual que favorece la diversidad biológica en la región. Bosque Húmedo Tropical, también conocido como bosque lluvioso tropical, es un ecosistema caracterizado por altos niveles de precipitación y una diversidad biológica excepcional (Holdridge 1967). El extenso territorio se encuentra rodeado de exuberantes bosques, extensas áreas naturales protegidas, predios agrícolas,

y diversas poblaciones rurales e indígenas que coexisten en armonía con la naturaleza. La extracción de oro, la agricultura intensiva y extensiva, así como la ganadería intensiva y extensiva, son las actividades humanas que provocan los mayores impactos negativos en el paisaje natural. Los ríos Madre de Dios, Inambari, Tambopata y Las Piedras destacan como las principales redes hídricas de mayor afluencia en el área de estudio (Alarcon-Aguirre et al. 2021). El estudio se evaluó en la época seca del año 2025.

3.4 Población y muestra

El área de estudio comprende una población de 16 065,49 km² (1 606 548,91 ha). El cual se delimito de acuerdo a lo propuesto por Dourojeanni (2014), donde el área de influencia de estos impactos puede extenderse hasta 50 km a cada lado de vía interoceánica (Puerto Maldonado-Inambari). La cantidad de muestras destinadas al análisis de la clasificación de la deforestación y degradación forestal mediante el método de análisis SMA para NDFI, en relación con la incertidumbre de las estimaciones de carbono forestal aéreo a través de la combinación de datos GEDI L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, desarrollo de una distribución binomial de probabilidad (Anaya y Chuvieco 2010; Chuvieco y Hantson 2010; Ochoa y Páez 2019). El tamaño de muestra se calculó mediante la ecuación 1:

$$n = \frac{Z^2 p(qN)}{(N-1)E^2 + Z^2 pq} \quad (\text{Ecuación 1})$$

Dónde:

Z: Es el valor de la curva normal estandarizada para un nivel determinado de probabilidad, 1,96 (95%).

p: indica el porcentaje de aciertos estimado, 0,50 (50%).

q: Indica el porcentaje de errores (q = 1 – p), 0,50 (50%).

N: Tamaño de la población.

E: El error permitido, 0,05 (5%).

$$= \frac{(1,96)^2 * 0,5(0,5 * 1\ 606\ 548,91)}{(1\ 606\ 548,91 - 1) * 0,05^2 + 1,96^2 * (0,5 * 0,5)}$$

$n = 384,07 = 384$ puntos de muestreo

Para asegurar una distribución homogénea de la muestra a lo largo de toda el área de estudio, se empleó un muestreo aleatorio estratificado, adoptando un enfoque probabilístico de conveniencia. El criterio de distribución por conveniencia se basó en la accesibilidad y las áreas de riesgo para el acceso de los tesisistas (Ochoa y Páez 2019).

La distribución se fundamentó en un conjunto de 384 muestras recolectadas a través de un criterio mixto que incorpora puntos aleatorizados, datos de campo e imágenes de satélite de alta resolución (PlanetScope, PersuSat-1 y WorldView). Se distribuyó en tres categorías distintas: (1) 128 muestras y/o puntos correspondientes a la categoría de "Deforestación", (2) 128 en la categoría de "Degradación forestal" y (3) 128 en la categoría de "Bosque" (Olivares y López-Beltrán 2019).




Figura 2. Distribución de muestras por estratos en el área de estudio.

3.5 Método y técnicas

El análisis de la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis de SMA para NDFI sobre la incertidumbre de las estimaciones de carbono forestal aéreo mediante la combinación de datos GEDI L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, utilizo todos los datos disponibles de polarización y reflectancia de S1 y S2 (Nivel 2A) del Ecosistema de datos espaciales de Copernicus de la Agencia Espacial Europea (ESA, <https://apps.sentinel-hub.com/eo-browser/>) (Tabla 2) que fueron cargados mediante las API de Python y Javascript de GEE (Gorelick et al. 2017).

Los productos de datos preprocesados de S1 correspondientes a la época estacional de junio a septiembre fueron analizados mediante la agregación en métricas espectrales temporales. Este análisis se llevó a cabo a través del cálculo de percentiles, específicamente el 25 y el 75, con el objetivo de determinar el rango intercuartílico (IQR) basado en la mediana (50). De manera análoga, los productos de S2 correspondientes al mismo intervalo temporal que los datos de S1 fueron restringidos a métricas percentiles (25, 75) (Indirabai y Nilsson 2024).

La información correspondiente a SMA y NDFI fue recolectada en la interfaz del navegador GEE. La NDFI establece una correlación entre los datos de bosques talados, tala selectiva y bosque no alterado en la Amazonía y las proporciones de suelo, sombra, vegetación verde (GV) y vegetación no fotosintética (NPV) a través de un modelo de SMA (Tabla 2, Ecuación 2) (Souza y Roberts 2005; Allnutt et al. 2013; Bullock et al. 2020c; Chen et al. 2021). Las magnitudes de NDFI oscilan entre -1 y 1 , la densidad de los bosques densos de dosel se estima en un valor aproximado de 1 , donde una disminución en la cobertura arbórea resultará en una disminución del NDFI con un valor cercano a -1 , lo que resultará en una deforestación total del bosque (Ecuaciones 3 y 4). Los bosques de dosel abierto manifiestan valores de NDFI similares a los bosques densos que han sufrido tala (Souza et al. 2005a; Schultz et al. 2016; Bullock et al. 2020c).

Se utilizó un método mixto para medir la precisión de los resultados de la clasificación de la deforestación y degradación, que incluirá trabajo de campo e imágenes de alta resolución. También se hizo un muestreo estratificado aleatorio por conveniencia en el diseño (Zhang et al. 2020). Para ambos escenarios, se llevó a cabo un análisis detallado mediante una matriz de confusión, la cual permitirá evaluar la precisión global del modelo y calcular la concordancia de kappa (k), un indicador de la fiabilidad de las predicciones realizadas (Cohen 1960; Elijah y Jensen 1996; Chuvieco 2002; Cohen et al. 2003; Chuvieco y Hantson 2010; Alarcón et al. 2016).

Respecto a la biomasa forestal aérea, se utilizó el instrumento GEDI que consta de 3 láseres que emiten pulsos a lo largo de 8 pistas paralelas y proporciona estimaciones de 1 km x 1 km (Longo et al. 2016; Csillik y Asner 2020; Campbell et al. 2021; Duncanson et al. 2022; Shendryk 2022; Guo et al. 2023; Pascual et al. 2023). Los datos utilizados incluyen AGB sobre estimaciones de 1 km x 1 km (GEDI L4B), que se obtendrán del Sistema de Información y Datos del Sistema de Observación de la Tierra de la NASA (ORNL DAAC, <https://daac.ornl.gov/>). Los datos de GEDI L4B para el año 2023 y se convirtieron a shapefiles mediante un script de Python de GEE (Longo et al. 2016; Csillik y Asner 2020; Campbell et al. 2021; Duncanson et al. 2022; Guo et al. 2023; Pascual et al. 2023).

La combinación de datos GEDI L4B con imágenes S1, S2, elevación y pendiente mediante un algoritmo de RF en GEE facilitó una estimación precisa y escalable de la AGB. GEDI L4B ofrecerá estimaciones exactas de AGB obtenidas de mediciones lidar, las cuales funcionan como datos de entrenamiento (Shendryk 2022; Guo et al. 2023; Indirabai y Nilsson 2024). Asimismo, S1 y S2 proporcionaron polarizaciones y bandas espectrales para capturar las características de la vegetación. Se integro datos elevación y pendiente con el objetivo de considerar las influencias topográficas en la distribución de AGB (Shendryk 2022; Guo et al. 2023; Pascual et al. 2023; Indirabai y Nilsson 2024). En GEE, se realizó una sincronización espacial y temporal de estos conjuntos de datos, y se entrenó en un modelo de RF empleando las huellas de GEDI como referencias, con las bandas espectrales

de S1, S2, elevación y la pendiente como variables predictoras (Shendryk 2022; Guo et al. 2023; Pascual et al. 2023; Indirabai y Nilsson 2024). Se procedió a la aplicación del modelo para la predicción de la AGB en la totalidad del área de estudio con un 60% de áreas de entrenamiento, y la validación se llevó a cabo mediante la utilización de huellas GEDI independientes para la validación (40%) (Shendryk 2022; Guo et al. 2023; Pascual et al. 2023; Indirabai y Nilsson 2024; El Masri y Xiao 2025).

La evaluación de la precisión del modelo, se procedió a calcular diversos criterios de eficiencia fundamentados en las predicciones generadas por el modelo y en conjuntos de datos de prueba que sean independientes entre sí: se incluyó el coeficiente de determinación (R^2 , Ecuación 1 y 2), el error cuadrático medio general (RMSE, Ecuación 3), así como el error cuadrático medio relativo (rRMSE, Ecuación 4) (Pascual et al. 2023).

Para determinar el CF aéreo, se empleó el valor promedio de carbono (C) contenido en la vegetación ($C = \text{biomasa forestal} \times 0,5 = \text{MgC/ha}$). Es importante tener en cuenta que la cantidad de carbono presente equivale al 50% de la AGB de los árboles existentes en el área de estudio, tal como lo indican diversos estudios (Malhi et al. 2004; Li et al. 2020; Zhang et al. 2022; Hunka et al. 2024).

3.6 Tratamiento de datos

3.6.1 Procesamiento de datos

El estudio comprenderá las siguientes fases:

- 1. Selección de datos de satélite:** los datos de S1 y S2 se obtuvieron del Ecosistema de datos espaciales de Copernicus de la Agencia Espacial Europea (ESA, <https://apps.sentinel-hub.com/eo-browser/>) (Gorelick et al. 2017), GEDI L4B del Sistema de Información y Datos del Sistema de Observación de la Tierra de la NASA (ORNL DAAC, <https://daac.ornl.gov/>), y el DEM del Servicio Geológico de Estados Unidos (USGS, STRM (<https://www.usgs.gov/>)) de la Misión

Topográfica Shuttle Radar (SRTM). Para el caso de S1 y S2 se consideró la estación seca (junio a setiembre) de 2025. La selección de imágenes ópticas considero la ausencia de nubosidad o <10%. Todas las imágenes S2 fueron de nivel 2A. Mientras que para GEDI, estuvo en función de la disponibilidad de datos del año de estudio.

Tabla 2. Información de datos Sentinel-2, GEDI L4B y DEM

Sensor	Fecha de datos	Nivel de procesamiento	Resolución espacial (m)
Sentinel-1 (S1)	2025/07/13 2025/09/10	Interferometric Wide Swath (IW) Level-1 GRD Ascendente	5 x 20 m
Sentinel-2 (A/B)	2025/07/19 2025/08/26	2A	10 y 20
GEDI L4B	2019-04-18 00:00:00 - 2023-03-16 23:59:59	AGB	1 km x 1 km
STRM	2014 - v3.	DEM	30




Figura 3: Mosaico de imágenes S1 con polarización VV.




Figura 4. Mosaico de imágenes S1 con polarización VH.




Figura 5. Mosaico de imágenes S2.




Figura 6. Datos GEDI L4B y superposición de puntos (533) en el área de estudio.



Figura 7. SRTM del área de estudio

- 2. Procesamiento:** respecto a la información S1 Ground-Range-Detected (GRD, con una resolución espacial de 5 x 20 m) destinada a su análisis. Este proceso implicó la implementación de métodos de filtrado moteado, normalización radiométrica del terreno y eliminación del ruido de borde, de acuerdo a lo propuesto por Mullissa et al. (2021). Además, los datos de S1 fueron segmentados en las polarizaciones VV (Vertical-Vertical) y VH (Vertical-Horizontal) respectivamente. Los datos fueron compilados en métricas espectrales a través del cálculo de percentiles (25 y 75) con el propósito de establecer un rango intercuartílico (IQR) fundamentado en la mediana (50). Este estudio abarcó el intervalo temporal que abarca los meses de junio a septiembre de 2025 (Tabla 2). Para S2, se emplearon los canales de color azul (B2), verde (B3), rojo (B4) e infrarrojo cercano (B8). Además, se utilizaron los canales de borde rojo (B5), infrarrojo cercano NIR (B6, B7 y B8A) e infrarrojo de onda corta SWIR (B11 y B12), que tienen una resolución de 10 m. Los valores espectrales fueron calculados utilizando los valores medios de los píxeles de 10 metros (Indirabai y Nilsson 2024). En lo concerniente a GEDI, se empleó el L4B, que ofrece información relativa a la densidad media de biomasa sobre el suelo (AGB), para realizar una caracterización detallada de las condiciones de la estructura forestal en la vegetación (Tabla 2) (Dubayah et al. 2020; Duncanson et al. 2020; Dubayah et al. 2022; Duncanson et al. 2022). Los datos de GEDI L4A AGB correspondientes al área de estudio serán descargados en el formato GeoTIFF (Longo et al. 2016; Csillik y Asner 2020; Campbell et al. 2021; Duncanson et al. 2022; Guo et al. 2023; Pascual et al. 2023).
- 3. SMA y NDFI:** para el procesamiento se utilizó imágenes S2 mediante la interfaz del navegador GEE. SMA, básicamente proceso imágenes apoyada en la física que ayudara a la derivación repetida y precisa de información cuantitativa de subpíxeles (Souza et al. 2005a), bajo el supuesto de que un espectro calculado por un sensor se considera como una combinación lineal de los espectros de todos los

componentes dentro del píxel y se considera que las proporciones espectrales de los miembros finales reflejan proporciones del área ocupada por características definidas en la superficie del suelo (Souza y Roberts 2005; Souza et al. 2005a; Chen et al. 2021). Matemáticamente, el SMA se puede escribir como:

$$R_i = \sum_{k=1} F_k R_{ki} + \varepsilon_i \quad (\text{Ecuación 2})$$

donde i es la banda espectral utilizada; $k = 1, \dots, n$ (número de miembros finales); R_i es la reflectancia espectral de la banda i de un píxel que contiene uno o más miembros finales; F_k es la proporción de miembros finales k dentro del píxel; R_{ki} se conoce como la reflectancia espectral del miembro final k dentro del píxel en la banda i , ε_i es el error para la banda i .

NDFI se relacionó con información de bosques degradados y bosque no alterada en la Amazonía con las proporciones de suelo, sombra, vegetación verde (GV) y vegetación no fotosintética (NPV) mediante un modelo de SMA (Ecuación 3 y 4) (Souza y Roberts 2005; Allnut et al. 2013; Bullock et al. 2020c; Chen et al. 2021). Estos píxeles combinados se desintegrarán en fracciones de firmas espectrales representativas de materiales puros (endmembers), en las que la reflectancia del píxel combinado se deriva de la combinación de las reflectancias de los elementos endmembers que se encuentran en el píxel (Tabla 3 y Figura 8).

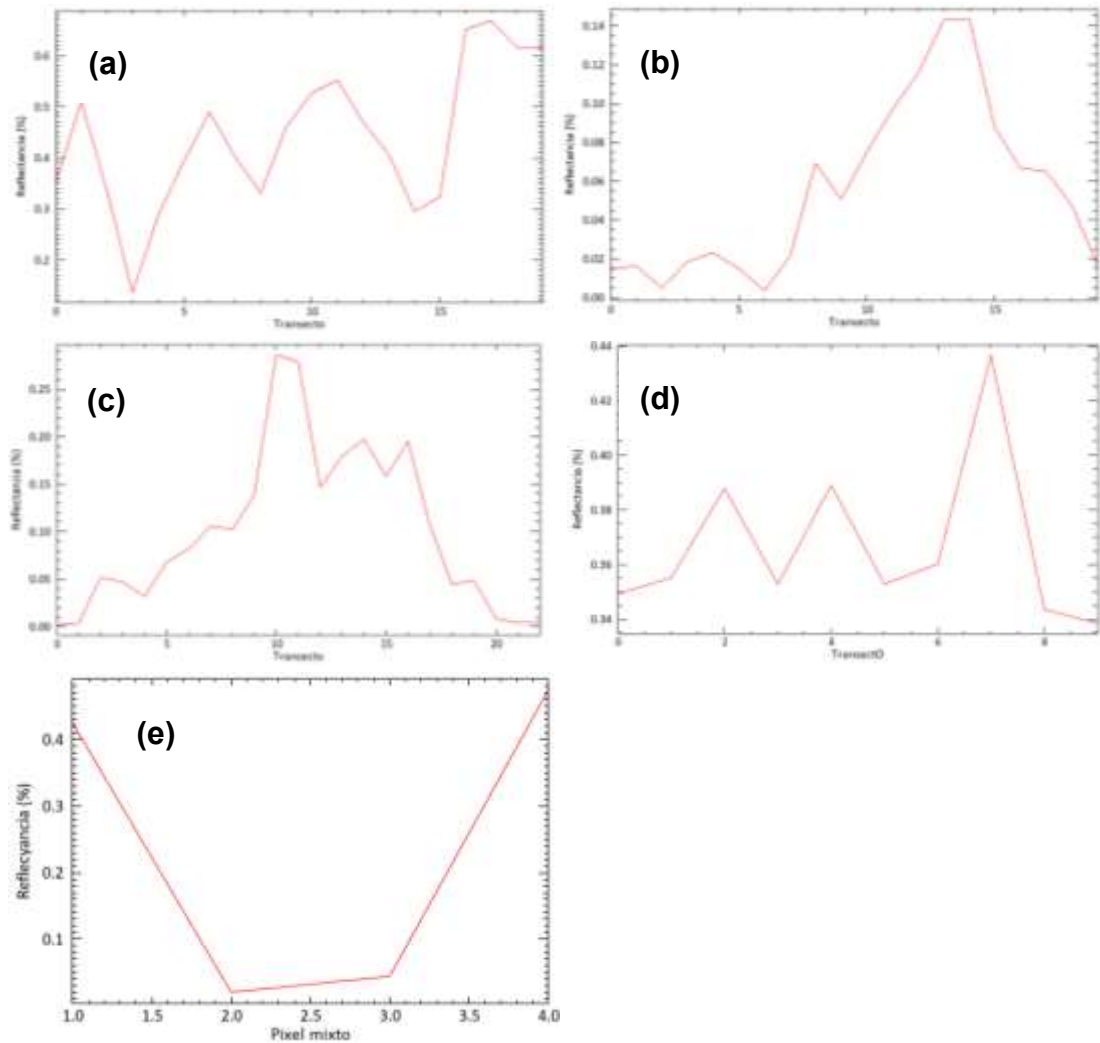


Figura 8. Firmas espectrales representativas de materiales puros (Endmembers) utilizadas en imágenes S2 para GV (a), NPV (b), Suelo (c), Sombra (d) y pixel mixto (e) de 20225.

Tabla 3. S2; umbrales de firmas espectrales representativas de materiales puros (Endmembers)

Materiales	Valores de firmad espectrales representativos					
	Azul	Verde	Roja	NIR	SWIR1	SWIR2
Sombra y nube	0,4031	0,8714	0,79	0,8989	0,7002	0,6607
Suelo	0,1799	0,2479	0,3158	0,5437	0,7707	0,6646
Vegetación fotosintética (NPV) no	0,1514	0,1597	0,1421	0,3053	0,7707	0,1975

Vegetación verde (GV)	0,0119	0,0475	0,0169	0,625	0,2399	0,0675
-----------------------	--------	--------	--------	-------	--------	--------

Fuente: tomado y adaptado de Souza et al. (2005a).

NDFI se expresa mediante:

$$NDFI = \frac{GV_{Shade} - (NPV + Soil)}{GV_{Shade} + (NPV + Soil)} \quad (\text{Ecuación 3})$$

donde

$$GV_{Shade} = \frac{GV}{1 - Shade} \quad (\text{Ecuación 4})$$

El rango de valores de NDFI va de -1 a 1; cuantificando a los bosques con un denso dosel con un valor de 1. La reducción de cobertura arbórea de un bosque se puede suponer que con un índice NDFI cercano a -1. Bosques con un dosel abierto presentan valores de NDFI comparables a aquellos de bosques que han sido sometidos a un raleo (Souza et al. 2005a; Schultz et al. 2016; Bullock et al. 2020c). La Tabla 4 los valores de NDFI considerados en el estudio.

Tabla 4. Valores adaptados de NDFI

Categoría	Valores NDFI
Deforestación	$\leq 0,60$
Degradación forestal	$> 0,50$ y $\leq 0,60$
Bosque	$> 0,60$

Fuente: Tomado y adaptado de Souza et al. (2005a).

- 4. AGB:** la combinación de datos GEDI L4B con imágenes S1, S2, elevación y pendiente se realizó con el algoritmo de RF en GEE con la finalidad de estimar de manera precisa y escalable la AGB. GEDI L4B ofrecerá estimaciones exactas de AGB obtenidas de mediciones lidar,

las cuales funcionan como datos de entrenamiento (Shendryk 2022; Guo et al. 2023; Indirabai y Nilsson 2024). Asimismo, S1 y S2 proporcionara polarizaciones (VV y VH) y bandas espectrales para capturar las características de la vegetación. Se integro datos elevación pendiente con el objetivo de considerar las influencias topográficas en la distribución de AGB (Shendryk 2022; Guo et al. 2023; Pascual et al. 2023; Indirabai y Nilsson 2024). En GEE, se realizó una sincronización espacial y temporal de estos conjuntos de datos, y se entrenó en un modelo de RF empleando las huellas de GEDI como referencias, con las polarizaciones de S1, bandas espectrales de S2, elevación y pendiente como variables predictoras (Shendryk 2022; Guo et al. 2023; Pascual et al. 2023; Indirabai y Nilsson 2024). Se procedió a la aplicación del modelo para la predicción de la AGB en la totalidad del área de estudio con un 60% de áreas de entrenamiento, y la validación se llevara a cabo mediante la utilización de huellas GEDI independientes para la validación (40%) (Shendryk 2022; Guo et al. 2023; Pascual et al. 2023; Indirabai y Nilsson 2024; El Masri y Xiao 2025).

RF, al ser un algoritmo de aprendizaje automatico flexible y fácil de usar, permitió producir incluso sin ajuste de hiperparametros, un gran resultado en la mayoría de los procesos (Breiman 2001). También, debido a su simplicidad y diversidad, se puede utilizar tanto para tareas de clasificación como de regresión, que es nuestro caso, con ello, creamos un conjunto de múltiples árboles de decisión para llegar a una predicción o resultado singular y más preciso de la AGBD (Malhi et al. 2004; Li et al. 2020; Zhang et al. 2022; Hunka et al. 2024).

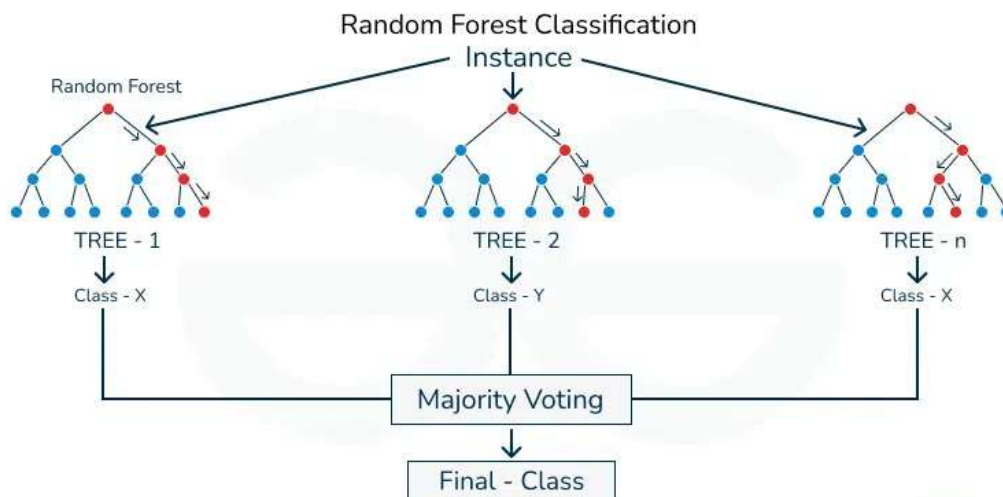


Figura 9. Algoritmo de Random Forest (RF).

Fuente: Tomado de Tin (1995).

5. CF aéreo: se empleó el valor promedio de carbono (C) contenido en la vegetación ($C = \text{biomasa forestal} \times 0,5 = \text{Mg C/ha}$). Es importante tener en cuenta que la cantidad de carbono presente equivale al 50% de la AGB de los árboles existentes en el área de estudio, tal como lo indican diversos estudios (Malhi et al. 2004; Li et al. 2020; Zhang et al. 2022; Hunka et al. 2024).

El geoprocesamiento de datos se desarrolló para todos los casos en el sistema de proyección World Geodetic System 1984 (WGS 84) zona 19 S.

3.6.2 Precisión de datos

Los mapas de bosques intacto, degradación forestal y deforestación se validó mediante la precisión general y la concordancia de kappa (Ecuaciones 5 y 6). Con base en el número dado por la Ecuación 1, se recopiló la cantidad necesaria de puntos de muestra (Cohen 1960; Cohen et al. 2003; Cerda y Villarroel 2008; Kuhn y Johnson 2013; Alarcón et al. 2016).

$$\text{Precision general} = \frac{VP + VN}{VP + FP + VN + FN} \quad (\text{Ecuación 5})$$

donde: VP es verdadero positivo, VN verdadero negativo, FP falso positivo, y FN falso negativo.

$$Kappa(k) = \frac{f_o - f_c}{N - f_c} \quad (\text{Ecuación 6})$$

donde: f_o : proporción de unidades concordantes, y f_c : proporción de unidades para las que se espera una concordancia al azar.

Tabla 5. Valores del coeficiente kappa

Kappa	Concordancia
“0,00”	“Pobre (<i>Poor</i>)”
“0,01 – 0,20”	“Leve (<i>Slight</i>)”
“0,21 – 0,40”	“Aceptable (<i>Fair</i>)”
“0,41 – 0,60”	“Moderada (<i>Moderate</i>)”
“0,61 – 0,80”	“Considerable (<i>Substantial</i>)”
“0,81 – 1,00”	“Casi perfecta (<i>Almost perfect</i>)”

Fuente: Cerda y Villarroel (2008); Cohen (1960); (Cohen et al. 2003); Landis y Koch (1977).

La validación se realizó mediante una metodología mixta utilizando datos de campo y de imágenes satelitales (Figura 5). Las imágenes corresponden a WorldView (0,38m), PeruSat-1 (0,70m panchromática y 2,8m multiespectral), y PlanetScope (3m) (Planet-Team 2025). La metodología de campo se basó en el modelo desarrollado por el “Centro para el Estudio de Instituciones, Población y Cambio Ambiental de la Universidad de Indiana (CIPEC)” (Moran y Brondizio 1998; Chávez et al. 2013).




Figura 10. Validación de la deforestación, degradación forestal y bosque mediante imágenes de PlanetScope (a) con una resolución espacial de $3\text{ m} \times 3\text{ m}$, Perusat-1 (c) con $0,7\text{ m} \times 0,70\text{ m}$ y de $2,8\text{ m} \times 2,8\text{ m}$, y WorldView (c) de $0,38\text{ m} \times 0,38$.

Fuente: Planet-Team (2025).

La evaluación de la precisión del modelo RF para AGB, se procedió a calcular diversos criterios de eficiencia fundamentados en las predicciones generadas

por el modelo y en conjuntos de datos de prueba que sean independientes entre sí: se incluyó el coeficiente de determinación (R^2 , Ecuación 7 y 8), el error cuadrático medio general (RMSE, Ecuación 9), así como el error cuadrático medio relativo (rRMSE, Ecuación 10) (Pascual et al. 2023).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (\text{Ecuación 7})$$

$$R^2 = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (\text{Ecuación 8})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad (\text{Ecuación 9})$$

$$rRMSE = \frac{RMSE}{\bar{x}} \times 100 \quad (\text{Ecuación 10})$$

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

Para ello, se procedió a la aplicación del modelo para la predicción de la AGB en la totalidad del área de estudio con un 60% de áreas de entrenamiento, y la validación se llevara a cabo mediante la utilización de huellas GEDI independientes para la validación (40%) (Shendryk 2022; Guo et al. 2023; Pascual et al. 2023; Indirabai y Nilsson 2024; El Masri y Xiao 2025).

3.6.4 Análisis estadístico

En función a los objetivos planteados, se realizó el siguiente procedimiento estadístico:

Para el primer objetivo, sobre calcular el índice de fracción de diferencia normalizada (NDFI) utilizando el método de análisis de mezcla espectral (SMA) que considera distintas coberturas como vegetación verde (GV), vegetación no fotosintética (NPV), suelo, sombra y nube en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, se analizó mediante GEE.

El segundo objetivo, sobre estimar la magnitud de la deforestación y degradación forestal a través del índice de fracción de diferencia normalizada

(NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, se analizó mediante GEE, ArcGIS 10,8® y ArcGIS Pro 3,4®.

El tercer objetivo, sobre medir la precisión de la clasificación de la deforestación y degradación forestal producto del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, se realizó la matriz de confusión e índice de kappa con el software SigmaPlot 15®

El cuarto objetivo, sobre cuantificar la biomasa forestal con el modelo Random Forest (RF) mediante la combinación de datos GEDI nivel L4A con Sentinel-2 (S2), modelo de elevación digital (DEM) y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, se procesó mediante GEE, ArcGIS 10,8® y ArcGIS Pro 3,4®.

El quinto objetivo, sobre determinar el carbono forestal por tipo de cobertura de suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, se estimará el CF en bosques degradados versus otros tipos de cobertura.

Finalmente, el sexto objetivo, sobre analizar la cuantificación del carbono forestal por la incertidumbre de la clasificación de la degradación forestal en la cartografía de cobertura del suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, se analizará la fiabilidad del modelo sobre la cuantificación del CF.

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1 Análisis de mezcla espectral (SMA) para NDFI en los bosques del sureste de la Amazonia de Madre de Dios

Los resultados se enmarcan en procedimientos previos de la investigación (Figura 8 y Tabla 3) donde se identifica la degradación forestal mediante técnicas de SMA en el área de estudio para 2025 (Figura 12).




Figura 11. Fracciones representativas de materiales puros (Endmembers) de GV (a), NPV (b), suelo (c) y sombra (d) del área de estudio.

Se realizó un seguimiento de las perturbaciones a través de la implementación del NDFI durante el año 2025 (Figura 12). Además, investigaciones anteriores han demostrado que el NDFI exhibe una mayor susceptibilidad a las

perturbaciones en los bosques tropicales en comparación con otros índices espectrales (Schultz et al. 2016). Se constató que, en determinadas circunstancias, el agua puede exhibir valores de NDFI equiparables a los de los bosques. Por lo tanto, se optó por eliminar del análisis la nubosidad, la sombra de nubes y las fuentes de agua. Pese a ciertas limitaciones, se argumenta que el NDFI, al integrar coeficientes de regresión para GV, NPV, Suelo y Sombra como insumos en la clasificación de la cobertura del suelo, presenta una superioridad en comparación con los métodos convencionales de clasificación y detección de la degradación forestal y deforestación.




Figura 12. NDFI en escala de grises para el área de estudio.

El valor del NDFI en los bosques no afectados por la intervención humana es casi 1. Una afectación de la cubierta conlleva una reducción del NDFI, mientras que, si se tala en su totalidad el bosque provocaría la deforestación, en el que los valores descienden considerablemente, hasta -1 (Souza et al. 2003; Souza y Roberts 2005; Souza et al. 2005b; Souza et al. 2013; Salih 2023).

4.2 Deforestación y degradación forestal a través del NDFI en los bosques del sureste de la Amazonia de Madre de Dios

En el año 2025, la deforestación alcanzó una proporción superior en comparación con la degradación forestal, registrando un 83,82% y afectando un total de 164 282,65 ha, este fenómeno fue atribuido a diversas actividades productivas, extractivas e infraestructurales, como se ilustra en la Figura 13-14. La degradación forestal se registró en un 16,18%, lo que equivale a 31 723,24 ha.

En términos generales, se estima que aproximadamente 196 005,89 ha de bosque en el área de estudio han experimentado algún tipo de perturbación para el año 2025 (Figuras 13-14). En este contexto, se observa que la deforestación representa una proporción mayor en comparación con la degradación forestal.

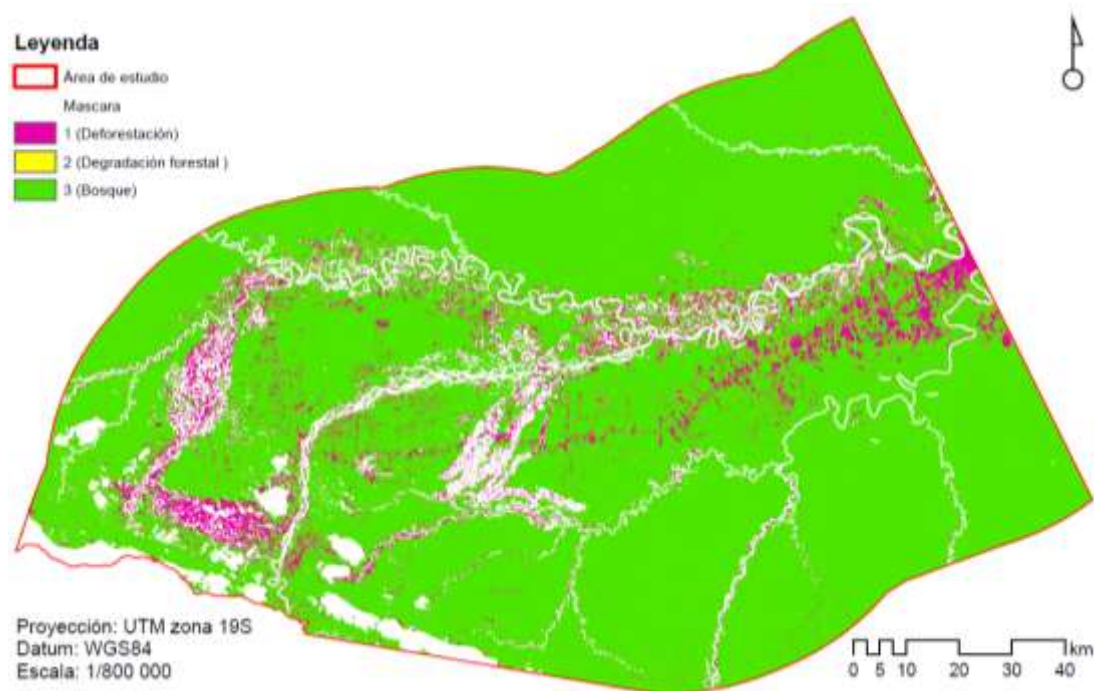


Figura 13. NDFI del área de estudio.

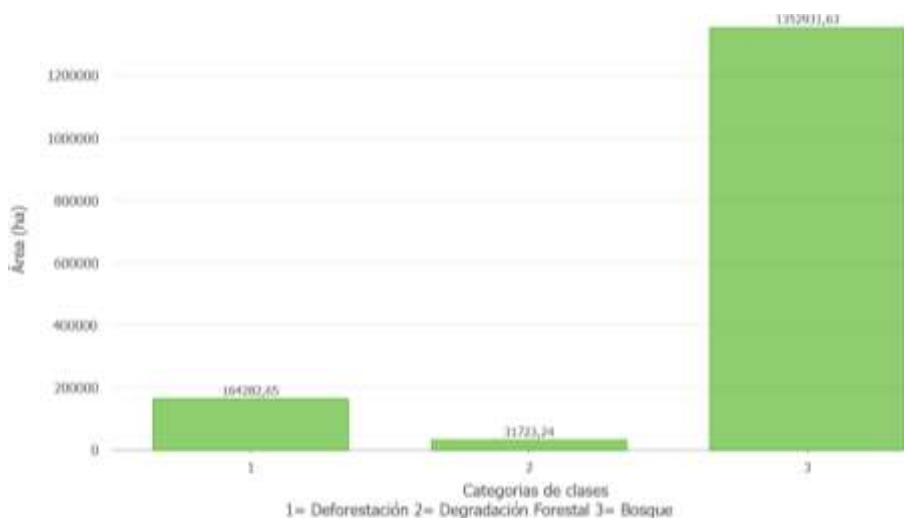


Figura 14. Cuantificación de categorías; deforestación, degradación forestal y bosque.

En el campo de investigación se observa una superposición de derechos en la que se entrelazan terrenos agrícolas, comunidades indígenas, títulos habilitadores (concesiones forestales) y Áreas Naturales Protegidas. Estas últimas comprenden la Reserva Comunal Amarakari, el Parque Nacional Manu y la Reserva Nacional Tambopata, junto con sus respectivas zonas de amortiguamiento. Esta última se distingue por un conglomerado de paisajes que, predominantemente, están afectados por actividades tales como la extracción de oro, la agricultura y la tala de árboles.

En este contexto, la deforestación mostró una mayor superficie (164 282,65 ha), en comparación con la degradación forestal. No obstante, se muestra una degradación del bosque a considerar (31 723,24 ha).

En cuanto a la degradación forestal, esta puede ser atribuida a muchas causas, entre las cuales sobresalen la presión de la agricultura migratoria y la tala de árboles, sin embargo, esta situación en muchos casos, puede de ser revertida, pero, para lograrlo, es fundamental implementar un sistema de monitoreo eficiente, así como desarrollar estrategias de recuperación que involucren a los actores y sectores pertinentes.

La deforestación exhibe un patrón análogo, aunque con una mayor cuantificación, en el cual se evidencia una mayor implicación de la minería de

oro, seguida por la agricultura de migración. La magnitud de la degradación forestal y la deforestación puede ser entendida mediante la interacción de múltiples factores, incluyendo la minería de oro, la agricultura permanente, el cultivo migratorio, la ganadería y la tala selectiva (Baraloto et al. 2015; Perz et al. 2016; Mendoza et al. 2017; Alarcon et al. 2020; Alarcon-Aguirre et al. 2021; Alarcón et al. 2021; Perz et al. 2022; Alarcon-Aguirre et al. 2023).

Los datos obtenidos reportan la magnitud de la pérdida de cobertura forestal y su distribución en función del grado de perturbación, donde el impacto de la deforestación es considerable, sin embargo, no se debe desmerecer a la degradación forestal, por lo que debe ser considerado en los planes de gestión del territorio (Alarcón et al. 2021; Eckert et al. 2024).

Los hallazgos presentan diferencias en comparación con investigaciones anteriores (Souza et al. 2005a; Allnutt et al. 2013; Zhu y Woodcock 2014; Bullock et al. 2020a; Bullock et al. 2020c; Bullock et al. 2020d; Aryal et al. 2021; Eckert et al. 2024), en las que se registró que el porcentaje de degradación forestal sobrepasaba al de la deforestación. Esta variación puede ser atribuida a los efectos indirectos generados por los proyectos de infraestructura, así como a la presencia de áreas naturales protegidas y territorios de comunidades indígenas que fomentan la preservación de los recursos forestales.

El presente estudio examina la evolución de la dinámica y las tasas de cambio de la cubierta forestal en uno de los sectores más impactados por la intervención humana, empleando el método SMA. No solo la deforestación desempeña un papel, sino también la degradación de las masas forestales. Adicionalmente, el objetivo es delinear la dinámica de cambio forestal, en particular la degradación forestal, ocasionada por prácticas como la agricultura migratoria, la tala selectiva y los incendios, entre otras, utilizando información recolectada desde el espacio. A lo largo del tiempo, numerosos estudios se han aventurado con la intención de tejer métodos y compendios que permitan descifrar las alarmantes tasas anuales de deforestación, la degradación de los majestuosos bosques y el caos que emerge en los ecosistemas arbóreos. Desafortunadamente, los resultados han resultado ser

más bien susurros en el viento, ineficaces para captar la magnitud de esta tragedia ecológica (Zhu y Woodcock 2014; Bullock et al. 2020a; Bullock et al. 2020b; Bullock et al. 2020c; Bullock et al. 2020d; Eckert et al. 2024). La lucha por salvaguardar los bosques continúa, como una batalla sin cuartel contra un enemigo casi invisible. No obstante, existen escasas investigaciones que hayan empleado estos enfoques SMA para investigar la dinámica forestal, especialmente en lo que respecta a la deforestación y la degradación forestal, en contextos de bosques tropicales. Numerosas investigaciones recurren a los conjuntos de datos del Cambio Forestal Global (GFC) (Hansen et al. 2013), que suministran actualizaciones anuales a nivel global sobre el porcentaje de pérdida forestal, conceptualizada como deforestación (sin abarcar degradación o perturbaciones múltiples). Estos datos se encuentran accesibles en la resolución de 30 × 30 m por píxel de Landsat; sin embargo, no se encuentran disponibles para el uso de S2. Caballero et al. (2018) utilizaron datos del GFC combinados con información de CLASlite propuesta por Asner et al. (2009). Su labor evidenció la devastadora tragedia de la deforestación y la degradación de los bosques Amazónicos, asediados por la minería artesanal de oro en la región de Madre de Dios, Perú. La investigación muestra el impacto del ecosistema y la lucha de sobrevivencia en un mundo que prioriza el oro. No obstante, la mayoría de las investigaciones han centrado su atención en las repercusiones directas de la minería en los bosques tropicales, sin embargo, no han evaluado las modificaciones indirectas en la utilización del suelo. La integración de avances recientes en tecnología y algoritmos, junto con el acceso a un archivo histórico completo de datos satelitales Landsat mediante servicios de computación en la nube, como GEE, ha posibilitado la supervisión de diversas perturbaciones forestales con un grado de detalle tanto espacial como temporal considerable. Esto permite entender el impacto de los grandes proyectos en los paisajes.

Como era previsible, la mayor parte de la deforestación se localizó en la cercanía de las vías de acceso y de los centros poblados, lejos de ellos, la deforestación y la degradación se mantuvieron bajas. Este patrón sugiere que hay impactos causados por prácticas como la agricultura migratoria, la

ganadería y la deforestación que son acelerados por las vías de acceso. Asimismo, es importante mencionar el rol de las comunidades indígenas en la protección del bosque, su vigilancia ante el surgimiento de actividades ilegales e informales que cambian el paisaje (Baraloto et al. 2015; Perz et al. 2016; Mendoza et al. 2017; Alarcon et al. 2020; Perz et al. 2022; Alarcon-Aguirre et al. 2023; Alarcón-Aguirre et al. 2023).

4.3 Evaluación de precisión de NDFI

Con el objetivo de corroborar la precisión del algoritmo para el año 2025, se elaboró una matriz de confusión para el NDFI, tal como se ilustra en la Tabla 6. Se desarrolló un modelo global con una precisión del 83,90% y una concordancia de kappa de 0,758, clasificado como "Considerable" (Tabla 5) (Cohen 1960; Cohen et al 2003). (Tabla 5) (Cohen 1960; Cohen et al. 2003).

Tabla 6. *Precisión con datos de campo e imágenes de alta resolución frente a datos de la NDFI S2*

Categoría		Datos de campo e imágenes de alta resolución			
		1	2	3	$f_{\text{NDFI S2}}$
NDFI S2 (2025)	1	101 (35)	22	5	128
	2	2	105 (46)	21	128
	3	1	11	116 (47)	128
	f_{PCxI}	104	138	142	384
$f_o=$	322			$f_c=$	128
$k=$	0,758			$k_M=$	0,961
$\sigma_k=$	0,0282			$\sigma_{k_o}=$	0,0361
$z=$	21,001			Matriz de confusión=	0,839

Las muestras aleatorias recolectadas durante la fase de validación (n=384) para el año 2025 resultaron apropiadas para evaluar la utilización de la cobertura del suelo, tales como la deforestación, la degradación forestal y los

bosques. Para ello, se analizaron los datos empleando un criterio de frecuencias periódicas (Cohen 1960; Cohen et al. 2003; Yaghobi et al. 2019). Con un valor de k de 0,758, más del cincuenta por ciento de las muestras verificadas coinciden de manera óptima y no aleatoria con los datos NDFI del satélite S2. $k_M = 0,961$ sugiere que una considerable proporción de las discrepancias puede atribuirse a diferencias menores que pueden modificar los resultados finales, donde la probabilidad de que el parámetro poblacional x oscile entre 0,703 y 0,813 es del 95% (Cohen 1960; (Landis y Koch 1977)Cohen et al. 2003). El valor de z (21,001) posee una significancia notable, con una probabilidad inferior a $(P) < 0,001$ (Tabla 5), lo que implica comparar un parámetro hipotético de la población con un estadístico muestral (Landis y Koch 1977; Yaghobi et al. 2019; Koley y Chockalingam 2022).

4.4 Biomasa forestal aéreo con el modelo RF mediante la combinación de datos GEDI nivel L4B con S1, S2, elevación y pendiente en los bosques del sureste de la Amazonia de Madre de Dios

En el entrenamiento se usó el 60% de los datos para crear el modelo. El modelo AGB (MU de GEDI L4B) muestra una alta concordancia, con un error cuadrático medio (RMSE) de 45,14 Mg/ha. Las variables independientes lograron explicar el 78,10% de la variabilidad del modelo, según el coeficiente de determinación (R^2), lo que indica que existe una relación lineal positiva.

En la Figura 15 se muestran las puntuaciones del modelo AGB, lo que permite entender mejor la importancia de la variable de características predictivas. La variable más importante fue la elevación del modelo SRTM. En el espectro del satélite S-2, el pico se localiza en la longitud de onda del Borde Rojo 1 (B5) y el valle en el infrarrojo cercano (NIR, B8). Los valores de la cuarta puntuación se relacionan con la pendiente, y las polarizaciones VV y VH corresponden con la penúltima y última puntuación, respectivamente. Estos hallazgos coinciden por lo propuesto por Kacic et al. (2021), que sostienen que las fracciones de las muestra proporcionan correlaciones positivas, por

consiguiente los datos son más precisos, ello genera, que el modelo mejora mientras más variables y fracciones se incluyan en el entrenamiento.

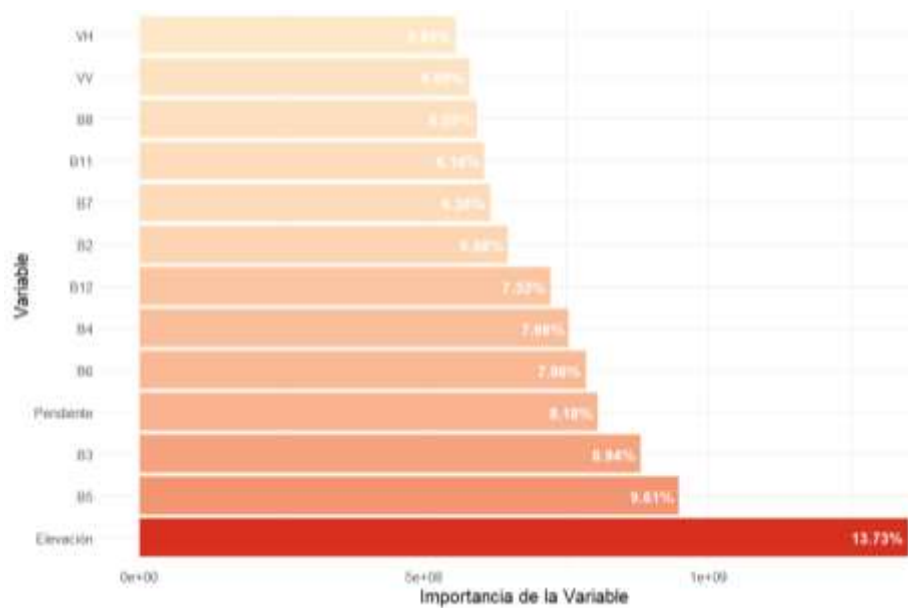


Figura 15. Importancia de las variables en el modelo RF (en puntuación y porcentaje).




Figura 16. Entrenamiento del modelo RF de datos predichos versus observado.

El proceso de validación del modelo se realizó con el 40% de los datos. El coeficiente de determinación (R^2) indica una correlación lineal positiva débil, donde el 37,40% de la variabilidad del modelo se explica por las variables

predictoras, allí, el RMSE fue de 71,83 Mg/ha, lo que significa que, en promedio, las estimaciones de biomasa forestal aérea se desvían en 71,83 Mg/ha de los valores reales, donde rRMSE fue de 36,72%, que es la media de la biomasa en el área de estudio.

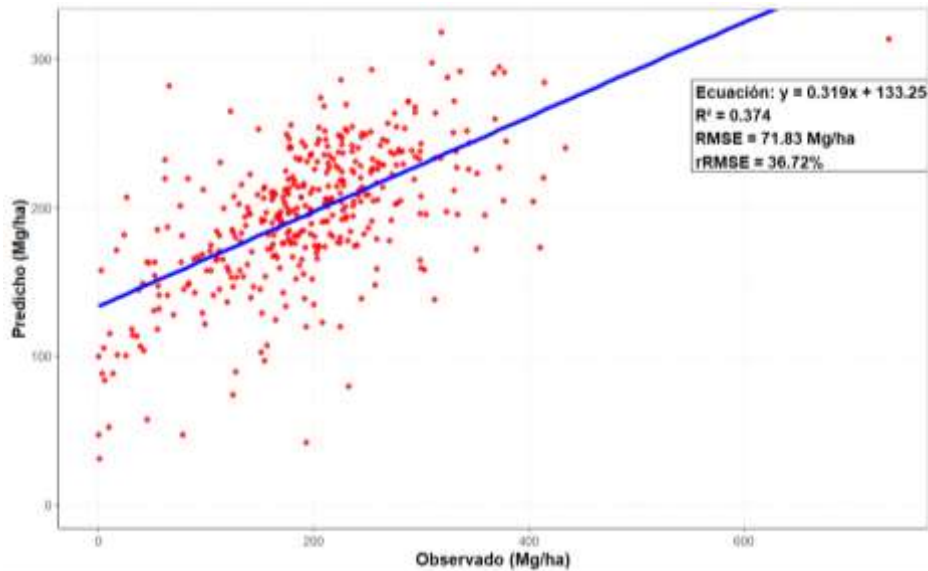


Figura 17. Validación del modelo RF de datos predichos versus observado.

Un R^2 de 0,781 en el conjunto de entrenamiento y de 0,374 en el conjunto de validación nos indica claramente que el modelo está sobreajustado. Un valor de R^2 de 0,781 significa que el modelo ha logrado explicar el 60% de la variabilidad en los datos. Esto indica que el modelo se ha sobreajustado a esa parte de los datos, con todo lo que ello implica (ruido, características propias de esas muestras, etc.), obteniendo un buen resultado. La validación del modelo, con un R^2 de 0,374, muestra una caída importante en la fase de validación (40% de los datos). Esto indica que el modelo no logra generalizar bien, es decir, los patrones aprendidos en la fase de entrenamiento no son representativos del conjunto de datos.

Si bien el sobreajuste puede ser una restricción, la metodología combinando datos GEDI L4B con S1, S2, elevación y pendiente usando RF muestra potencial de aplicabilidad en diferentes paisajes y estudios de biomasa forestal aérea, el modelo, entrenado con datos de alta fidelidad de GEDI, es capaz de aprender las relaciones entre estructura forestal (GEDI),

características espectrales (S2), textura y retrodispersión (S1) y topografía (DEM). Esta metodología tiene la capacidad de ser replicada para la creación de mapas de biomasa en otras localizaciones de la Amazonía u otros ecosistemas, ajustando el conjunto de datos de entrenamiento a la zona de interés. En ese sentido, el modelo se establece como una buena base metodológica que puede ser mejorada con mayor densidad de puntos de entrenamiento o técnicas de validación más robustas, llegando a ser una herramienta estandarizada y eficiente para el monitoreo forestal a gran escala.

La métrica GEDI L4B fue usada en la investigación, que mide la biomasa forestal aéreo, para entrenar un clasificador de RF en combinación con la mediana de sensores ópticos, SAR y modelos de elevación digital. Con este tipo de aproximación se pretende conocer mejor la dinámica forestal en la zona y apoyar la gestión sostenible de los recursos naturales, al compararse con un clasificador de RF de referencia que incluyó las variables S-1, S-2, elevación y pendiente, el modelo predijo una biomasa forestal aéreo (AGB) de 3 381 248 793,51 Mg, con un promedio de 191,95 Mg/ha y una mediana de 193,01 Mg/ha, en un rango de 24,69 a 365,69 Mg/ha, lo que demuestra no solo la capacidad del modelo para estimar la biomasa, sino también la importancia de las variables ambientales en la clasificación y evaluación forestal. La resolución espacial de 10 m permitió identificar con precisión diferentes objetos en el área de estudio y realizar una caracterización más profunda y detallada (Figura 18 y Tabla 7), también la capacidad de resolución permitió identificar elementos aislados, así como comprender mejor las relaciones y características del entorno estudiado, lo que contribuye a una evaluación más completa y efectiva del área en cuestión.




Figura 18. Biomasa forestal aérea en el área de estudio.

Tabla 7. Biomasa forestal aérea en el área de estudio

Total (Mg)	Media (Mg/ha)	Mediana (Mg/ha)	Desviación estándar
3 381 248 793,51	191,95	193,01	44,79

La combinación de datos GEDI L4B, S1, S2 y DEM para modelar la biomasa forestal aérea usando un algoritmo de RF es una metodología común en sensoramiento remoto, y se sustenta en los antecedentes de la investigación. Según Campbell et al. (2021) y Liang et al. (2023), que demostraron la capacidad de combinar datos GEDI/ALS con sensores ópticos (Landsat), a pesar de que el estudio actual expande esta línea de investigación al incluir nuevas variables usando datos radar (S1), que proporcionan mayor debido a la nubosidad constante en la Amazonía. La elección de GEDI L4B como referencia de campo para entrenar el modelo es una práctica común en la comunidad de teledetección. Pascual et al. (2023) examinaron la utilidad de los datos agregados GEDI L4B para validar y mejorar productos en celdas. Esta metodología se justifica con la incorporación de variables topográficas, como la elevación y la pendiente, cuya importancia ya ha sido demostrada en

estudios anteriores (Shendryk 2022) en la determinación de la distribución de la biomasa.

Los resultados del entrenamiento del modelo, con un coeficiente de determinación (R^2) de 0,781, muestran una capacidad predictiva similar a la de estudios anteriores, como las de Campbell et al. (2021), que lograron una R^2 de 0,68 combinando datos GEDI y Landsat, y Liang et al. (2023) lograron una R^2 de 0,64 en bosques de baja biomasa forestal aérea. El valor de R^2 de 0,781 en este estudio muestra que la combinación de datos de diferentes fuentes puede ser muy efectiva, pero el sobreajuste es un problema, debido a que genera una caída importante del rendimiento en la validación ($R^2 = 0,374$; RMSE = 71,83 Mg/ha) lo que indica que el modelo tiene problemas para generalizar en nuevas localizaciones. Aunque la metodología utilizada es sólida, se pueden hacer mejoras en la forma en que se aplica, los antecedentes muestran que hay posibles soluciones. Pascual et al. (2023) destacan la necesidad de ampliar la base de datos de entrenamiento GEDI como un elemento clave para mejorar el modelo, además, abren la puerta a futuros estudios para investigar si la inclusión de nuevas variables predictoras mejoraría significativamente el modelo. En esta solución, Campbell et al. (2021) y Shendryk (2022) tratan la propagación de la incertidumbre en el modelo de aprendizaje automático, lo que podría ayudar a resolver el sobreajuste.

4.5 Carbono forestal aéreo por tipo de cobertura de suelo

En la Figura 20 se puede observar la distribución espacial del carbono forestal aéreo en el área de estudio. Como era de esperar, la mayor cantidad de carbono se encuentra en las áreas de bosque intacto, en comparación con las áreas deforestadas o degradadas, que tienen densidades mucho menores, estos hallazgos destacan la importancia de la conservación de los bosques intactos para la mitigación del cambio climático, así como el monitoreo de bosques degradados con la finalidad de mitigar los impactos y desarrollar mecanismos de recuperación.




Figura 19. Carbono forestal en el área de estudio.

El carbono forestal aéreo por tipo de cobertura de suelo en el sureste de la Amazonía de Madre de Dios muestra diferencias en el carbono almacenado (Tabla 8), el bosque intacto es la categoría que más carbono almacena, con 1 540 179 765,89 MgC, con una densidad media de 100,08 MgC/ha, mediana de 100,04 MgC/ha y una desviación estándar de 18,70, lo que indica que son bosques densos y homogéneos. Las áreas deforestadas tienen un total de 119 207 455,2 MgC, con una densidad promedio de 63,92 MgC/ha. A pesar de la deforestación, esta categoría aún tiene carbono, ya sea por la biomasa remanente (tocones y ramas) o por vegetación secundaria en el área de estudio. En la categoría degradación forestal se tiene un almacenamiento de 31 237 175,67 MgC, con una densidad promedio de 86,5 MgC/ha. Este valor se encuentra entre la deforestación y los bosques, lo que representa una pérdida parcial de biomasa por tala selectiva y fuegos de sotobosque para uso agrícola.

La presencia de carbono forestal aéreo en áreas deforestadas, con una densidad promedio de 63,92 MgC/ha, puede parecer contradictorio, sin embargo, es consistente por la complejidad de los procesos de cambio de uso

de la tierra en la Amazonía, donde la deforestación no siempre implica la remoción completa de la materia orgánica forestal. Incluso después de la tala, una gran cantidad de biomasa (tocones, ramas, árboles caídos) puede permanecer en el lugar. Esta biomasa, ya sea leña o restos de cosecha, todavía contiene carbono, y que se puede calcular con el modelo de biomasa. Muchas áreas deforestadas, sobre todo posterior al uso del suelo no es intensivo, se regeneran naturalmente, es aquí, donde la vegetación secundaria (pastos, arbustos y árboles jóvenes de rápido crecimiento) comienza a acumular biomasa y a secuestrar carbono. Esto resulta en carbono aéreo en esas áreas. La teledetección generalmente clasifica un área como deforestada si pierde cierto porcentaje de cubierta forestal (80%), pero no necesariamente esta categorización implica una pérdida completa de la biomasa, la deforestación puede ser gradual, dejando remanentes de biomasa que siguen contribuyendo a la densidad total de carbono. Asimismo, las zonas cercanas a las áreas deforestadas, el bosque se ve perturbado por el estrés ambiental (efecto borde), este efecto, puede causar la muerte de árboles y la liberación de carbono. Pero también puede crear las condiciones para el desarrollo de nuevas especies que favorezcan la acumulación de biomasa. Todo este proceso, contribuye a que el carbono forestal aéreo en las áreas clasificadas como deforestadas no sea nulo.

Tabla 8. *Carbono forestal aéreo por tipo de cobertura en el área de estudio*

Estadística	Categorías (ha)		
	1 (Deforestación)	2 (Degradación forestal)	3 (Bosque)
Total (MgC)	119 207 455,2	31 237 175,67	1 540 179 765,89
Mínima (MgC/ha)	12,34	15,06	13,66
Máxima (MgC/ha)	178,98	179,22	182,85
Media (MgC/ha)	63,92	86,5	100,08
Mediana (MgC/ha)	66,72	81,64	100,04
Desviación estándar	23,59	22,58	18,70

Los resultados de la densidad media de carbono forestal aéreo en bosques intactos de 100,08 MgC/ha valida las metodologías de cuantificación utilizadas. Este valor está en semejanza con las densidades de carbono informadas para la Amazonía, donde los bosques maduros actúan como sumideros de carbono. La baja desviación estándar (18,70 MgC/ha) en esta categoría indica que los bosques intactos son bastante homogéneos en cuanto al carbono almacenado, lo que es un signo de salud de estos ecosistemas.

El estudio arrojó una densidad de 86,5 MgC/ha en bosques degradados, un punto medio entre bosques intactos y deforestación. Estos resultados concuerdan con lo reportado por Rappaport et al. (2018), quienes indican que los bosques degradados aún conservan gran parte de las reservas de carbono, aunque en menor medida (13,5% menos) que los bosques intactos. Lo reportado es consistente con el hallazgo encontrado por Rangel et al. (2023), que mencionan que la degradación forestal, al ser un proceso menos visible que la deforestación, es una fuente importante de emisiones y a menudo subestimada. Asimismo, destacan que la medición del carbono restante en estas zonas es útil para los inventarios de gases de efecto invernadero y para los programas de mitigación, como REDD+.

El hecho de encontrar una densidad media de carbono de 63,92 MgC/ha en zonas catalogadas como deforestadas puede parecer sorprendente en un principio para una zona que se supone que carece de arbolado. Este hallazgo es congruente con la historia de la investigación y puede deberse a varias razones. La deforestación, sobre todo la causada por la minería o por la pequeña agricultura, suele dejar tras de sí biomasa residual en forma de tocones, troncos caídos y ramas. Este carbono no se libera inmediatamente a la atmósfera. Como señalan Maxwell et al. (2019) y Rappaport et al. (2018), los bosques tienen la capacidad de regenerarse, y las zonas deforestadas pueden desarrollar rápidamente vegetación secundaria y arbustos, esta vegetación, aunque no es un bosque, puede acumular biomasa, es aquí, donde el modelo de biomasa basado en las métricas GEDI y Sentinel puede

ser útil para capturar la estructura de esta vegetación y proporcionar una estimación más precisa que multiplicar el área por un factor de emisión.

4.6 Carbono forestal aéreo por la incertidumbre de la clasificación de cobertura del suelo

Los resultados de la relación entre la precisión de los modelos de teledetección y la fiabilidad de las estimaciones de carbono, demuestran que, si bien la metodología es robusta y valiosa, la incertidumbre se propaga a lo largo de las fases de clasificación y modelado, lo que presenta tanto oportunidades como limitaciones.

Los resultados del estudio demuestran que la metodología es una herramienta prometedora para el monitoreo forestal, la precisión global del 83,90% y el coeficiente Kappa de 0,758 en la clasificación de la cobertura del suelo son considerables y validan el uso del SMA para diferenciar la degradación y la deforestación a gran escala, el método se enmarca en la ciencia de la teledetección, que resalta la capacidad de los modelos SMA para detectar perturbaciones en el bosque.

El modelo de biomasa de RF presentó un buen rendimiento en la fase de entrenamiento, con un coeficiente de determinación (R^2) de 0,781. Este valor, se compara a estudios previos (Campbell et al. 2021; Liang et al. 2023), que confirma la capacidad del modelo para aprender de la estructura forestal al combinar datos de GEDI, Sentinel y topografía, en ese sentido, la metodología se establece como una base sólida para futuros estudios, demostrando ser escalable y adaptable a diferentes paisajes.

A pesar de las bondades, la incertidumbre no es un problema de mala clasificación sino una limitación inherente a los modelos predictivos, como lo señalan estudios de incertidumbre en la teledetección (Rangel et al. 2023). La precisión de la clasificación entre las categorías de perturbación se realizó mediante la matriz de confusión y concordancia de kappa, que muestran que la degradación forestal es la más difícil de clasificar correctamente, esto debido al proceso sutil que implica la degradación, con una variabilidad en la

pérdida de biomasa que es difícil de capturar con precisión, una limitación reconocida por Rappaport et al. (2018). Esta incertidumbre se propaga de manera acumulativa a las estimaciones de carbono forestal aéreo. El sobreajuste del modelo de biomasa, evidenciado por la caída en la precisión durante la validación (RMSE de 71,83 Mg/ha), indica que el modelo no se generaliza bien, la incertidumbre en el mapa de cobertura y el error de predicción del modelo de biomasa se suman, lo que afecta directamente el cálculo final del carbono. Eso significa, que, al clasificar incorrectamente áreas de degradación como deforestación, el modelo sobreestima las emisiones de carbono, ya que asume una pérdida total que no ocurrió, contrariamente, al confundir áreas de bosque como degradación, subestima las reservas de carbono.

A pesar todo, la metodología de este estudio es una herramienta valiosa y confiable, pero no perfecta, porque resalta la necesidad de seguir mejorando la precisión en la clasificación de la degradación y los modelos de biomasa para obtener estimaciones de carbono más fiables. En ese sentido, lejos de ser un fracaso, este resultado es foco de alerta para futuras investigaciones que mejoren estas técnicas y, por lo tanto, ayuden a la toma de decisiones en la gestión forestal y la mitigación del cambio climático.

CONCLUSIONES

La metodología utilizó el SMA y el NDFI, mostrando ser eficaz para clasificar la deforestación y degradación forestal en el área de estudio.

La clasificación de la cobertura del suelo arrojó una exactitud global del 83,90% y un índice Kappa de 0,758, estos hallazgos confirman la capacidad del NDFI para el seguimiento de alteraciones forestales.

Se determinó que la deforestación fue el principal motor de perturbación del bosque, con un 83,82% y 164 282,65 ha afectadas mientras que la degradación forestal abarcó el 16,18% con 31 723,24 ha alteradas.

El modelo de biomasa usando RF predijo una biomasa aérea forestal total de 3 381 248 793,51 Mg, con un promedio de 191,95 Mg/ha, a pesar de ello, la confiabilidad del modelo se ve limitada por el sobreajuste que se produce en la validación.

Las áreas de bosque intacto albergan la mayor cantidad de carbono forestal aéreo, con 1 540 179 765,89 MgC, seguida de la deforestación con 119 207 455,2 MgC, y bosques degradados con 31 237 175,67 MgC. Los resultados demuestran la importancia de conservar los bosques y de monitorear la degradación forestal como mecanismos para mitigar el cambio climático.

La incertidumbre en la clasificación y modelado de biomasa se va acumulando y afecta directamente la incertidumbre en las estimaciones de carbono, en este caso, el sobreajuste del modelo de biomasa y la confusión entre degradación y deforestación son las principales fuentes de incertidumbre, lo que destaca la necesidad de mejorar las metodologías para un monitoreo más exacto.

Se rechaza la hipótesis nula y se acepta parcialmente la alterna, donde el modelo de análisis de mezcla espectral para el índice de fracción de diferencia normalizada permite estimar con precisión la incertidumbre del carbono forestal aéreo en áreas de degradación forestal en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025, debido al sobreajuste del modelo de biomasa, el cual debe ser tratado en futuras investigaciones.

SUGERENCIAS

Para futuros trabajos que busquen modelar la biomasa forestal, es fundamental centrarse en la robustez y la capacidad de generalización del modelo. Para ello, debe explorarse algoritmos más allá de los tradicionales, como técnicas de aprendizaje profundo (deep learning) o el aprendizaje por conjunto (ensemble learning) que pueden ser más efectivas para capturar las relaciones no lineales entre los datos del sensor y la biomasa, lo que podría llevar a modelos con un menor error de predicción y una mayor capacidad de generalización.

REFERENCIAS BIBLIOGRÁFICAS

- 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 ZAVALA, 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
- ALARCON-AGUIRRE, G., MIRANDA FIDHEL, R. F., RAMOS ENCISO, D., CANAHUIRE-ROBLES, R., RODRIGUEZ-ACHATA, L. Y GARATE-QUISPE, J. Burn Severity Assessment Using Sentinel-1 SAR in the Southeast Peruvian Amazon, a Case Study of Madre de Dios. *Fire*, 2022, 5(4). doi:<https://doi.org/10.3390/fire5040094>
- ALARCÓN-AGUIRRE, G., SAJAMI QUISPE, E., VÁSQUEZ ZAVALA, 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., DIAZ-REVOREDO, J. L. Y BARRIGA-PAREDES, V. Á. M. Dinámica de la pérdida de bosques en el sureste de la Amazonia peruana 2021/4/5 2021, 1(1). doi:<http://hdl.handle.net/20.500.14070/661>
- 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>

ALARCON, G., ZEVALLOS, P. A., QUISPE, R., RAMOS, D. Y GARATE-QUISPE, J. S. Valor de conservación de un bosque en el sureste de la Amazonia Peruana: El caso de Madre de Dios. *Revista Ecosistemas*, 2020, 29(3). doi:<https://doi.org/10.7818/ECOS.1947>

ALLNUTT, T. F., ASNER, G. P., GOLDEN, C. D. Y POWELL, G. V. N. Mapping recent deforestation and forest disturbance in northeastern Madagascar. *Tropical Conservation Science*, 2013, 6(1), 1-15. doi:10.1177/194008291300600101

ANAYA, J. A. Y CHUVIECO, E. Validación para Colombia de la estimación de área quemada del producto L3JRC en el periodo 2001-2007/Validation of the L3JRC burned area product estimation in Colombia from 2001 to 2007. *Actualidades Biológicas*, 2010, 32(92), 29.

ANJI-REDDY, M. *Geographical Information System. 3rd Edition, BS Publication, Hyderabad* [Type of Work]. 2010. Disponible en Internet:<<https://go.gale.com/ps/i.do?id=GALE%7CA242180195&sid=googleScholar&v=2.1&it=r&linkaccess=abs&issn=16920074&p=IFME&sw=w&userGroupName=anon%7E7ab09282&aty=open-web-entry>>

AQUINO, C., MITCHARD, E., MCNICOL, I., CARSTAIRS, H., BURT, A., PUMA VILCA, B. L., MAYTA, S. Y DISNEY, M. Detecting Tropical Forest Degradation Using Optical Satellite Data: An Experiment in Peru Show Texture at 3 M Gives Best Results. *Preprints.org*, 2022 2022. doi:10.20944/preprints202202.0141.v1

ARAUJO, E. C. G., SANQUETTA, C. R., DALLA CORTE, A. P., PELISSARI, A. L., ORSO, G. A. Y SILVA, T. C. Global review and state-of-the-art of biomass and carbon stock in the Amazon. *Journal of Environmental Management*, 2023/04/01/ 2023, 331, 117251. doi:<https://doi.org/10.1016/j.jenvman.2023.117251>

- ARYAL, R. R., WESPESTAD, C., KENNEDY, R., DILGER, J., DYSON, K., BULLOCK, E., KHANAL, N., KONO, M., POORTINGA, A., SAAH, D. Y TENNESON, K. Lessons learned while implementing a time-series approach to forest canopy disturbance detection in Nepal. *Remote Sensing*, 2021, 13(14). doi:10.3390/rs13142666
- ASNER, G. P., DAVID, E. K., ARAVINDH, B. Y GUAYANA, P.-A. Automated mapping of tropical deforestation and forest degradation: CLASlite. *Journal of Applied Remote Sensing*, 8/1 2009, 3(1), 033543. doi:10.1117/1.3223675
- ASSIS, T. O., DE AGUIAR, A. P. D., VON RANDOW, C., MELO DE PAULA GOMES, D., KURY, J. N., OMETTO, J. P. H. B. Y NOBRE, C. A. CO₂ emissions from forest degradation in Brazilian Amazon. *Environmental Research Letters*, 2020/09/24 2020, 15(10), 104035. doi:10.1088/1748-9326/ab9cfc
- BACCINI, A., GOETZ, S. J., WALKER, W. S., LAPORTE, N. T., SUN, M., SULLAMENASHE, D., HACKLER, J., BECK, P. S. A., DUBAYAH, R., FRIEDL, M. A., SAMANTA, S. Y HOUGHTON, R. A. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. *Nature Climate Change*, 2012/03/01 2012, 2(3), 182-185. doi:10.1038/nclimate1354
- 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>
- BREIMAN, L. Random forest, vol. 45. *Mach Learn*, 2001, 1. doi:10.1017/CBO9781107415324.004

- BULLOCK, E. L., NOLTE, C., SEGOVIA, A. R. Y WOODCOCK, C. E. Ongoing forest disturbance in Guatemala's protected areas. *Remote Sensing in Ecology and Conservation*, 2020a, 6(2), 141-152. doi:10.1002/rse2.130
- BULLOCK, E. L., WOODCOCK, C. E. Y HOLDEN, C. E. Improved change monitoring using an ensemble of time series algorithms. *Remote Sensing of Environment*, 2020b, 238. doi:10.1016/j.rse.2019.04.018
- BULLOCK, E. L., WOODCOCK, C. E. Y OLOFSSON, P. Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. *Remote Sensing of Environment*, 2020/03/01/ 2020c, 238, 110968. doi:<https://doi.org/10.1016/j.rse.2018.11.011>
- BULLOCK, E. L., WOODCOCK, C. E., SOUZA, C. Y OLOFSSON, P. Satellite-based estimates reveal widespread forest degradation in the Amazon. *Global Change Biology*, 2020d, 26(5), 2956-2969. doi:10.1111/gcb.15029
- BULLOCK, E. L., WOODCOCK, C. E., SOUZA JR, C. Y OLOFSSON, P. Satellite-based estimates reveal widespread forest degradation in the Amazon. *Global Change Biology*, 2020/05/01 2020e, 26(5), 2956-2969. doi:<https://doi.org/10.1111/gcb.15029>
- CABALLERO, J., MESSINGER, M., ROMÁN-DAÑOBEYTIA, F., ASCORRA, C., FERNANDEZ, L. E. Y SILMAN, M. Deforestation and forest degradation due to gold mining in the Peruvian Amazon: A 34-year perspective. *Remote Sensing*, 2018, 10(12), 1903. doi:<https://doi.org/10.3390/rs10121903>
- CAMPBELL, M. J., DENNISON, P. E., KERR, K. L., BREWER, S. C. Y ANDEREGG, W. R. L. Scaled biomass estimation in woodland ecosystems: Testing the individual and combined capacities of satellite multispectral and lidar data. *Remote Sensing of Environment*, 2021/09/01/ 2021, 262, 112511. doi:<https://doi.org/10.1016/j.rse.2021.112511>

- CAMPOS, M. S., ANJOS, L. J. S., SOUZA, E. B. D., BEZERRA, F. G. S., LIMA, A. M. M. D., GALBRAITH, D. R. Y ADAMI, M. Prioritizing Amazon Forest conservation: Assessing potential biomass under climate change. *Global Ecology and Conservation*, 2024/10/01/ 2024, 54, e03106. doi:<https://doi.org/10.1016/j.gecco.2024.e03106>
- CERDA, J. Y VILLARROEL, L. Evaluación de la concordancia inter-observador en investigación pediátrica: Coeficiente de Kappa. *Revista chilena de pediatría*, 2008, 79(1), 54-58. doi:<http://dx.doi.org/10.4067/S0370-41062008000100008>
- 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>
- CHEN, S., WOODCOCK, C. E., BULLOCK, E. L., ARÉVALO, P., TORCHINAVA, P., PENG, S. Y OLOFSSON, P. Monitoring temperate forest degradation on Google Earth Engine using Landsat time series analysis. *Remote Sensing of Environment*, 2021/11/01/ 2021, 265, 112648. doi:<https://doi.org/10.1016/j.rse.2021.112648>
- CHUVIECO, E. Teledetección espacial: la observación de la Tierra desde el espacio 2002.
- CHUVIECO, E. *Fundamentals of satellite remote sensing: An environmental approach*. Edtion ed.: CRC press, 2016. ISBN 1498728073.
- CHUVIECO, E. Y HANTSON, S. Procesamiento estándar de imágenes Landsat. Documento técnico de algoritmos a aplicar. Version1. Plan Nacional de Teledetección. Instituto Geográfico Nacional. En línea; http://www.ign.es/PNT/pdf/especificacionestecnicas-pnt-medar-landsat_v2-2010.pdf, 2010.

- COHEN, J. A Coefficient of Agreement for Nominal Scales. *Educational and Psychological Measurement*, 1960/04/01 1960, 20(1), 37-46. doi:<https://doi.org/10.1177/001316446002000104>
- COHEN, J., MANION, L. Y MORRISON, J. Designing a qualitative study. In.: Newsbury Park: CA Sage, 2003.
- CSILLIK, O. Y ASNER, G. P. Aboveground carbon emissions from gold mining in the Peruvian Amazon. *Environmental Research Letters*, 2020/01/14 2020, 15(1), 014006. doi:10.1088/1748-9326/ab639c
- CSILLIK, O., KUMAR, P., MASCARO, J., O'SHEA, T. Y ASNER, G. P. Monitoring tropical forest carbon stocks and emissions using Planet satellite data. *Scientific Reports*, 2019/11/28 2019, 9(1), 17831. doi:10.1038/s41598-019-54386-6
- DOUROJEANNI, M. Impactos socioambientales probables de la carretera transoceánica (Río Branco-Puerto Maldonado-Ilo) y la capacidad de respuesta del Perú. *Boletín CF+ S*, 2014, (19).
- 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., SCHOLES, R., SILVA, C. A., SIMARD, M., SKIDMORE, A., STERENCZAK, K., TANASE, M., TORRESAN, C., VALBUENA, R., VERBEECK, H., VRŠKA, 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>

ECKERT, S., SCHMID, L., MESSERLI, P. Y ZAEHRINGER, J. G. Spatiotemporal assessment of deforestation and forest degradation indicates spillover effects from mining activities and related biodiversity offsets in Madagascar. Remote Sensing Applications: Society and Environment, 2024/11/01/ 2024, 36, 101269. doi:<https://doi.org/10.1016/j.rsase.2024.101269>

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>

ELIJAH, R. Y JENSEN, J. R. Remote sensing of mangrove wetlands: relating canopy spectra to site-specific data 1996. doi:https://www.asprs.org/wp-content/uploads/pers/1996journal/aug/1996_aug_939-948.pdf

FAO FRA 2015: Terms and Definitions 2012. doi:<https://www.fao.org/home/es>

FAO Evaluación de los recursos forestales mundiales 2020 – Principales resultados 2020, 16. doi:<https://doi.org/10.4060/ca8753es>

FERRAZ, A., SAATCHI, S., XU, L., HAGEN, S., CHAVE, J., YU, Y., MEYER, V., GARCIA, M., SILVA, C., ROSWINTIART, O., SAMBOKO, A., SIST, P., WALKER, S., PEARSON, T. R. H., WIJAYA, A., SULLIVAN, F. B., RUTISHAUSER, E., HOEKMAN, D. Y GANGULY, S. Carbon storage potential in degraded forests of Kalimantan, Indonesia. Environmental Research Letters, 2018/08/21 2018, 13(9), 095001. doi:10.1088/1748-9326/aad782

GARATE-QUISPE, J., HERRERA-MACHACA, M., PAREJA AUQUIPATA, V., ALARCÓN AGUIRRE, G., BAEZ QUISPE, S. Y CARPIO-VARGAS, E. E. Resilience of Aboveground Biomass of Secondary Forests Following the Abandonment of Gold Mining Activity in the Southeastern Peruvian Amazon.

Diversity [Type of Work]. 2024, vol. 16, no. 4. ISSN 1424-2818. doi:10.3390/d16040233.

GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D. Y MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 2017, 202, 18-27. doi:<https://doi.org/10.1016/j.rse.2017.06.031>

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>

HANCOCK, S., HOFTON, M., SUN, X., TANG, H., KELLNER, J. R., ARMSTON, J., DUNCANSON, L. I. Y DUBAYAH, R. The GEDI simulator: A large-footprint waveform lidar simulator for calibration and validation of spaceborne missions. *Earth Space Sci.*, 2019, 6, 294-310. doi:10.1029/2018EA000506

HANSEN, M. C., POTAPOV, P. V., MOORE, R., HANCHER, M., TURUBANOVA, S. A., TYUKAVINA, A., THAU, D., STEHMAN, S. V., GOETZ, S. J., LOVELAND, T. R., KOMMAREDDY, A., EGOROV, A., CHINI, L., JUSTICE, C. O. Y TOWNSHEND, J. R. G. High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*, 2013/11/15 2013, 342(6160), 850-853. doi:10.1126/science.1244693

HETHCOAT, M. G., CARREIRAS, J. M. B., EDWARDS, D. P., BRYANT, R. G., PERES, C. A. Y QUEGAN, S. Mapping pervasive selective logging in the south-west Brazilian Amazon 2000–2019. *Environmental Research Letters*, 2020/08/25 2020, 15(9), 094057. doi:10.1088/1748-9326/aba3a4

HOLDRIDGE, L. R. Life zone ecology. *Life zone ecology.*, 1967, (rev. ed.)).

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

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>

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

KOLEY, S. Y CHOCKALINGAM, J. Sentinel 1 and Sentinel 2 for cropland mapping with special emphasis on the usability of textural and vegetation indices. Advances in Space Research, 2022/02/15/ 2022, 69(4), 1768-1785. doi:<https://doi.org/10.1016/j.asr.2021.10.020>

KUHN, M. Y JOHNSON, K. *Applied predictive modeling*. Edtion ed.: Springer, 2013.

LANDIS, J. R. Y KOCH, G. G. The measurement of observer agreement for categorical data. biometrics, 1977, 159-174. doi:<https://doi.org/10.2307/2529310>

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
- LIANG, M., DUNCANSON, L., SILVA, J. A. Y SEDANO, F. Quantifying aboveground biomass dynamics from charcoal degradation in Mozambique using GEDI Lidar and Landsat. *Remote Sensing of Environment*, 2023/01/01/ 2023, 284, 113367. doi:<https://doi.org/10.1016/j.rse.2022.113367>
- LONGO, M., KELLER, M., DOS-SANTOS, M. N., LEITOLD, V., PINAGÉ, E. R., BACCINI, A., SAATCHI, S., NOGUEIRA, E. M., BATISTELLA, M. Y MORTON, D. C. Aboveground biomass variability across intact and degraded forests in the Brazilian Amazon. *Global Biogeochemical Cycles*, 2016/11/01 2016, 30(11), 1639-1660. doi:<https://doi.org/10.1002/2016GB005465>
- 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.
- 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>

MAXWELL, S. L., EVANS, T., WATSON, J. E. M., MOREL, A., GRANTHAM, H., DUNCAN, A., HARRIS, N., POTAPOV, P., RUNTING, R. K., VENTER, O., WANG, S. Y MALHI, Y. Degradation and forgone removals increase the carbon impact of intact forest loss by 626%. *Science Advances*, 2019, 5(10), eaax2546. doi:10.1126/sciadv.aax2546

MENDOZA, R., ALARCÓN AGUIRRE, G., PERZ, S. Y CORREA NUÑEZ, G. Changes in Landscape of Pampa Juliaca Grassland in Bahuaja-Sonene National Park by Fire Men-Made (1990-2010) *Modern Environmental Science and Engineering*, Mayo, 2017 2017, 3, 332-348 doi: 10.15341/mese(2333-2581)/05.03.2017/006

MORAN, E. F. Y BRONDIZIO, E. Land-use change after deforestation in Amazonia. *People and pixels: Linking remote sensing and social science*, 1998, 94-120.

MPAKAIRI, K. S., NDAIMANI, H. Y KAVHU, B. Exploring the utility of Sentinel-2 MSI derived spectral indices in mapping burned areas in different land-cover types. *Scientific African*, 2020/11/01/ 2020, 10, e00565.
doi:<https://doi.org/10.1016/j.sciaf.2020.e00565>

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.

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

OCHOA, C. Y PÁEZ, O. Inferencia estadística: probabilidad, variables aleatorias y distribuciones de probabilidad. *Evid Pediatr*, 2019, 15, 27.

- OLIVARES, B. O. Y LÓPEZ-BELTRÁN, M. A. Índice de Vegetación de Diferencia Normalizada aplicado al territorio indígena agrícola de Kashaama, Venezuela. Cuadernos de Investigación UNED, 2019, 11, 112-121. doi:<http://dx.doi.org/10.22458/urj.v11i2.2299>
- OLIVEIRA, A. H., MATRICARDI, E. A., DE ARAGÃO, L. E., FELIX, I. M., CHAVES, J. H., MAGLIANO, M. M., OLIVEIRA-JUNIOR, J. M., VIEIRA, T. A., SANTOS, L. E., REIS, L. P., PEREIRA, D. O., DIAS, C. T., GAMA, J. R. Y MARTORANO, L. G. Assessing Forest Degradation Through Remote Sensing in the Brazilian Amazon: Implications and Perspectives for Sustainable Forest Management. *Remote Sensing* [Type of Work]. 2024, vol. 16, no. 23. ISSN 2072-4292. doi:10.3390/rs16234557.
- OMETTO, J. P., AGUIAR, A. P., ASSIS, T., SOLER, L., VALLE, P., TEJADA, G., LAPOLA, D. M. Y MEIR, P. Amazon forest biomass density maps: tackling the uncertainty in carbon emission estimates. In J.P. OMETTO, R. BUN, M. JONAS Y Z. NAHORSKI eds. *Uncertainties in Greenhouse Gas Inventories: Expanding Our Perspective*. Cham: Springer International Publishing, 2015, p. 95-110.
- PASCUAL, A., GUERRA-HERNÁNDEZ, J., ARMSTON, J., MINOR, D. M., DUNCANSON, L. I., MAY, P. B., KELLNER, J. R. Y DUBAYAH, R. Assessing the performance of NASA's GEDI L4A footprint aboveground biomass density models using National Forest Inventory and airborne laser scanning data in Mediterranean forest ecosystems. *Forest ecology and management*, 2023/06/15/ 2023, 538, 120975. doi:<https://doi.org/10.1016/j.foreco.2023.120975>
- PAULINO, R. S., MARTINS, V. S., NOVO, E. M. L. M., BARBOSA, C. C. F., MACIEL, D. A., WANDERLEY, R. L. D. N., PORTELA, C. I., CABALLERO, C. B. Y LIMA, T. M. A. Generation of robust 10-m Sentinel-2/3 synthetic aquatic reflectance bands over inland waters. *Remote Sensing of Environment*, 2025/03/01/ 2025, 318, 114593. doi:<https://doi.org/10.1016/j.rse.2024.114593>

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. G., MENDOZA, E. R. H. Y DOS SANTOS PIMENTEL, A. Seeing the broader picture: Stakeholder contributions to understanding infrastructure impacts of the Interoceanic Highway in the southwestern Amazon. *World Development*, 2022/11/01/ 2022, 159, 106061. doi:<https://doi.org/10.1016/j.worlddev.2022.106061>

PLANET-TEAM. Planet Application Program Interface: In Space for Life on Earth. *Habitat International* [Type of Work]. 2025. Disponible en Internet:<<https://api.planet.com>>

PLOTON, P., BARBIER, N., COUTERON, P., ANTIN, C. M., AYYAPPAN, N., BALACHANDRAN, N., BARATHAN, N., BASTIN, J. F., CHUYONG, G., DAUBY, G., DROISSART, V., GASTELLU-ETCHEGORRY, J. P., KAMDEM, N. G., KENFACK, D., LIBALAH, M., MOFACK, G., MOMO, S. T., PARGAL, S., PETRONELLI, P., PROISY, C., RÉJOU-MÉCHAIN, M., SONKÉ, B., TEXIER, N., THOMAS, D., VERLEY, P., ZEBAZE DONGMO, D., BERGER, U. Y PÉLISSIER, R. Toward a general tropical forest biomass prediction model from very high resolution optical satellite images. *Remote Sensing of Environment*, 2017/10/01/ 2017, 200, 140-153. doi:<https://doi.org/10.1016/j.rse.2017.08.001>

QIN, Y., XIAO, X., WIGNERON, J.-P., CIAIS, P., BRANDT, M., FAN, L., LI, X., CROWELL, S., WU, X., DOUGHTY, R., ZHANG, Y., LIU, F., SITCH, S. Y MOORE, B. Carbon loss from forest degradation exceeds that from

deforestation in the Brazilian Amazon. *Nature Climate Change*, 2021/05/01 2021, 11(5), 442-448. doi:10.1038/s41558-021-01026-5

RANGEL, E., KELLER, M., PECK, C. P., LONGO, M., DUFFY, P. Y CSILLIK, O. Effects of forest degradation classification on the uncertainty of aboveground carbon estimates in the Amazon. *Carbon Balance and Management*, 2023/02/14 2023, 18(1), 2. doi:10.1186/s13021-023-00221-5

RAPPAPORT, D. I., MORTON, D. C., LONGO, M., KELLER, M., DUBAYAH, R. Y DOS-SANTOS, M. N. Quantifying long-term changes in carbon stocks and forest structure from Amazon forest degradation. *Environmental Research Letters*, 2018/06/07 2018, 13(6), 065013. doi:10.1088/1748-9326/aac331

SALIH, A. Spectral Mixture Analysis (SMA) Model for Extracting Urban Fractions from Landsat and Sentinel-2A Images in the Al-Ahsa Oasis, Eastern Region of Saudi Arabia. *Land* [Type of Work]. 2023, vol. 12, no. 10. ISSN 2073-445X. doi:10.3390/land12101842.

SCHULTZ, M., CLEVERS, J. G. P. W., CARTER, S., VERBESSELT, J., AVITABILE, V., QUANG, H. V. Y HEROLD, M. Performance of vegetation indices from Landsat time series in deforestation monitoring. *International Journal of Applied Earth Observation and Geoinformation*, 2016/10/01/ 2016, 52, 318-327. doi:<https://doi.org/10.1016/j.jag.2016.06.020>

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-JUNIOR, C. H. L., ARAGÃO, L. E. O. C., ANDERSON, L. O., FONSECA, M. G., SHIMABUKURO, Y. E., VANCUTSEM, C., ACHARD, F., BEUCHLE, R.,

- NUMATA, I., SILVA, C. A., MAEDA, E. E., LONGO, M. Y SAATCHI, S. S. Persistent collapse of biomass in Amazonian forest edges following deforestation leads to unaccounted carbon losses. *Science Advances*, 2018, 6(40), eaaz8360. doi:10.1126/sciadv.aaz8360
- SOUZA, C., FIRESTONE, L., SILVA, L. M. Y ROBERTS, D. Mapping forest degradation in the Eastern Amazon from SPOT 4 through spectral mixture models. *Remote Sens Environ*, 2003// 2003, 87. doi:10.1016/j.rse.2002.08.002
- SOUZA, C. M. Y ROBERTS, D. Mapping forest degradation in the Amazon region with Ikonos images. *International journal of remote sensing*, 2005/02/01 2005, 26(3), 425-429. doi:10.1080/0143116031000101620
- SOUZA, C. M., ROBERTS, D. A. Y COCHRANE, M. A. Combining spectral and spatial information to map canopy damage from selective logging and forest fires. *Remote Sensing of Environment*, 2005/10/15/ 2005a, 98(2), 329-343. doi:<https://doi.org/10.1016/j.rse.2005.07.013>
- SOUZA, C. M., ROBERTS, D. A. Y MONTEIRO, A. Multitemporal analysis of degraded forests in the southern Brazilian Amazon. *Earth Interact*, 2005// 2005b, 9. doi:10.1175/EI132.1
- SOUZA, C. M., SIQUEIRA, J. V., SALES, M. H., FONSECA, A. V., RIBEIRO, J. G. Y NUMATA, I. Ten-year Landsat classification of deforestation and forest degradation in the Brazilian Amazon. *Remote Sens*, 2013// 2013, 5. doi:10.3390/rs5115493
- 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.
- WHITMORE, T. C. Y BURNHAM, C. P. *Tropical rain forests of the Far East*. Edition ed.: Clarendon Press, 1975. ISBN 0198541279.

- YAGHOBI, S., HEIDARIZADI, Z. Y MIRZAPOUR, H. Comparing NDVI and RVI for forest density estimation and their relationships with rainfall (Case study: Malekshahi, Ilam Province). *Environmental Resources Research*, 2019, 7(2), 117-128. doi:10.22069/IJERR.2019.4819
- 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
- ZHANG, G., WANG, J., XUE, Y., ZHANG, C., XU, B., CHENG, Y. Y REN, Y. Comparison of sampling effort allocation strategies in a stratified random survey with multiple objectives. *Aquaculture and Fisheries*, 2020/05/01/ 2020, 5(3), 113-121. doi:<https://doi.org/10.1016/j.aaf.2020.02.002>
- ZHU, Z. Y WOODCOCK, C. E. Continuous change detection and classification of land cover using all available Landsat data. *Remote Sensing of Environment*, 2014/03/25/ 2014, 144, 152-171. doi:<https://doi.org/10.1016/j.rse.2014.01.011>
- ZUHLKE, M., FOMFERRA, N., BROCKMANN, C., PETERS, M., VECI, L., MALIK, J. Y REGNER, P. SNAP (sentinel application platform) and the ESA sentinel 3 toolbox. *ESASP*, 2015, 734, 21.

ANEXOS

Anexo 1. Matriz de consistencia.

Título: Análisis de la deforestación y degradación forestal sobre la incertidumbre de las estimaciones de carbono forestal en la Amazonia de Madre de Dios.

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPOTESIS GENERAL	VARIABLES/INDICADORES	METODOLOGÍA
¿Cuánto y como es la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis de mezcla espectral (SMA) sobre la incertidumbre de las estimaciones de carbono forestal aéreo mediante la combinación de datos GEDI L4A con Sentinel-2 (S2) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?	Analizar la clasificación de la deforestación y degradación forestal utilizando el enfoque de análisis de mezcla espectral (SMA) sobre la incertidumbre de las estimaciones de carbono forestal aéreo mediante la combinación de datos GEDI L4A con Sentinel-2 (S2) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.	El modelo de análisis de mezcla espectral para el índice de fracción de diferencia normalizada no permite estimar con precisión la incertidumbre del carbono forestal aéreo en áreas de degradación forestal en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.	<p>Variable Dependiente: Incertidumbre de carbono forestal aéreo por deforestación y degradación forestal en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.</p> <p>Indicadores: CF aéreo (Mg C/ha y Mg) por magnitud de deforestación y degradación forestal.</p> <p>Variable Independiente: Reflectancia espectral de la deforestación y degradación forestal con el SMA para NDFI y CF mediante la combinación de datos GEDI nivel L4A con Sentinel-2 (S2), modelo de elevación digital (DEM) y pendiente.</p> <p>Indicadores:</p>	<p>Diseño: No experimental Transaccional (transversal). Tipo: descriptiva, correlacional y predictivo Método: 1. Descarga de imágenes S2, GEDI L4A y DEM. 2. Preprocesamiento con GEE. 3. Estimación de SMA y NDFI para 2025. 4. Cuantificación de la deforestación y degradación forestal. 5. Validación de los resultados con trabajos de campo e imágenes de alta resolución. 6. Cuantificación AGB aéreo. 7. Cuantificación de CF aéreo por incertidumbre de degradación forestal</p> <p>Población y muestra: se empleará la distribución binomial de probabilidad.</p> $n = \frac{Z^2 p(qN)}{(N - 1)E^2 + Z^2 pq}$ <p>“Z: Es el valor de la curva normal estandarizada para un nivel determinado de probabilidad, 1,96 (95%)”. “p: indica el porcentaje de aciertos estimado, 0,50 (50%)”.</p>
PROBLEMAS ESPECIFICOS	OBJETIVOS ESPECÍFICOS			
<p>P.E.1 ¿Cómo es el índice de fracción de diferencia normalizada (NDFI) utilizando el método de análisis de mezcla espectral (SMA) que considera distintas coberturas como vegetación verde (GV), vegetación no fotosintética (NPV), suelo, sombra y nube en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?</p> <p>P.E.2 ¿Cuánto es la magnitud de la deforestación y degradación forestal a través del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste</p>	<p>O.E.1 Calcular el índice de fracción de diferencia normalizada (NDFI) utilizando el método de análisis de mezcla espectral (SMA) que considera distintas coberturas como vegetación verde (GV), vegetación no fotosintética (NPV), suelo, sombra y nube en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.</p> <p>O.E.2 Estimar la magnitud de la deforestación y degradación forestal a través del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la</p>			

<p>de la Amazonia de Madre de Dios durante el año 2025?</p> <p>P.E.3 ¿Cuál es la precisión de la clasificación de la deforestación y degradación forestal producto del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?</p> <p>P.E.4 ¿Cuánto es la biomasa forestal aéreo con el modelo Random Forest (RF) mediante la combinación de datos GEDI nivel L4A con Sentinel-2 (S2), modelo de elevación digital (DEM) y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?</p> <p>P.E.5 ¿Cuál es la cantidad de carbono forestal aéreo por tipo de cobertura en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?</p> <p>P.E.6 ¿Cómo es el comportamiento de la cuantificación del carbono forestal aéreo por la incertidumbre de la clasificación de la degradación forestal en la cartografía de cobertura del suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025?</p>	<p>Amazonia de Madre de Dios durante el año 2025.</p> <p>O.E.3 Medir la precisión de la clasificación de la deforestación y degradación forestal producto del índice de fracción de diferencia normalizada (NDFI) en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.</p> <p>O.E.4 Cuantificar la biomasa forestal aéreo con el modelo Random Forest (RF) mediante la combinación de datos GEDI nivel L4A con Sentinel-2 (S2), modelo de elevación digital (DEM) y pendiente en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.</p> <p>O.E.5 Determinar el carbono forestal aéreo por tipo de cobertura de suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.</p> <p>O.E.6 Analizar la cuantificación del carbono forestal aéreo por la incertidumbre de la clasificación de la degradación forestal en la cartografía de cobertura del suelo en los bosques del sureste de la Amazonia de Madre de Dios durante el año 2025.</p>		<ol style="list-style-type: none"> 1. SMA. NDFI, deforestación y degradación forestal (ha). 2. Matriz de confusión e índice de kappa (k). 3. AGB aéreo (Mg/h y Mg), CF aéreo (Mg/ha y Mg), CF aéreo en áreas de degradación forestal (ha). 	<p>“q: Indica el porcentaje de errores ($q = 1 - p$), 0,50 (50%)”.</p> <p>“N: Tamaño de la población”.</p> <p>“E: El error permitido, 0,05 (5%)”.</p>
---	---	--	---	--

Anexo 2. Puntos de muestreo por categoría en el área de estudio.

N.º	Código	Categoría
1	3	Bosque
2	3	Bosque
3	3	Bosque
4	3	Bosque
5	3	Bosque
6	3	Bosque
7	3	Bosque
8	3	Bosque
9	3	Bosque
10	3	Bosque
11	3	Bosque
12	3	Bosque
13	3	Bosque
14	3	Bosque
15	3	Bosque
16	3	Bosque
17	3	Bosque
18	3	Bosque
19	3	Bosque
20	3	Bosque
21	3	Bosque
22	3	Bosque
23	3	Bosque
24	3	Bosque
25	3	Bosque
26	3	Bosque
27	3	Bosque
28	3	Bosque
29	3	Bosque
30	3	Bosque
31	3	Bosque
32	3	Bosque
33	3	Bosque
34	3	Bosque
35	3	Bosque
36	3	Bosque
37	3	Bosque
38	3	Bosque
39	3	Bosque
40	3	Bosque
41	3	Bosque
42	3	Bosque

43	3	Bosque
44	3	Bosque
45	3	Bosque
46	3	Bosque
47	3	Bosque
48	3	Bosque
49	3	Bosque
50	3	Bosque
51	3	Bosque
52	3	Bosque
53	3	Bosque
54	3	Bosque
55	3	Bosque
56	3	Bosque
57	3	Bosque
58	3	Bosque
59	3	Bosque
60	3	Bosque
61	3	Bosque
62	3	Bosque
63	3	Bosque
64	3	Bosque
65	3	Bosque
66	3	Bosque
67	3	Bosque
68	3	Bosque
69	3	Bosque
70	3	Bosque
71	3	Bosque
72	3	Bosque
73	3	Bosque
74	3	Bosque
75	3	Bosque
76	3	Bosque
77	3	Bosque
78	3	Bosque
79	3	Bosque
80	3	Bosque
81	3	Bosque
82	3	Bosque
83	3	Bosque
84	3	Bosque
85	3	Bosque
86	3	Bosque
87	3	Bosque

88	3	Bosque
89	3	Bosque
90	3	Bosque
91	3	Bosque
92	3	Bosque
93	3	Bosque
94	3	Bosque
95	3	Bosque
96	3	Bosque
97	3	Bosque
98	3	Bosque
99	3	Bosque
100	3	Bosque
101	3	Bosque
102	3	Bosque
103	3	Bosque
104	3	Bosque
105	3	Bosque
106	3	Bosque
107	3	Bosque
108	3	Bosque
109	3	Bosque
110	3	Bosque
111	3	Bosque
112	3	Bosque
113	3	Bosque
114	3	Bosque
115	3	Bosque
116	3	Bosque
117	3	Bosque
118	3	Bosque
119	3	Bosque
120	3	Bosque
121	3	Bosque
122	3	Bosque
123	3	Bosque
124	3	Bosque
125	3	Bosque
126	3	Bosque
127	3	Bosque
128	3	Bosque
129	2	Degradación forestal
130	2	Degradación forestal
131	2	Degradación forestal
132	2	Degradación forestal

133	2	Degradación forestal
134	2	Degradación forestal
135	2	Degradación forestal
136	2	Degradación forestal
137	2	Degradación forestal
138	2	Degradación forestal
139	2	Degradación forestal
140	2	Degradación forestal
141	2	Degradación forestal
142	2	Degradación forestal
143	2	Degradación forestal
144	2	Degradación forestal
145	2	Degradación forestal
146	2	Degradación forestal
147	2	Degradación forestal
148	2	Degradación forestal
149	2	Degradación forestal
150	2	Degradación forestal
151	2	Degradación forestal
152	2	Degradación forestal
153	2	Degradación forestal
154	2	Degradación forestal
155	2	Degradación forestal
156	2	Degradación forestal
157	2	Degradación forestal
158	2	Degradación forestal
159	2	Degradación forestal
160	2	Degradación forestal
161	2	Degradación forestal
162	2	Degradación forestal
163	2	Degradación forestal
164	2	Degradación forestal
165	2	Degradación forestal
166	2	Degradación forestal
167	2	Degradación forestal
168	2	Degradación forestal
169	2	Degradación forestal
170	2	Degradación forestal
171	2	Degradación forestal
172	2	Degradación forestal
173	2	Degradación forestal
174	2	Degradación forestal
175	2	Degradación forestal
176	2	Degradación forestal
177	2	Degradación forestal

178	2	Degradación forestal
179	2	Degradación forestal
180	2	Degradación forestal
181	2	Degradación forestal
182	2	Degradación forestal
183	2	Degradación forestal
184	2	Degradación forestal
185	2	Degradación forestal
186	2	Degradación forestal
187	2	Degradación forestal
188	2	Degradación forestal
189	2	Degradación forestal
190	2	Degradación forestal
191	2	Degradación forestal
192	2	Degradación forestal
193	2	Degradación forestal
194	2	Degradación forestal
195	2	Degradación forestal
196	2	Degradación forestal
197	2	Degradación forestal
198	2	Degradación forestal
199	2	Degradación forestal
200	2	Degradación forestal
201	2	Degradación forestal
202	2	Degradación forestal
203	2	Degradación forestal
204	2	Degradación forestal
205	2	Degradación forestal
206	2	Degradación forestal
207	2	Degradación forestal
208	2	Degradación forestal
209	2	Degradación forestal
210	2	Degradación forestal
211	2	Degradación forestal
212	2	Degradación forestal
213	2	Degradación forestal
214	2	Degradación forestal
215	2	Degradación forestal
216	2	Degradación forestal
217	2	Degradación forestal
218	2	Degradación forestal
219	2	Degradación forestal
220	2	Degradación forestal
221	2	Degradación forestal
222	2	Degradación forestal

223	2	Degradación forestal
224	2	Degradación forestal
225	2	Degradación forestal
226	2	Degradación forestal
227	2	Degradación forestal
228	2	Degradación forestal
229	2	Degradación forestal
230	2	Degradación forestal
231	2	Degradación forestal
232	2	Degradación forestal
233	2	Degradación forestal
234	2	Degradación forestal
235	2	Degradación forestal
236	2	Degradación forestal
237	2	Degradación forestal
238	2	Degradación forestal
239	2	Degradación forestal
240	2	Degradación forestal
241	2	Degradación forestal
242	2	Degradación forestal
243	2	Degradación forestal
244	2	Degradación forestal
245	2	Degradación forestal
246	2	Degradación forestal
247	2	Degradación forestal
248	2	Degradación forestal
249	2	Degradación forestal
250	2	Degradación forestal
251	2	Degradación forestal
252	2	Degradación forestal
253	2	Degradación forestal
254	2	Degradación forestal
255	2	Degradación forestal
256	2	Degradación forestal
257	1	Deforestación
258	1	Deforestación
259	1	Deforestación
260	1	Deforestación
261	1	Deforestación
262	1	Deforestación
263	1	Deforestación
264	1	Deforestación
265	1	Deforestación
266	1	Deforestación
267	1	Deforestación

268	1	Deforestación
269	1	Deforestación
270	1	Deforestación
271	1	Deforestación
272	1	Deforestación
273	1	Deforestación
274	1	Deforestación
275	1	Deforestación
276	1	Deforestación
277	1	Deforestación
278	1	Deforestación
279	1	Deforestación
280	1	Deforestación
281	1	Deforestación
282	1	Deforestación
283	1	Deforestación
284	1	Deforestación
285	1	Deforestación
286	1	Deforestación
287	1	Deforestación
288	1	Deforestación
289	1	Deforestación
290	1	Deforestación
291	1	Deforestación
292	1	Deforestación
293	1	Deforestación
294	1	Deforestación
295	1	Deforestación
296	1	Deforestación
297	1	Deforestación
298	1	Deforestación
299	1	Deforestación
300	1	Deforestación
301	1	Deforestación
302	1	Deforestación
303	1	Deforestación
304	1	Deforestación
305	1	Deforestación
306	1	Deforestación
307	1	Deforestación
308	1	Deforestación
309	1	Deforestación
310	1	Deforestación
311	1	Deforestación
312	1	Deforestación

313	1	Deforestación
314	1	Deforestación
315	1	Deforestación
316	1	Deforestación
317	1	Deforestación
318	1	Deforestación
319	1	Deforestación
320	1	Deforestación
321	1	Deforestación
322	1	Deforestación
323	1	Deforestación
324	1	Deforestación
325	1	Deforestación
326	1	Deforestación
327	1	Deforestación
328	1	Deforestación
329	1	Deforestación
330	1	Deforestación
331	1	Deforestación
332	1	Deforestación
333	1	Deforestación
334	1	Deforestación
335	1	Deforestación
336	1	Deforestación
337	1	Deforestación
338	1	Deforestación
339	1	Deforestación
340	1	Deforestación
341	1	Deforestación
342	1	Deforestación
343	1	Deforestación
344	1	Deforestación
345	1	Deforestación
346	1	Deforestación
347	1	Deforestación
348	1	Deforestación
349	1	Deforestación
350	1	Deforestación
351	1	Deforestación
352	1	Deforestación
353	1	Deforestación
354	1	Deforestación
355	1	Deforestación
356	1	Deforestación
357	1	Deforestación

358	1	Deforestación
359	1	Deforestación
360	1	Deforestación
361	1	Deforestación
362	1	Deforestación
363	1	Deforestación
364	1	Deforestación
365	1	Deforestación
366	1	Deforestación
367	1	Deforestación
368	1	Deforestación
369	1	Deforestación
370	1	Deforestación
371	1	Deforestación
372	1	Deforestación
373	1	Deforestación
374	1	Deforestación
375	1	Deforestación
376	1	Deforestación
377	1	Deforestación
378	1	Deforestación
379	1	Deforestación
380	1	Deforestación
381	1	Deforestación
382	1	Deforestación
383	1	Deforestación
384	1	Deforestación

Anexo 3. Panel fotográfico.



Foto 1. Degradación forestal y deforestación.



Foto 2. Mosaico de paisajes.



Foto 3. Deforestación por quema.



Foto 4. Áreas deforestadas y degradadas.



Foto 5. Perturbación por quema.



Foto 6. Deforestación por ganadería.



Foto 7. Deforestación por infraestructura.



Foto 8. Deforestación por minería.