

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



TESIS

“Evaluación de cambios espacio-temporales de la deforestación por actividades antrópicas en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024”

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

AUTOR:

Bach. RACUA VILLAR, Marvin Alexis

ASESOR:

Dr. ALARCÓN AGUIRRE, Gabriel

Puerto Maldonado, marzo de 2026

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



TESIS

“Evaluación de cambios espacio-temporales de la deforestación por actividades antrópicas en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024”

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

AUTOR:

Bach. RACUA VILLAR, Marvin Alexis

ASESOR:

Dr. ALARCÓN AGUIRRE, Gabriel

Puerto Maldonado, marzo de 2026

RST-RI_Evaluación de cambios espacio-temporales de la deforestación por actividades antrópicas en territorios indígenas del ECA AmaraKaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018

INFORME DE ORIGINALIDAD

17%

INDICE DE SIMILITUD

19%

FUENTES DE INTERNET

1%

PUBLICACIONES

2%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.unamad.edu.pe Fuente de Internet	13%
2	repositorio.uta.edu.ec Fuente de Internet	1%
3	scholar.archive.org Fuente de Internet	1%
4	server.servindi.org Fuente de Internet	1%
5	repositorio.upn.edu.pe Fuente de Internet	1%
6	repositorio.unas.edu.pe Fuente de Internet	1%
7	hdl.handle.net Fuente de Internet	1%
8	peru.mapbiomas.org Fuente de Internet	1%

Dedicatoria

Dedico esta tesis con profundo amor y gratitud a mi querido abuelo, Guillermo Villar Cabaña, quien en paz descansa. Su constante aliento y sabiduría siempre fueron una luz en mi camino. A mi abuela, María Paredes Panduro, por su amor incondicional; a mi papá, Carmelo Racua Guevara, y a mi mamá, Lita Villar Paredes, por su apoyo y sacrificio; a mi hermana menor, Ninoska Racua Villar, por ser mi compañera en cada paso; a mi esposa, Elsa Granada Toñón, por su amor y paciencia; y a mi hija, Alexia Racua Granada, por recordarme la importancia de soñar en grande. Recuerdo con cariño las palabras de mi abuelo, quien siempre me instó a culminar mis estudios y obtener mi título profesional. Su legado vive en mí y me impulsa a seguir adelante.

Marvin Alexis Racua Villar

Agradecimientos

Quiero expresar mi más sincero agradecimiento a mi casa de estudios, la Universidad Nacional de Madre de Dios, por ser el suelo donde se cultivó mi compromiso con la Amazonía. A todos mis docentes, por su dedicación y enseñanzas que han sido fundamentales en mi formación. A mis compañeros, por compartir este viaje académico lleno de retos y aprendizajes. Un agradecimiento especial a mi asesor, Dr. Gabriel Alarcón Aguirre, por su guía y apoyo académico. Asimismo, agradezco a las diez comunidades nativas socias de la Reserva Comunal Amarakeri, que me abrieron las puertas de su territorio y me dieron la oportunidad de recolectar información valiosa para este estudio.

Marvin Alexis Racua Villar

Resumen

El estudio tuvo como objetivo evaluar los cambios espacio-temporales de la deforestación por actividades antrópicas en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024. Se utilizaron imágenes satelitales de alta resolución (resolución espacial de 4 m) de PlanetScope debido a los beneficios en ayudar a diferenciar varias clases de cobertura terrestre con una resolución espacial más alta mediante técnicas de redes neurales (Neural Net) con ENVI. Los resultados mostraron una superficie de formación boscosa y áreas mayormente naturales para el periodo inicial (2018) de 178 716,80 ha a 176 137,13 ha para 2024, la deforestación paso de 8 020,31 ha a 10 599,44 ha, en 6 años de evaluación, la deforestación se incrementó en 2 579,13 ha. Siendo la mayor responsable la minería de oro con un 65,50% en el 2018 y 72,80% en el 2024. La pérdida de cobertura boscosa en el periodo de 2018-2024 mostró una tasa anual de cambio (q) de -0,24% y una deforestación total anual promedio (r) de 429,95 ha/año. Para los años 2018 y 2024, se determinó una precisión global a través de un análisis de una matriz de confusión que arrojó un valor de 87,30% y 89,30%, respectivamente. La concordancia de kappa reportó una fiabilidad de 0,848 y 0,873, categorizada como Casi perfecta. El cambio de LULC cuantifica a la clase de bosque y áreas mayormente naturales con 178 800,15 ha para 2018 y con 177 628,91ha para 2024. Traduciéndose en una deforestación inicial de 7 936,97 a una final de 9 107.66 ha. Esta tendencia, género que de 2018-2024 las áreas de pasto (15) aumentara en un 58,91%, agricultura (18) con 278,19%, mosaico agropecuario (21) con 1,66%, infraestructura (24) con 59,23% y minería (30) con un 20,49%. Finalmente, se demuestra la alta fiabilidad de imágenes de alta resolución para cuantificar la deforestación en la Amazonia.

Palabras clave: Uso y cobertura de suelo, neural net, minería de oro, agricultura y mosaico agropecuario.

Abstract

The study aimed to assess the spatio-temporal changes of deforestation due to anthropogenic activities in the indigenous territories of the Amarakaeri Madre de Dios ECA from PlanetScope imagery, period 2018-2024. High-resolution satellite imagery (4 m spatial resolution) from PlanetScope was used for its advantages in differentiating different land cover classes with higher spatial resolution, using neural network techniques with ENVI. The results showed an area of forest formation and mostly natural areas for the initial period (2018) from 178 716.80 ha to 176 137.13 ha by 2024, deforestation increased from 8 020.31 ha to 10 599.44 ha, in 6 years of assessment, deforestation increased by 2 579.13 ha. Gold mining is the most responsible with 65.50% in 2018 and 72.80% in 2024. The loss of forest cover in the period 2018-2024 showed an annual rate of change (q) of -0.24% and an average annual total deforestation (r) of 429.95 ha/year. For the years 2018 and 2024, an overall accuracy was determined through a confusion matrix analysis, which yielded a value of 87.30% and 89.30%, respectively. The kappa concordance showed a reliability of 0.848 and 0.873, categorized as near perfect. The LULC change quantifies the forest class and mostly natural areas with 178,800.15 ha for 2018 and with 177,628.91 ha for 2024. This translates into an initial deforestation of 7,936.97 to a final deforestation of 9,107.66 ha. This trend, gender that from 2018-2024 the pasture (15) will increase by 58.91%, agriculture (18) with 278.19%, agricultural mosaic (21) with 1.66%, infrastructure (24) with 59.23% and mining (30) with 20.49%. Finally, the high reliability of high-resolution imagery for quantifying deforestation in the Amazon is demonstrated.

Key words: Land use and land cover, neural network, gold mining, agriculture and agricultural mosaic.

ÍNDICE

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

INTRODUCCIÓN

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN..... 1

1.1 Descripción del problema 1

1.2 Formulación del problema 3

1.2.1 Problema general..... 3

1.2.2 Problemas específicos 3

1.3 Objetivos de la investigación..... 4

1.3.1 Objetivo general..... 4

1.3.2 Objetivos específicos 4

1.4 Variables de la investigación..... 4

1.4.1 Identificación de variables..... 4

1.5 Operacionalización de variables 5

1.6 Hipótesis 6

1.7 Justificación e importancia 6

1.8 Consideraciones éticas 8

CAPÍTULO II: MARCO TEÓRICO..... 9

2.1 Antecedentes de la investigación..... 9

2.1.1 Antecedentes internacionales 9

2.1.2 Antecedentes nacionales 14

2.2 Base teórica 16

2.2.1 Comunidad Nativa 16

2.2.2 ECA Amaraeri	16
2.2.3 Bosque.....	16
2.2.3 Deforestación	16
2.2.4 Uso y cobertura del suelo (LULC).....	16
2.2.5 Factores de la deforestación.....	18
2.2.6 Principios básicos de la teledetección	20
2.2.7 Sensores remotos.....	21
2.2.8 Concepto de energía	21
2.2.9 Radiación electromagnética.....	22
2.2.10 ENVI.....	22
2.2.11 Clasificador Neural NET (NN)	22
2.2.12 Imágenes PlanetScope	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	28
3.5 Método y técnicas	31
3.6 Tratamiento de datos	33
3.6.1 Procesamiento de datos	33
3.6.3 Precisión de datos clasificados.....	37
3.6.4 Análisis estadístico	40
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	41
4.1 Deforestación por tipo de actividades productivas en territorios indígenas del ECA Amaraeri Madre de Dios	41

4.2 Tasa de deforestación	47
4.3 Evaluación de precisión	49
4.4 Caracterización de los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo).....	52
CONCLUSIONES	56
SUGERENCIAS.....	58
REFERENCIAS BIBLIOGRÁFICAS	59
ANEXOS.....	72

Índice de Tablas

	Pág.
Tabla 1. Operacionalización de variables	5
Tabla 2. Datos de adquisición del sensor PlanetScope	33
Tabla 3. Clases de cobertura y uso del suelo del Perú (MAPBIOMAS Colección 2.0).....	35
Tabla 4. Valores del coeficiente kappa	39
Tabla 5. LULC en territorios indígenas del ECA Amaraeri Madre de Dios de 2018 y 2024.....	43
Tabla 6. LULC por comunidades nativas del ECA Amaraeri Madre de Dios de 2018.....	44
Tabla 7. LULC por comunidades nativas del ECA Amaraeri Madre de Dios de 2024.....	45
Tabla 8. Tasa y deforestación anual promedio LULC en territorios indígenas del ECA Amaraeri Madre de Dios	47
Tabla 9. Tasa y deforestación anual promedio por comunidades nativas del ECA Amaraeri Madre de Dios.....	48
Tabla 10. Matriz de confusión y concordancia de kappa de imágenes de alta resolución frente a imágenes clasificadas de PlanetScope de 2018	50
Tabla 11. Matriz de confusión y concordancia de kappa de datos de campo e imágenes de alta resolución frente a imágenes clasificadas de PlanetScope de 2024	51
Tabla 12. Cambios de LULC como patrones de deforestación en territorios indígenas del ECA Amaraeri Madre de Dios, 2018-2024	54

Índice de Figuras

	Pág.
<i>Figura 1.</i> Parámetros de la misión Planet.	24
<i>Figura 2.</i> Tipo de productos PlanetScope.....	24
<i>Figura 3.</i> Instrumentos de PlanetScope.....	25
<i>Figura 4.</i> Ubicación del área de estudio, área de influencia de ECA Amarakaeri, Madre de Dios y Cusco – Perú.....	28
<i>Figura 5.</i> Distribución de muestras por clases con fines de validación.	30
<i>Figura 6.</i> Esquema metodológico del proceso de clasificación supervisada Neural Net.....	36
<i>Figura 7.</i> Imágenes de alta resolución para validación de la clasificación de LULC (bosque, bosque inundable, zona pantanosa o pastizal inundable, pastizal / herbazal, pasto, agricultura, mosaico agropecuario, infraestructura y minería. a) PeruSAT-1 (pancromático con 0,70 m y multiespectral con 2,8 m), b) WorldView (0,38 m) y c) Dron (0,05 m). .	38
<i>Figura 8.</i> LULC en territorios indígenas del ECA Amaraeri Madre de Dios de 2018.....	42
<i>Figura 9.</i> LULC en territorios indígenas del ECA Amaraeri Madre de Dios de 2024.....	42
<i>Figura 10.</i> Cambios de LULC como patrones de deforestación en territorios indígenas del ECA Amaraeri Madre de Dios, 2018-2024.	53

Índice de anexos

	Pág.
Anexo 1. Matriz de consistencia.	73
Anexo 2. Puntos de muestreo distribuidos al azar por clases en el área de estudio.	74
Anexo 3. Panel fotográfico.	83
Anexo 4. LULC por comunidades nativas.	89

Introducción

La pérdida de bosques a menudo sigue a la demanda de productos forestales y a la producción de tierras despejadas, lo que aumenta preguntas sobre las mejores maneras de equilibrar la conservación con el desarrollo económico (Rico et al. 2018). La pérdida de bosques tropicales ha sido impulsada por innumerables intereses tanto individuales como sociales, desarrollo económico, incluida la tala y la minería legales e ilegales, el desarrollo de infraestructura, la ganadería y la expansión de la agricultura industrializada (Rico et al. 2018). A pesar del crecimiento de los bosques en las zonas templadas; incluso en plantaciones desde 1990 ha habido en promedio una pérdida neta anual de bosques del 0,13 por ciento a nivel mundial (FAO 2016; FAO 2020). Eso representa una pérdida neta total de bosque durante este período de 129 millones de hectáreas, una superficie equivalente al tamaño de Sudáfrica (FAO 2016; FAO 2020).

En el caso de la Amazonía peruana ha experimentado un aumento alarmante en las últimas décadas, con una pérdida de bosque (2001-2022) de 2 921 137 ha, generando consecuencias ambientales y sociales de gran magnitud (MINAM 2024). La región de Madre de Dios, lugar donde se encuentra la Reserva Comunal Amarakaeri y sus comunidades nativas asociadas, no es excluyente a esta problemática, y representa una pérdida de bosque de 10,33% (301 781 ha) respecto a la Amazonia peruana (MINAM 2024).

Monitorear los cambios forestales y las áreas de cambios utilizando imágenes de satélite es una parte cada vez más importante de las iniciativas destinadas a reducir la deforestación global, principalmente porque los resultados pueden respaldar una respuesta rápida a la deforestación (Asrat et al. 2018; Vijay et al. 2018; Aik y Ismail 2020; Suratman et al. 2020; González-Fernández et al. 2022; Wagner et al. 2023). Por otro lado, los enfoques existentes para la detección de perturbaciones forestales adolecen de varias limitaciones. Por ejemplo, las series temporales de Landsat y ahora Sentinel analizadas con sistemas de trayectoria espectral se utilizaron para mapear deforestación en varias regiones del mundo. Los productos utilizando un enfoque de aprendizaje automático permiten mapear la extensión, pérdida y ganancia de

la cobertura arbórea a escala global (Asrat et al. 2018; Vijay et al. 2018; Aik y Ismail 2020; Suratman et al. 2020; Pickering et al. 2021; González-Fernández et al. 2022; Masolele et al. 2022; Wagner et al. 2023; Yang et al. 2023).

Para respaldar las actividades de monitoreo de la pérdida de bosque, es necesario detectar cambios forestales lo antes posible, así como caracterizar la dinámica de la superficie terrestre con altas frecuencias temporales en escalas espaciales finas (Asrat et al. 2018; Francini et al. 2020; Pickering et al. 2021; Rufin et al. 2022; Walker et al. 2022; Yang et al. 2023; Zhang et al. 2023). Esta información es esencial para las actividades de monitoreo forestal en territorios heterogéneos como áreas naturales protegidas y comunidades indígenas, donde la dimensión de la apertura de áreas son variables (Asrat et al. 2018; Francini et al. 2020; Pickering et al. 2021; Rufin et al. 2022; Walker et al. 2022; Yang et al. 2023; Zhang et al. 2023).

Hasta la fecha, no está disponible un método integral para monitorear el cambio forestal casi en tiempo real, principalmente porque los sensores ópticos satelitales tradicionales no proporcionan imágenes con tiempos de revisita suficientemente cortos y resolución espacial suficiente para predecir cambios forestales en pequeñas áreas (Chávez et al. 2013; Alarcón et al. 2016; Asrat et al. 2018; Aik y Ismail 2020; Francini et al. 2020; Suratman et al. 2020; Alarcon-Aguirre et al. 2021; Pickering et al. 2021; Alarcon-Aguirre et al. 2022; Alarcon-Aguirre et al. 2023). Múltiples plataformas satelitales con una variedad de frecuencias temporales adquieren imágenes ópticas de alta resolución útiles para cartografiar los cambios forestales: CBERS (26 días), SPOT (26 días), IRS (25 días), LANDSAT (16 días) y Sentinel-2 (2 a 5 días dependiendo de la latitud) (Alarcon-Aguirre et al. 2023) (Vijay et al. 2018; Francini et al. 2020; Masolele et al. 2022). Aunque estas fuentes de información pueden usarse para mapear eficientemente los cambios forestales anuales utilizando métodos de detección de cambios, ninguna adquiere imágenes con suficiente frecuencia para un monitoreo casi en tiempo real (Francini et al. 2020) o para apoyar medidas operativas de reacción rápida, especialmente en regiones nubladas. El número de observaciones válidas se puede aumentar utilizando imágenes de radar de apertura sintética

(SAR) que pueden penetrar las nubes (Alarcón et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022; Alarcon-Aguirre et al. 2023).

La nueva constelación de nanosatélites PlanetScope representa un posible punto de inflexión en este tema. La misión PlanetScope (<https://www.planet.com/>) fue iniciada por Planet Labs Inc., una empresa de imágenes de la Tierra con sede en San Francisco, EE. UU., utilizando múltiples lanzamientos de grupos (bandas) de nanosatélites denominados CubeSat 3 U. (Asrat et al. 2018; Francini et al. 2020; Alarcon-Aguirre et al. 2023; Planet-Team 2024). Estos nanosatélites llamados “*Palomas*” miden aproximadamente 10 cm x 10 cm x 30 cm y están equipados con una cámara multispectral relativamente simple que adquiere datos en cuatro bandas en los canales visible y NIR (entre 455 y 860 nm) (Planet-Team 2024). A partir de la primera bandada desplegada el 22 de junio de 2016, el número de satélites ha aumentado constantemente hasta llegar a 149 satélites en órbita en septiembre de 2019, ofreciendo así una capacidad para recopilar datos de 200 millones de km²/día (Asrat et al. 2018; Francini et al. 2020; Alarcon-Aguirre et al. 2023; Planet-Team 2024). Los satélites PlanetScope están todos en la misma órbita a 400 km de altura, considerablemente más baja que los satélites Landsat (700 km) y Sentinel-2 (780 km) (Planet-Team 2024). Los satélites PlanetScope ofrecen una combinación sin precedentes de resolución espacial de 3 m y resolución temporal de 1 día y representan un avance tecnológico crucial para el desarrollo de sistemas de detección remota casi en tiempo real (Francini et al. 2020; Planet-Team 2024). A pesar de estas ventajas potenciales, una búsqueda bibliográfica basada en Scopus no reveló aplicaciones de las imágenes de PlanetScope para el seguimiento y mapeo de perturbaciones forestales.

El procesamiento aplico el algoritmo de redes neuronales en un software especializado en análisis de imágenes ENVI (Piczak 2015), que ofrecen la posibilidad de clasificar datos basándose en una coincidencia rápida con patrones generales utilizando factores de ponderación previamente calculados (Piczak 2015; Francini et al. 2020). Para ello, se utilizó imágenes de PlanetScope para la detección de cambios forestales y validar el algoritmo

con respecto tanto a la exactitud del mapa como a la precisión de las estimaciones de las áreas de cambio en el área de influencia de la Reserva Comunal Amarakaeri y sus comunidades nativas asociadas (Francini et al. 2020; Planet-Team 2024).

El estudio proporciona una nueva visión sobre cómo la creciente disponibilidad de sensores remotos de alta resolución espaciotemporal puede resolver una importante fuente de error en el mapeo de la cobertura terrestre, dentro del contexto de una de las aplicaciones de datos planetarios recientemente disponibles que se han llevado a cabo para fecha. El enfoque se basó en esfuerzos recientes de la comunidad de observación de la Tierra para de imágenes ópticas PlanetScope, para mejorar la detección y clasificación de la cubierta forestal.

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1 Descripción del problema

La amenaza de la deforestación en la Amazonia es la explotación de su inmensa riqueza, principalmente los recursos forestales, donde la conversión es frecuente para usos agrícolas, zonas de pastoreo, infraestructura vial, extracción de madera y la minería, sean legales o ilegales. La situación es similar en la Amazonia occidental del Perú, donde la deforestación se da en mayor proporción en la conversión de bosque para usos agrícolas y la minería de oro, esta última con una explosión de actividades focalizadas en la parte sur oeste de la región de Madre de Dios. En este caso, se ha experimentado un aumento alarmante en las últimas décadas, con una pérdida de bosque (2001-2022) de 2 921 137 ha, generando consecuencias ambientales y sociales de gran magnitud (MINAM 2024). La región de Madre de Dios, lugar donde se encuentra la Reserva Comunal Amarakaeri y sus comunidades nativas asociadas, no es excluyente a esta problemática, y representa una pérdida de bosque de 10,33% (301 781 ha) respecto a la Amazonia peruana (MINAM 2024).

Mapear la deforestación a través de los cambios en la cobertura y el uso del suelo es uno de los temas más importantes y más investigados en teledetección (Francini et al. 2020; Pickering et al. 2021; Masolele et al. 2022; Rufin et al. 2022; Walker et al. 2022; Wagner et al. 2023; Zhang et al. 2023; Planet-Team 2024). Las herramientas de la ciencia de la teledetección son una parte integral de la implementación de programas de mapeo a escala nacional y subnacional de acuerdo con las pautas establecidas por el Panel Intergubernamental sobre el Cambio Climático (IPCC) (Francini et al. 2020; Pickering et al. 2021; Masolele et al. 2022; Rufin et al. 2022; Planet-Team 2024). Automatizar completamente este proceso de mapeo es difícil debido a

una serie de factores, incluida la diversidad de tipos de cambios en la cobertura del suelo (Francini et al. 2020; Pickering et al. 2021; Masolele et al. 2022; Rufin et al. 2022; Planet-Team 2024).

Los avances en la tecnología de teledetección brindan oportunidades cada vez mejores para mapear y rastrear los cambios en la cobertura y el uso de la tierra. Una de las formas más reconocidas y eficientes de monitorear estos cambios es mediante el uso de imágenes satelitales para mapear los cambios en la cobertura del suelo empleando una muestra probabilística del área objetivo. La elección de imágenes satelitales de referencia es una decisión clave en la implementación de programas cartográficos (Francini et al. 2020; Pickering et al. 2021; Alarcon-Aguirre et al. 2023). Idealmente, las imágenes de referencia deberían tener suficiente resolución espacial y temporal para que los mapas y estimaciones producidos sean altamente precisos y relevantes tanto a escala local como nacional (Francini et al. 2020; Pickering et al. 2021; Alarcon-Aguirre et al. 2023). Para los estudios que analizan la dinámica histórica de la cobertura del suelo como es nuestro caso, las imágenes Landsat son la mejor fuente de imágenes de referencia, ya que su archivo se remonta a la década de 1980 (Francini et al. 2020; Pickering et al. 2021; Alarcon-Aguirre et al. 2023). Sin embargo, para algunas aplicaciones, la resolución de 30 m del Landsat y un intervalo de revisión de 8 a 16 días no son suficientes (Francini et al. 2020; Pickering et al. 2021; Alarcon-Aguirre et al. 2023). Por ejemplo, la degradación forestal asociada con la eliminación parcial de la cubierta de dosel debido a la tala selectiva podría no capturarse adecuadamente en datos de resolución de 30 m.

Las imágenes de PlanetScope cambian las reglas del juego en términos de resolución espacial y temporal. PlanetScope es una constelación de más de 200 satélites que brindan cobertura diaria de imágenes globales con una resolución espacial de 3 a 5 m. Las imágenes con esta resolución y frecuencia de revisión permiten el mapeo de áreas taladas más grandes en los bosques y, de manera importante, aumentan nuestra capacidad para rastrear cambios efímeros a pequeña escala en la cubierta arbórea, como la recolección

selectiva de madera (Asrat et al. 2018; Francini et al. 2020; Pickering et al. 2021; Masolele et al. 2022; Rufin et al. 2022; Planet-Team 2024).

En este contexto, la investigación se enfocó en la problemática crítica de la deforestación por diferentes tipos de actividades antrópicas (como la minería de oro, tala, invasiones, cultivos ilícitos entre otros) que impactan la cobertura vegetal en áreas de las comunidades nativas asociada a la Reserva Comunal de Amarakaeri, como parte de la gestión territorial de la Reserva.

1.2 Formulación del problema

1.2.1 Problema general

¿Cuáles son los escenarios del espacio-temporal de la deforestación por actividades antrópicas en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024?

1.2.2 Problemas específicos

P.E.1 ¿Cuanto es la deforestación por tipo de actividad productiva en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024?

P.E.2 ¿Cuál es la tasa de deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024?

P.E.3 ¿Cuánto es la precisión de la clasificación del algoritmo de redes neuronales de los periodos 2018 y 2024?

P.E.4 ¿Cómo y cuánto son los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo) en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024?

1.3 Objetivos de la investigación

1.3.1 Objetivo general

Evaluar los cambios espacio-temporales de la deforestación por actividades antrópicas en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024.

1.3.2 Objetivos específicos

O.E.1 Cuantificar la deforestación por tipo de actividad productiva en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.

O.E.2 Determinar la tasa de deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.

O.E.3 Evaluar la precisión de la clasificación del algoritmo de redes neuronales de los periodos 2018 y 2024.

O.E.4 Caracterizar los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo) en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.

1.4 Variables de la investigación

1.4.1 Identificación de variables

Variable Dependiente: Deforestación y patrones espaciales en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.

Variable Independiente: Comportamiento de la deforestación por tipo de actividad productiva en la unidad mínima de medida del pixel de imágenes PlanetScope.

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				
El análisis espacio-temporal de cobertura del suelo permite cuantificar la deforestación en territorios indígenas del ECA Amaraeri Madre de Dios en los periodos 2018 y 2024.	Cuantificación de la deforestación en territorios indígenas del ECA Amaraeri Madre de Dios.	Deforestación en territorios indígenas del ECA Amaraeri.	Superficie en hectáreas (ha).	P.E.1
	Medición de la tasa de deforestación en territorios indígenas del ECA Amaraeri Madre de Dios.	Tasa de deforestación en territorios indígenas del ECA Amaraeri.	Tasa porcentual y en hectáreas (ha).	P.E.2
	Precisión del algoritmo de redes neuronales.	Fiabilidad del algoritmo.	Matriz de confusión e índice de kappa.	P.E.3
Los cambios de uso y cobertura del suelo permiten caracterizar los patrones espaciales de la deforestación en territorios indígenas del ECA Amaraeri Madre de Dios en los periodos 2018 y 2024.	Patrones espaciales de la deforestación en territorios indígenas del ECA Amaraeri Madre de Dios	Dinámica de patrones espaciales de la deforestación.	Superficie en hectáreas (ha).	P.E.4
Variable dependiente				
La cuantificación del uso y cobertura permite evaluar el espacio-temporal de la deforestación en territorios indígenas del ECA Amaraeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024.	Deforestación y patrones espaciales en territorios indígenas del ECA Amaraeri Madre de Dios en los periodos 2018 y 2024.	Dinámica de la deforestación y patrones espaciales.	Deforestación por tipo de actividad productiva y patrones espaciales.	P.E.1 P.E.2 P.E.3 P.E.4

1.6 Hipótesis

Hipótesis nula (H_0): No existe un incremento significativo de la deforestación en los territorios indígenas del ECA Amarakaeri causado por actividades antrópicas como la minería y agricultura migratoria, en el periodo 2018-2024.

Hipótesis alterna (H_1): Existe un incremento significativo de la deforestación en los territorios indígenas del ECA Amarakaeri causado por actividades antrópicas como la minería y agricultura migratoria, en el periodo 2018-2024.

1.7 Justificación e importancia

El estudio sobre la evaluación espacio-temporal de la deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope durante el periodo 2018-2024, es crucial en el ámbito forestal y ambiental, debido a la creciente presión antropogénica en los bosques en comunidades indígenas y la necesidad de comprender y mitigar los impactos sobre la cobertura del suelo, aplicando los sistemas de información geográfica y sensoramiento remoto,

Los bosques tropicales del mundo contienen más de la mitad de las reservas globales de carbono superficial y proporcionan un inmenso valor ambiental y económico, sobre todo a través de su papel en el ciclo global del carbono (Baccini et al. 2017). Debemos tener en cuenta, que cada año el mundo pierde alrededor de 5 millones de hectáreas de bosques. El 95% de esto ocurre en los trópicos. Al menos las tres cuartas partes de esto son impulsadas por la agricultura: la tala de bosques para cultivar, criar ganado y producir otros productos derivados. Si queremos abordar la deforestación debemos entender dos preguntas clave: dónde estamos perdiendo bosques y qué actividades lo están impulsando. Esto nos permite dirigir nuestros esfuerzos hacia industrias, productos o regiones específicos donde tendrán el mayor impacto (Zhang et al. 2023).

Durante las últimas tres décadas, el 17% de los bosques tropicales del mundo fueron deforestados y el 10% se degradaron a escala pantropical (Vancutsem et al.), lo que provocó cambios masivos en el flujo de carbono y pérdidas de biodiversidad (Baccini et al. 2017; Zhang et al. 2023). Se necesita urgentemente un monitoreo satelital de las perturbaciones de los bosques tropicales para apoyar la conservación de los bosques tropicales y promover su uso sostenible, más aún cuando se trata de comunidades indígenas (Vancutsem et al. ; Baccini et al. 2017; Francini et al. 2020; Zhang et al. 2023).

Se han utilizado ampliamente imágenes de sensores satelitales con diversas resoluciones espaciales que van desde 10 m a 250 m para mapear las perturbaciones de los bosques tropicales (Vancutsem et al. ; Baccini et al. 2017; Francini et al. 2020; Zhang et al. 2023). Durante las últimas dos décadas, cabe destacar que se desarrollaron muchos productos de cambio de la cubierta del suelo basados en sensores remotos listos para usar, que pueden aplicarse para monitorear las perturbaciones de los bosques tropicales (MODIS Vegetation Continuous Fields, Landsat, ALOS/ALOS-2 PALSAR/PALSAR-2, mapas de cubierta forestal global con una resolución espacial de 25 m, mapa anual de cambio forestal global (GFC) de 30 m y fusiones de imágenes ópticas-radar) (Vancutsem et al. ; Baccini et al. 2017; Francini et al. 2020; Zhang et al. 2023).

Por otro lado, las imágenes de sensores satelitales de resolución espacial muy fina (VFR), como Quickbird, IKONOS, Worldview, RapidEye, SPOT y GaoFen, se pueden utilizar como fuentes de datos alternativas para estimar las perturbaciones de los bosques tropicales a pequeña escala (Vancutsem et al. ; Baccini et al. 2017; Francini et al. 2020; Walker et al. 2022; Wagner et al. 2023; Zhang et al. 2023). Sin embargo, el período de revisita de estos sensores satelitales siempre es demasiado breve para monitorear las aperturas a corto plazo de la cobertura y el impacto causadas por el desmonte y la tala selectiva de los pequeños agricultores (Francini et al. 2020; Zhang et al. 2023), y las licencias de datos de estos satélites comerciales son costosas. La nueva constelación PlanetScope está compuesta por más de 200 satélites *Dove* y proporciona imágenes multispectrales de cuatro bandas

con un tiempo de revisita diaria y una resolución espacial de 3 m. Planet es el primer sistema satelital con una combinación única de gran cobertura, frecuencia diaria y resolución espacial a nivel de metros (Francini et al. 2020; Wagner et al. 2023; Zhang et al. 2023; Planet-Team 2024). Sin embargo, las imágenes diarias de PlanetScope de 3 m no están disponibles gratuitamente en la actualidad a gran escala y las densas imágenes diarias de resolución espacial fina a largo plazo requieren un intenso procesamiento computacional. Esto puede limitar su posible uso generalizado, especialmente para monitorear las perturbaciones forestales a gran escala.

Dado el gran potencial de las imágenes de PlanetScope para el mapeo de las perturbaciones de los bosques tropicales, el desafío es cuantificar la deforestación y patrones espaciales en territorio indígenas del ECA Amarakaeri Madre de Dios durante los periodos 2018 y 2024.

1.8 Consideraciones éticas

Estudiar el espacio-temporal de la deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024, requiere de protocolos de clasificación supervisada adecuados que permitan estimar los patrones espaciales de la deforestación y medir la fiabilidad de la precisión del algoritmo bajo un rigor científico probado.

El Centro de Teledetección para el Estudio y Manejo de los Recursos Naturales (CETEGERN) de la UNAMAD brindará la asesoría especializada en el estudio, con la finalidad que el tesista cumpla los objetivos planteados.

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de la investigación

2.1.1 Antecedentes internacionales

Yang et al. (2023) cartografiaron la cubierta forestal tropical a pequeña escala para el sudeste asiático utilizando imágenes Planet-NICFI y Sentinel-1. La precisión de los productos de cobertura forestal existente adolece de errores de “redondeo” que surgen de las clasificaciones que estiman la cobertura fraccionaria de bosque en cada píxel, que a menudo excluyen la presencia de árboles grandes y aislados y claros de bosque pequeños o estrechos, y es atribuible principalmente a la resolución moderada de las imágenes utilizadas para hacer mapas. Sin embargo, el grado en que estas imágenes de alta resolución pueden mitigar este problema y, por lo tanto, mejorar los mapas de cobertura forestal de grandes áreas, está en gran medida inexplorado. Aquí, desarrollamos un enfoque para mapear la cubierta forestal tropical a escala fina utilizando imágenes de radar de apertura sintética (SAR) Planet y Sentinel-1 en la plataforma Google Earth Engine y lo utilizaron para mapear toda la cubierta forestal del sudeste asiático. El enfoque de aprendizaje automático, basado en los modelos de Random Forests y entrenado y validado utilizando un total de 37 345 etiquetas recopiladas de imágenes de Planet en toda la región, tuvo una precisión de 0,937 y una puntuación F1 de 0,942, mientras que una versión basada únicamente en imágenes de Planet tuvo una precisión de 0,908 y F1 de 0,923.

Zhang et al. (2023) monitorearon las perturbaciones mensuales del bosque húmedo tropical con imágenes de Planet NICFI en Camerún. La tala selectiva y la tala por parte de pequeños agricultores fueron los factores dominantes de las alteraciones de los bosques tropicales. El estudio desarrollo un método para monitorear las perturbaciones mensuales de los bosques húmedos

tropicales a pequeña escala utilizando imágenes de Planet NICFI de 2021. Se obtuvo un mapa mensual ajustado de perturbación forestal eliminando muchos falsos positivos con un filtro espacio-temporal. Los resultados demostraron que el método aplicado a las imágenes mensuales de Planet NICFI fue eficaz para identificar numerosas perturbaciones de bosques tropicales a pequeña escala que fueron de corta duración y duraron solo unos pocos meses. Después de filtrar nuevas posibles perturbaciones forestales en 2021 que no cumplieron con un criterio de permanencia temporal basado en las imágenes mensuales, las precisiones ajustadas de usuarios y productores para fueron $84,7 \pm 2,9\%$ y $61,5 \pm 46,4\%$, respectivamente ($\pm 95\%$ intervalos de confianza). Los resultados proporcionan detalles espaciales mucho mayores que los métodos de alteración forestal basados en imágenes de Sentinel-1 y Landsat.

Matosak et al. (2022) mapearon la deforestación en el Cerrado basado en una arquitectura híbrida de aprendizaje profundo y series temporales satelitales de resolución espacial media en Brasil, cubriendo alrededor de 2 millones de km^2 . El método propuesto, evalúa la serie de tiempo en relación con el eje de tiempo para crear un mapa de probabilidad de deforestación, que el algoritmo U-Net analiza espacialmente junto con la pendiente del terreno para producir mapas de deforestación finales. El método se aplicó en dos áreas de estudio diferentes, que representan mejor los principales patrones de deforestación presentes en el Cerrado. Los mapas de deforestación resultantes, basados en imágenes gratuitas de Sentinel-2, lograron métricas de alta precisión, alcanzando un máximo de precisión general de $99,81\% \pm 0,219$ y F1-Puntuación de $0,8795 \pm 0,118$. Además, el método propuesto mostró un gran potencial para automatizar la cartografía.

Masolele et al. (2022) usaron imágenes de alta resolución y aprendizaje profundo para clasificar el uso de la tierra después de la deforestación: un estudio de caso en Etiopía. Evaluaron el potencial de diferentes modalidades de datos satelitales (fecha única, fechas múltiples, resolución múltiple y un conjunto de imágenes de sensores múltiples) para clasificar el uso de la tierra después de la deforestación en Etiopía utilizando la red profunda U-Net.

Arquitectura de red neuronal mejorada con atención. Realizaron el análisis de datos de imágenes satelitales recuperados en Etiopía a partir de datos satelitales Landsat-8, Sentinel-2 y Planet-NICFI disponibles gratuitamente. Los experimentos tenían como objetivo un análisis de (a) imágenes de una sola fecha de sensores individuales para tener en cuenta las diferencias en la resolución espacial entre sensores de imágenes en la detección de usos de la tierra, (b) conjuntos de múltiples imágenes de diferentes sensores (Planet-NICFI/Sentinel-2/Landsat-8) con diferentes resoluciones espaciales, (c) el uso de datos de múltiples fechas para dar cuenta de la contribución de la información temporal en la detección de usos de la tierra y, finalmente, (d) la identificación de diferencias regionales en términos del uso de la tierra tras la deforestación en Etiopía. La hipótesis es que elegir el tipo correcto de imágenes satelitales (sensor) es crucial para la tarea. Con base en un conjunto de datos de referencia integral interpretado visualmente de 11 tipos de usos de la tierra posteriores a la deforestación, encontraron que ya sea patrones espaciales detallados (Planeta-NICFI de fecha única) o patrones temporales detallados (Sentinel-2 de múltiples fechas, Landsat-8) son necesarios para identificar el uso de la tierra después de la deforestación, mientras que las imágenes de fecha única de resolución media no son suficientes para lograr una alta precisión de clasificación.

Rufin et al. (2022) mapearon grandes áreas de tierras de cultivo activas y barbechos a corto plazo en paisajes de pequeños agricultores utilizando datos de PlanetScope. El estudio se centró en el norte de Mozambique, un área que comprende 381 698 km². El enfoque se basó en Google Earth Engine y series temporales de mosaicos PlanetScope disponibles abiertamente a través del programa de datos de la Iniciativa Internacional sobre Clima y Bosques de Noruega (NICFI). Realizaron un corre gistro multitemporal de los datos de PlanetScope utilizando imágenes base estacionales de Sentinel-2 y derivamos métricas de series temporales estacionales consistentes y sin brechas para clasificar las tierras de cultivo activas y los barbechos a corto plazo. Se utilizó un marco de aprendizaje activo iterativo basado en probabilidades de clases de Random Forest para entrenar clases raras y

regiones inciertas. El mapa fue preciso (precisión general ajustada por área $88,6 \% \pm 1,5 \%$), siendo el principal tipo de error la comisión de tierras de cultivo activas. Las estimaciones de área ajustadas por errores de la extensión de las tierras de cultivo activas ($61.799,5 \text{ km}^2 \pm 4.252,5 \text{ km}^2$) revelaron que los productos de cobertura del suelo globales y regionales existentes tienden a subestimar o sobreestimar la extensión de las tierras de cultivo activas, respectivamente. Los barbechos a corto plazo ocuparon el 28,9% de las tierras de cultivo en nuestra muestra de referencia (13% de las tierras de cultivo cartografiadas), y las regiones agrícolas consolidadas mostraron las proporciones más altas de barbechos a corto plazo. El enfoque se basó en datos de PlanetScope disponibles abiertamente y en el procesamiento basado en la nube en Google Earth Engine, lo que minimiza las restricciones financieras y maximiza la replicabilidad de los métodos. Todo el código y los mapas estuvieron disponibles para su uso posterior.

Pickering et al. (2021) usaron datos satelitales de resolución múltiple para cuantificar la dinámica de la tierra: aplicaciones de las imágenes PlanetScope para la estimación del área de pérdida de cobertura arbórea y tierras de cultivo. El método propuesto fue independiente de la región geográfica y el tipo de cobertura y cambio del suelo, lo que se demuestra aplicando el método en dos geografías y clases temáticas muy diferentes. Se estima la extensión del trigo en Punjab, Pakistán, para la temporada de crecimiento 2018/2019, y se estima el área de pérdida de cubierta arbórea en Perú para 2017 y 2018. Utilizaron una serie temporal de imágenes de PlanetScope para clasificar una muestra de bloques de $5 \times 5 \text{ km}$ para cada región y área de producción se estima una pérdida de $55\,947 \text{ km}^2 (\pm 9,0\%)$ de trigo en Punjab y $5\,398 \text{ km}^2 (\pm 9,1\%)$ de pérdida de cubierta arbórea en Perú. También demostraron el uso de la estimación de regresión utilizando información de población de mapas basados en Landsat para reducir los errores estándar de las estimaciones basadas en muestras. Las estimaciones de regresión resultantes fueron del 3,6% y 5,1% para Pakistán y Perú, respectivamente. La combinación de la cobertura global diaria y la alta resolución espacial de las imágenes de Planet mejora nuestra capacidad para monitorear la fenología

de los cultivos y capturar la pérdida efímera de la cubierta arbórea y la dinámica de degradación, mientras que los mapas basados en Landsat brindan información de pared a pared para apuntar a la muestra y aumentar la precisión. de las estimaciones mediante el uso de estimación de regresión.

Aik y Ismail (2020) detectaron la deforestación y análisis de conversión de tierras a partir de imágenes satelitales de alta resolución en el distrito de Bintulu, Serawak, Malasia. En el Sudeste Asiático, la difusión de la palma aceitera ha experimentado un auge en las últimas dos décadas, lo que ha provocado la desaparición de las tierras forestales tropicales. Este cambio ha sido particularmente frecuente en Borneo, donde las tierras protegidas están cada vez más desarrolladas para el aceite de palma y las tierras ya deforestadas se están convirtiendo en plantaciones industriales. Las principales preocupaciones relacionadas con este patrón de cambio de uso de la tierra son los impactos a corto y largo plazo de la tala en nuestros entornos y ecosistemas naturales y cómo los patrones de deforestación están contribuyendo a problemas ambientales globales como el cambio climático. Al detectar y mapear las actividades madereras, los departamentos forestales pueden predecir mejor los cambios en la cobertura del suelo en una región particular como resultado del desarrollo y la deforestación. En este estudio, se utilizó una evaluación de la cobertura terrestre basada en técnicas de detección remota para analizar los cambios en el distrito de Bintulu, Borneo, especialmente el crecimiento de la palma aceitera y su influencia en la disminución de las áreas forestales entre 2016 y 2018. Imágenes satelitales de alta resolución (resolución espacial de 3 m) de PlanetScope se utilizaron debido a los beneficios de ayudar a diferenciar varias clases de cobertura terrestre en una resolución espacial más alta. Los resultados mostraron que la disminución de los bosques primarios en Bintulu es de aproximadamente el 26,5% en los últimos dos años. Con esa disminución, se produce un aumento del crecimiento de la palma aceitera del 17,6% en tan solo dos años. Se detectó un aumento en las áreas taladas (36,1%) para conversión a otras coberturas terrestres con una disminución constante de otras clases de cobertura terrestre de al menos un 20% cada año. La precisión de los

resultados demostró ser razonable con un 90,0% de confianza con imágenes de satélite. Por lo tanto, con el resultado se puede considerar un paso necesario para monitorear y prevenir la deforestación y diversas invasiones del bosque. Con datos satelitales de alta resolución, el monitoreo a escala local se ha vuelto posible para los administradores de recursos como una forma de crear evaluaciones oportunas y confiables.

Francini et al. (2020) detectaron los cambios forestales en tiempo casi real utilizando imágenes PlanetScope. El estudio propuso un sistema de alerta de perturbaciones forestales en tiempo casi real: el algoritmo Thresholding Rewards and Penances (TRP) produjo un nuevo mapa de cambios de bosque tan pronto como se adquiere una nueva imagen de PlanetScope. Para calibrar y validar el TRP, se construyó un conjunto de referencia como un censo completo de cinco áreas de estudio seleccionadas al azar en Toscana, Italia. Procesaron 572 imágenes PlanetScope adquiridas entre el 1 de mayo de 2018 y el 5 de julio de 2019. Se utilizó TRP para construir mapas de cambios forestales durante el período de estudio, para los cuales la precisión del usuario final fue del 86% y la precisión del productor final fue del 92%. Además, estimamos el área de cambio forestal utilizando un estimador estratificado insesgado que puede usarse con una pequeña muestra de datos de referencia. El intervalo de confianza del 95% para la estimación basada en muestra de 56,89 ha incluyó la estimación de área basada en el censo de 56,19 ha.

2.1.2 Antecedentes nacionales

Rico et al. (2018) evaluaron los Impactos forestales de la combinación de derechos de desarrollo y restricciones de uso del suelo en concesiones madereras, certificación y áreas protegidas en la Amazonia peruana. La investigación utilizó datos geospaciales y modelos de diferencias en diferencias para identificar los efectos de la deforestación, durante 2000-2013, de las principales políticas forestales en la Amazonía peruana: i) concesiones madereras, ii) certificación de concesiones por terceros, y iii) Áreas Protegidas (APs). Encontraron que, en promedio, las concesiones madereras no tienen

ningún efecto sobre la pérdida de cobertura arbórea, mientras que las AP reducen la pérdida. Además, las AP que permiten una extracción privada limitada salvan más bosques que las AP más restrictivas. La certificación tiene un impacto (reduce la pérdida) sólo en la única región donde las concesiones reducen la pérdida, lo que sugiere una complementariedad de terceros con los esfuerzos privados y públicos para gobernar las concesiones. Los resultados sugieren funciones para los derechos privados dentro de la conservación, dada la supervisión.

Vijay et al. (2018) analizaron los riesgos de deforestación que plantea la expansión de la palma aceitera en la Amazonía peruana. Examinaron la deforestación reciente asociada con la palma aceitera en la Amazonía peruana en el contexto de otros cultivos de la región. Encontraron más área dedicada al cultivo de palma aceitera (845 km²) que estudios anteriores. Si bien esto comprende menos del 4% de las tierras de cultivo de la región, representó el 11% de la deforestación causada por la expansión agrícola entre 2007 y 2013. Las zonas de cultivo de palma aceitera eran más grandes y estaban más agrupadas espacialmente que las de otros cultivos, lo que potencialmente aumentaba su impacto en la fragmentación del hábitat local. La modelización del riesgo de deforestación para la expansión de la palma aceitera utilizando factores climáticos y edáficos mostró que los sitios en elevaciones más bajas, con mayores precipitaciones y pendientes más bajas que aquellos típicamente utilizados para la agricultura intensiva corren un riesgo a largo plazo de deforestación debido a la agricultura de palma aceitera. Dentro de las áreas con riesgos a largo plazo, según los modelos CART, las áreas cercanas a centros urbanos, carreteras y áreas previamente deforestadas tienen mayor riesgo de deforestación a corto plazo. Las áreas protegidas existentes y los territorios indígenas oficialmente reconocidos cubren grandes áreas con riesgo a largo plazo de deforestación para la producción de palma aceitera (>40%). Menos del 7% de estas áreas están bajo protección estricta. Con base en estos hallazgos, sugieren un monitoreo específico de la deforestación de la palma aceitera, así como el fortalecimiento y expansión de áreas protegidas para conservar hábitats específicos.

2.2 Base teórica

2.2.1 Comunidad Nativa

Una comunidad es un grupo de personas que se han desarrollado en una zona geográfica específica o en zonas dentro de unas fronteras, caracterizadas por unas condiciones sociales, culturales y económicas que las distinguen de otras y que son reconocidas como un grupo distinto por otros grupos (denominadas "expresiones indígenas") (Crovetto 2013).

2.2.2 ECA Amarakaeri

Las comunidades indígenas de Amarakaeri formaron El Ejecutor del Contrato de Administración de la Reserva Comunal (ECA-Amarakaeri) en 2006 para proteger sus tierras ancestrales al tiempo que colaboraban con las autoridades gubernamentales (Delgado-Pugley y Borg-Rasmussen 2022).

2.2.3 Bosque

Por regla general, un bosque debe tener una cubierta de copas de al menos el 10%, una altura in situ de los árboles de al menos el 5%, una superficie de al menos 0,5 hectáreas y no permitir la agricultura (Whitmore y Burnham 1975; FAO 2012).

2.2.3 Deforestación

Referido a la pérdida de zonas forestales en todo el mundo para destinarlas a otros usos, como terrenos agrícolas, urbanización o actividades mineras. La deforestación, acelerada por la actividad humana desde 1960, ha perjudicado a los ecosistemas naturales, la biodiversidad y el clima (FAO 2020).

2.2.4 Uso y cobertura del suelo (LULC)

El uso del suelo/cobertura del suelo (ocupación del suelo) (LULC) clasifica las actividades humanas y las características naturales del paisaje a lo largo de un periodo de tiempo específico utilizando métodos científicos y estadísticos

de análisis de materiales fuente aceptables. Los métodos de clasificación varían (Bente et al. 2019).

Los mapas de LULC precisos y oportunos son importantes para una variedad de aplicaciones, como la planificación urbana y regional, el monitoreo de desastres y peligros, la gestión de recursos naturales y ambientales y la seguridad alimentaria. El mapeo LULC puede ayudar a abordar muchos desafíos importantes a gran escala, como el calentamiento global, la pérdida acelerada del hábitat de las especies, la migración poblacional sin precedentes, la creciente urbanización y las crecientes desigualdades dentro y entre las naciones. Por lo tanto, es importante producir mapas LULC precisos (Bente et al. 2019; Zhang y Li 2022).

El concepto de uso de la tierra y el concepto de cobertura de la tierra, aunque relacionados, son claramente diferentes. La cobertura de la tierra se refiere principalmente a las observaciones directas de los ecosistemas terrestres, los recursos naturales y los hábitats en la superficie de la Tierra, mientras que el uso de la tierra generalmente describe un cierto tipo de tierra producida, modificada o mantenida por los arreglos, actividades e insumos de las personas. El uso de la tierra se relaciona con el propósito para el cual la tierra es utilizada por las personas, pero la cobertura de la tierra especifica los patrones y características del paisaje. Los ejemplos de uso de la tierra pueden incluir viviendas residenciales multifamiliares, parques estatales, embalses y centros comerciales. En contraste, los ejemplos de cobertura de la tierra pueden incluir bosques, humedales, áreas construidas, agua y pastizales. Sin embargo, el uso de la tierra y la cobertura de la tierra a menudo se utilizan como términos intercambiables en la literatura de investigación existente (Bente et al. 2019; Zhang y Li 2022).

Las imágenes satelitales obtenidas por teledetección son una fuente valiosa para el mapeo LULC (Zhang y Li 2022). Muchos estudios han intentado extraer información LULC de imágenes obtenidas por teledetección. Los avances en las tecnologías de teledetección han resultado en mejoras en las resoluciones espectrales, espaciales y temporales de las imágenes satelitales, todo lo cual beneficia el mapeo LULC (Zhang y Li 2022). El mapeo

LULC actualmente está experimentando una transformación de las escalas gruesas y moderadas a escalas mucho más finas para proporcionar un conocimiento más preciso de la tierra. Aunque las imágenes obtenidas por teledetección se han utilizado en el mapeo LULC desde el lanzamiento de Landsat 1 en 1972, todavía es difícil capturar información y patrones LULC complejos y diversos utilizando solo imágenes obtenidas por teledetección. Por lo general, se necesitan datos auxiliares como complemento a las imágenes obtenidas por teledetección para identificar con precisión la información LULC, especialmente la información de uso de la tierra relacionada con aspectos socioeconómicos (Bente et al. 2019; Zhang y Li 2022).

2.2.5 Factores de la deforestación

El mundo ha perdido un tercio de sus bosques desde la Edad de Hielo y hoy en día se talan aproximadamente 15 mil millones de árboles cada año (Perz et al. 2016; Mendoza et al. 2017; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

Los bosques son fuentes de biodiversidad y un amortiguador esencial contra el cambio climático, ya que absorben miles de millones de toneladas de emisiones de dióxido de carbono cada año. Sin embargo, la pérdida de bosques sigue aumentando (Perz et al. 2016; Mendoza et al. 2017; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

La "pérdida de bosques" es un término amplio que abarca los impactos tanto de la deforestación permanente como de la degradación forestal. Existe una distinción importante entre ambas:

Deforestación permanente: se refiere a la eliminación completa de árboles o la conversión de bosques a otro uso de la tierra (como edificios), donde los bosques no pueden volver a crecer.

Degradación forestal: Se refiere a una reducción en la densidad de árboles en el área sin un cambio en el uso de la tierra. Se espera que los bosques vuelvan a crecer.

La degradación forestal es responsable de más del 70%, o 15 millones de hectáreas, de la pérdida anual de bosques. El 30% restante de los bosques perdidos se debe a la deforestación permanente.

La deforestación provocada por las materias primas, que incluye la tala de bosques para la agricultura y la minería, es la principal causa de la pérdida de bosques. La agricultura por sí sola representa tres cuartas partes de toda la deforestación provocada por las materias primas, en la que los bosques suelen convertirse en tierras para ganaderías y plantaciones (Baraloto et al. 2015; Caballero et al. 2018).

La cosecha de productos forestales como madera, papel, pulpa y caucho representa la mayor parte de la pérdida de bosques por degradación. Este proceso suele gestionarse y planificarse de modo que los bosques puedan volver a crecer después de la cosecha (Perz et al. 2016; Mendoza et al. 2017; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

La agricultura migratoria y los incendios forestales son responsables cada uno de ellos de unos cinco millones de hectáreas o una cuarta parte de la pérdida anual de bosques. En ambos casos, los bosques pueden reponerse si la tierra se deja sin utilizar (Perz et al. 2016; Mendoza et al. 2017; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

La urbanización (la conversión de bosques en tierras para ciudades e infraestructura) es, con diferencia, el factor menos contribuyente: representa menos del 1% de la pérdida forestal anual (Perz et al. 2016; Mendoza et al. 2017; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

Sin embargo, las causas de la deforestación varían de una región a otra. En América Latina y el Sudeste Asiático, la mayor parte de la deforestación actual es resultado de actividades industriales, en particular la ganadería en la Amazonia y la agricultura a gran escala y la tala intensiva en el Sudeste Asiático. La agricultura de subsistencia, que a menudo utiliza técnicas de tala y quema o barbecho, es la principal causa de pérdida de bosques en África. Si bien la pérdida neta de bosques se ha mantenido relativamente constante en los últimos veinte años, ha habido dos cambios significativos desde fines

de la década de 1980: (1) los bosques primarios están siendo reemplazados por plantaciones y bosques degradados y talados; y (2) la tala de bosques está impulsada cada vez más por la industria en lugar de las actividades de subsistencia (Baraloto et al. 2015; Perz et al. 2016; Mendoza et al. 2017; Caballero et al. 2018; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023). Controlar la deforestación es imperativo para abordar el cambio climático. La destrucción anual de 13 millones de hectáreas de bosque representa casi una quinta parte de las emisiones globales de gases de efecto invernadero, una proporción mayor que todos los camiones, automóviles, barcos y aviones del mundo juntos (Baraloto et al. 2015; Perz et al. 2016; Mendoza et al. 2017; Caballero et al. 2018; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023). La minería de oro ya es la segunda causa de deforestación en la región Madre de Dios de la Amazonía peruana, según un estudio científico. La deforestación provocada por la minería de oro se ha incrementado en 90% en el suroeste de la región Madre de Dios, ubicada en la zona oriental de la Amazonía peruana. Así lo revela un estudio científico que muestra cómo la actividad minera pasó de generar el 4 % de las pérdidas forestales al 105 % en 19 años, de 1999 a 2018. Si bien la agricultura sigue siendo la principal causa de deforestación en esta región, los indicadores ubican a la minería de oro como la segunda causa más importante. Solo en las últimas dos décadas (1999-2018) Madre de Dios ha perdido un promedio de casi 6.000 hectáreas por año debido a la agricultura y la minería de oro, señala el estudio (Baraloto et al. 2015; Perz et al. 2016; Mendoza et al. 2017; Caballero et al. 2018; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

2.2.6 Principios básicos de la teledetección

Los objetos y las superficies pueden identificarse por su energía radiante. La teledetección detecta y registra la energía radiante para la investigación utilizando este concepto. El agua, el suelo y las plantas devuelven energía en diferentes longitudes de onda electromagnéticas y en cantidades variadas. ¿Qué variables influyen en ello? Las principales propiedades son: 1. composición química y física, sustancia y rugosidad de la superficie; 2.

intensidad de la radiación, ángulo de incidencia y longitud de onda. La teledetección combina las ciencias ópticas, la fotografía, la espectroscopia, la electrónica, la informática, las telecomunicaciones y las tecnologías de lanzamiento de satélites, entre otras. El sistema de teledetección integra estas tecnologías. Las distintas etapas de la teledetección deben desarrollarse sin problemas para que tenga éxito (Anji-Reddy 2010; Chuvieco 2016; Li et al. 2022).

2.2.7 Sensores remotos

La teledetección es una tecnología que permite la recopilación de datos y el examen de un objeto, ubicación o fenómeno sin entrar en contacto físico directo con él. Tiene aplicaciones en varias disciplinas, incluidas geografía, geología, ecología, glaciología, hidrología y oceanografía. Las imágenes adquiridas de forma remota se recogen mediante cámaras especiales, lo que proporciona a los investigadores una "sensación" de la Tierra y otros planetas. Cuando se combina con la tecnología SIG, la detección remota ayuda en operaciones cruciales de bases de datos, como análisis estadísticos y consultas de mapas (Anji-Reddy 2010; Chuvieco 2016).

2.2.8 Concepto de energía

La capacidad de trabajo es la energía. Mueve con frecuencia lugares y cuerpos. La radiación, la conducción y la convección son procesos de transferencia de energía. La radiación es la transferencia de energía sin un medio. La energía solar se transmite en forma de radiación electromagnética (REM) desde el espacio vacío a la Tierra. La energía transferida de una molécula o átomo a otro se denomina conducción. En este proceso se aplica calor a un cuerpo metálico. La convección es la transferencia de energía de un cuerpo mediante el movimiento de su propio cuerpo. El aire caliente que se eleva desde el suelo y el aire frío que cae al suelo es un ejemplo de calentamiento atmosférico. El primero de los tres procesos es el más significativo para la teledetección (Anji-Reddy 2010; Chuvieco 2016).

2.2.9 Radiación electromagnética

La radiación electromagnética es una forma de energía que se produce por perturbaciones eléctricas y magnéticas oscilantes, o por el movimiento de partículas cargadas eléctricamente que viajan a través del vacío o de la materia. Los campos eléctrico y magnético forman ángulos rectos entre sí y la onda combinada se mueve perpendicularmente a los campos oscilantes magnéticos y eléctricos, de ahí la perturbación. La radiación de electrones se libera en forma de fotones, que son haces de energía luminosa que viajan a la velocidad de la luz como ondas armónicas cuantificadas. Luego, esta energía se agrupa en categorías según su longitud de onda en el espectro electromagnético. Estas ondas eléctricas y magnéticas viajan perpendiculares entre sí y tienen ciertas características, que incluyen amplitud, longitud de onda y frecuencia (Anji-Reddy 2010; Chuvieco 2016).

2.2.10 ENVI

ENVI® es el programa líder de análisis de imágenes utilizado por expertos en SIG, científicos de teledetección, y analizadores de imágenes. ENVI le permite extraer información relevante de las imágenes con el fin de hacer mejores juicios. ENVI se puede implementar y acceder tanto desde el escritorio como desde la nube (England et al. 1989).

2.2.11 Clasificador Neural NET (NN)

En aprendizaje automático, una red neuronal (RNA o NN) es un modelo inspirado en las redes neuronales biológicas del cerebro animal. Las RNA están formadas por neuronas artificiales conectadas que imitan a las neuronas cerebrales. Éstas se conectan mediante bordes de simulación de sinapsis cerebrales. Una neurona artificial recibe señales de las neuronas conectadas, las procesa y las envía a otras neuronas conectadas. La "señal" es un número real, y la salida de cada neurona se calcula utilizando una función no lineal del total de sus entradas, llamada función de activación. El peso de las neuronas y los bordes se ajusta a medida que avanza el aprendizaje. El peso puede

aumentar o disminuir la intensidad de una señal en una conexión (Piczak 2015).

La clasificación de imágenes es un proceso complejo afectado por algunas incertidumbres y decisiones tomadas por los investigadores. La precisión lograda por una clasificación supervisada depende en gran medida de los datos de entrenamiento proporcionados por el analista. El uso de conjuntos de datos de entrenamiento representativos es de gran importancia para el rendimiento de todos los métodos de clasificación. Sin embargo, esta cuestión es más importante para los clasificadores de redes neuronales, ya que toman en cuenta cada muestra en la etapa de entrenamiento. La representatividad está relacionada con el tamaño y la calidad de los datos de entrenamiento, que son muy importantes para evaluar la precisión de los mapas temáticos derivados de los datos detectados de forma remota. El análisis de calidad de los datos de entrenamiento ayuda a identificar píxeles atípicos y mixtos que pueden socavar la confiabilidad y la precisión de una clasificación resultante de una definición incorrecta del límite de clase. La selección de datos de entrenamiento puede considerarse como un proceso iterativo que se lleva a cabo para formar un conjunto de datos representativos después de algunas precisiones. Desafortunadamente, en muchas aplicaciones no se cuestiona la calidad de los datos de entrenamiento y el conjunto de datos se emplea directamente en la etapa de entrenamiento. Para aumentar la representatividad de los datos de entrenamiento, se presenta un enfoque de dos etapas y se realizan pruebas de rendimiento para una región seleccionada. Cumpliendo estos protocolos, los resultados mostrarán el uso de datos de entrenamiento más representativos ayudando al clasificador a producir resultados más precisos y confiables. Una mejora de varios puntos porcentuales en la precisión de la clasificación puede tener un efecto significativo en la calidad de la imagen clasificada (Kavzoglu 2009; Radhika y Varadarajan 2018; Jarrallah y Khodher 2022).

2.2.12 Imágenes PlanetScope

Planet proporciona información geoespacial a la velocidad del cambio, ayudando a las organizaciones a tomar decisiones informadas y oportunas. Las mejores imágenes de su clase le permiten supervisar áreas de interés, validar datos sobre el terreno e identificar patrones organizativos. Planet gestiona una flota de casi 200 satélites, que en conjunto ofrecen una colección sin parangón de imágenes de observación de la Tierra. Planet proporciona información geoespacial a un ritmo rápido, ofreciendo una amalgama distintiva de cobertura, frecuencia y resolución. Esto permite a los usuarios adquirir una comprensión completa y matizada de las condiciones dinámicas del terreno. La cámara PlanetScope de cada cubesat Dove funciona actualmente en ocho bandas: borde rojo, rojo, verde, verde I, amarillo, azul, azul costero e infrarrojo cercano (Figura 1, 2 y 3).

Orbit Altitude	475 km - 525 km
Orbit Type	Sun-synchronous
Orbit Inclination	98°
Repeat Cycle	Daily
Equator Crossing Time	9:30 - 11:30 am (local solar time)

Figura 1. Parámetros de la misión Planet.

Name	Description	Product Level
PlanetScope Basic Scene Product	Scaled Top of Atmosphere Radiance (at sensor) and sensor corrected product. The Basic Scene product is designed for users with advanced image processing and geometric correction capabilities. This product has scene based framing and is not projected to a cartographic projection. Radiometric and sensor corrections applied to the data.	Level 1B
PlanetScope Ortho Scene Product	Orthorectified, scaled Top of Atmosphere Radiance (at sensor) or Surface Reflectance image product suitable for analytic and visual applications. This product has scene based framing and is projected to a cartographic projection.	Level 3A
PlanetScope Ortho Tile Product	Radiometric and sensor corrections applied to the data. Imagery is orthorectified and projected to a UTM projection.	Level 3B

Figura 2. Tipo de productos PlanetScope.

Sensor Type	Three-band frame Imager or four-band frame Imager with a split-frame NIR filter (Dove-C) Four-band frame imager with butcher-block filter providing blue, green, red, and NIR stripes (Dove-R) Eight-band frame imager with butcher-block filter providing blue, green, red, red-edge, and NIR stripes (SuperDove)
Spectral Bands	Coastal Blue: 431 - 452 nm Blue: 465 - 515 nm Green I: 513 - 549 nm Green: 547 - 583 nm Yellow: 600 - 620 nm Red: 650 - 680 nm RedEdge: 697 - 713 nm NIR: 845 - 885 nm
Ground Sample Distance (nadir)	Dove-C: 3.0 m-4.1 m Dove-R: 3.0 m-4.1 m SuperDove: 3.7 m-
Frame Size	24 km x 8 km (approximate) for Dove-C 24 km x 16 km (approximate) for Dove-R 32.5 km x 19.6 km (approximate) for SuperDove
Maximum Image Strip per orbit	20,000 km ²
Revisit Time	Daily at nadir
Image Capture Capacity	200 million km ² /day

Figura 3. Instrumentos de PlanetScope.

2.3 Definición de términos

Clasificación supervisada: técnicas de procesamiento que utiliza áreas de entrenamiento supervisadas por el usuario (Nair y Bindhu 2016).

Neural Net: en aprendizaje automático, una red neuronal es un modelo inspirado en las redes neuronales biológicas del cerebro de los animales (Piczak 2015).

Actividades antropogénicas: todas las actividades influenciadas por el hombre.

Pixel: es la unidad más pequeña de una imagen digital (Nair y Bindhu 2016).

Tasa de deforestación: es el número anual de hectáreas o masas forestales que desaparecen (FAO 2020).

Uso de suelo: el suelo se clasifica por las actividades o personas que lo ocupan, como agrícola, industrial, residencial, urbano, rural o comercial (FAO 2020).

Ocupación del suelo: La categoría del terreno se basa en la vegetación de la superficie y los materiales que la componen, tales como pinar, prado, hielo, agua, o arena (FAO 2020).

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN

3.1 Tipo de estudio

El estudio es descriptiva y correlacional porque evaluó el espacio-temporal de la deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024 (Hernández-Sampieri y Mendoza-Torres 2018; León y González 2020).

3.2 Diseño del estudio

El estudio corresponde a un diseño no experimental Transaccional longitudinal de tendencia porque evaluó el espacio-temporal de la deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024 (Hernández-Sampieri y Mendoza-Torres 2018; León y González 2020).

3.3 Delimitación espacial y temporal

El área de estudio tiene una extensión aproximada de 1 981,0884 km² (198 108,84 ha), 9 comunidades se ubican en los distritos de Madre de Dios, Manu, Fitzcarrald y Huepetuhe del departamento de Madre de Dios y una en el distrito de Kcosñipata provincia de Paucartambo departamento de Cusco (12°9'34" y 13°12'13" S, 70°14'25" y 71°31'19" O). El clima va de semicálido y cálido. Las temperaturas oscilan entre 23,1 y 28,5 °C en las partes altas y entre 25 y 38 °C en las bajas. Durante los meses de junio y julio, la zona experimenta un descenso significativo de las temperaturas mínimas de hasta 8 °C, fenómeno conocido como "friaje" causado por los vientos polares que soplan a través de los Andes. Con precipitaciones anuales de alrededor de 2 480 mm a 3 810 mm y una variación altitudinal de 300 a 2 700 m s.n.m

(Holdridge 1967). Los ríos Colorado y Madre de Dios son las cuencas más importantes para garantizar la estabilidad de la tierra y los bosques a fin de mantener la calidad y cantidad de agua, el equilibrio ecológico y un entorno adecuado para el ecosistema (GOREMAD y IIAP 2009; Ríos et al. 2012; SENAMHI 2015; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021).

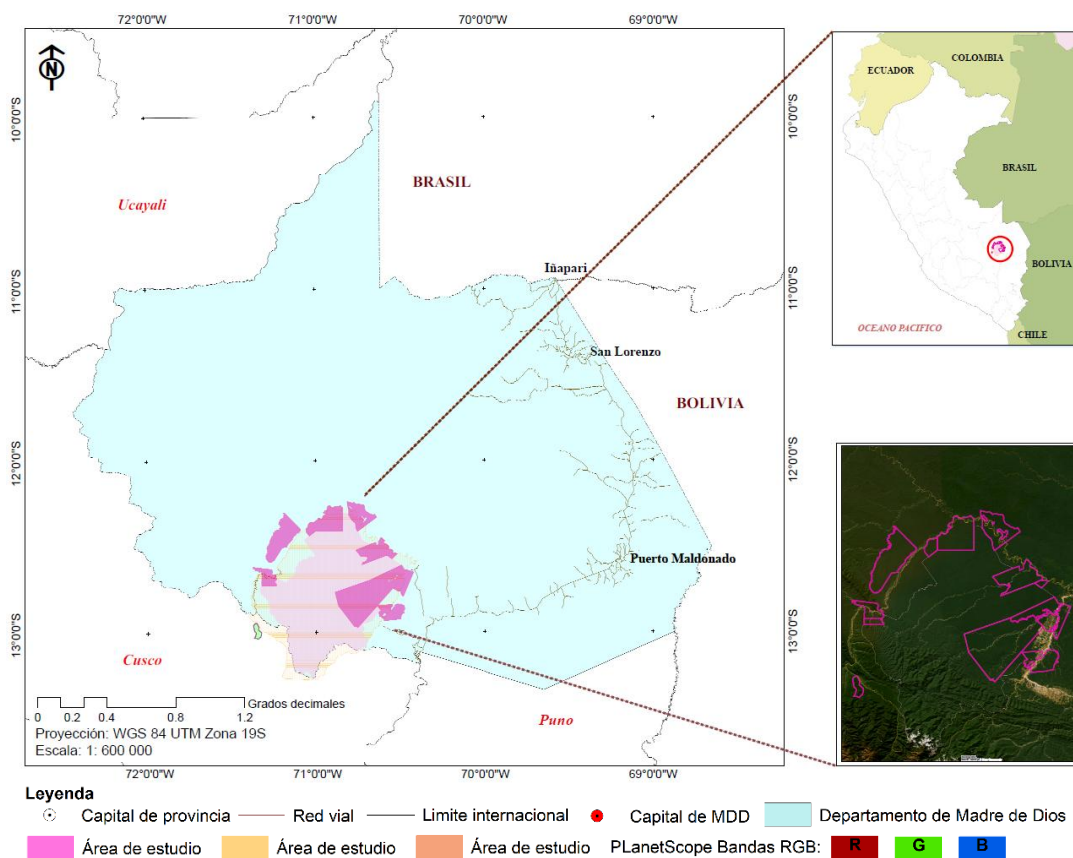


Figura 4. Ubicación del área de estudio, área de influencia de ECA Amarakaeri, Madre de Dios y Cusco – Perú.

La evaluación considero los años 2018 y 2024.

3.4 Población y muestra

El área de influencia del ECA Amarakaeri, que comprende el territorio de diez comunidades indígenas, determino la población. Estas comunidades incluyen ocho comunidades pertenecientes al pueblo Harakbut (Puerto Luz, San José

de Karene, Shintuya, Barranco Chico, Boca Isiriwe, Puerto Azul Mberowe, Masenawa y Queros), una comunidad perteneciente al pueblo Yine (Diamante) y una comunidad perteneciente al pueblo Matsiguenka (Shipetiari), todas las cuales juegan un papel crucial en la preservación de los bosques, los ríos y la cultura viva de estas tres comunidades. De esta manera se considerará como población un área de 1 981,0884 km² (198 108,84 ha).

La validación de datos se realizó con información de campo y con imágenes de alta resolución mediante una distribución de probabilidad binomial (Anaya y Chuvieco 2010; Chuvieco y Hantson 2010; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021), las muestras fueron calculadas con la siguiente ecuación (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%).

$$= \frac{(1,96)^2 * 0,5(0,5 * 198\ 108,84)}{(198\ 108,84 - 1) * 0,05^2 + 1,96^2 * (0,5 * 0,5)}$$

$$n = 383,42 = 383 \text{ puntos de muestreo}$$

La muestra establece un criterio de distribución aleatorio estratificado y considera los requisitos de exclusión e inclusión (Chuvieco 2002; Chuvieco y Hantson 2010; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021).

La distribución correspondió a: Bosque (3) con 80 puntos, Bosque inundable (6) con 80, Zona pantanosa o pastizal inundable (11) con 23, Pastizal / herbazal (12) con 20, Pasto (15) con 20, Agricultura (18) con 20, Mosaico agropecuario (21) con 60, Infraestructura (24) con 20 y Minería (30) con 60.

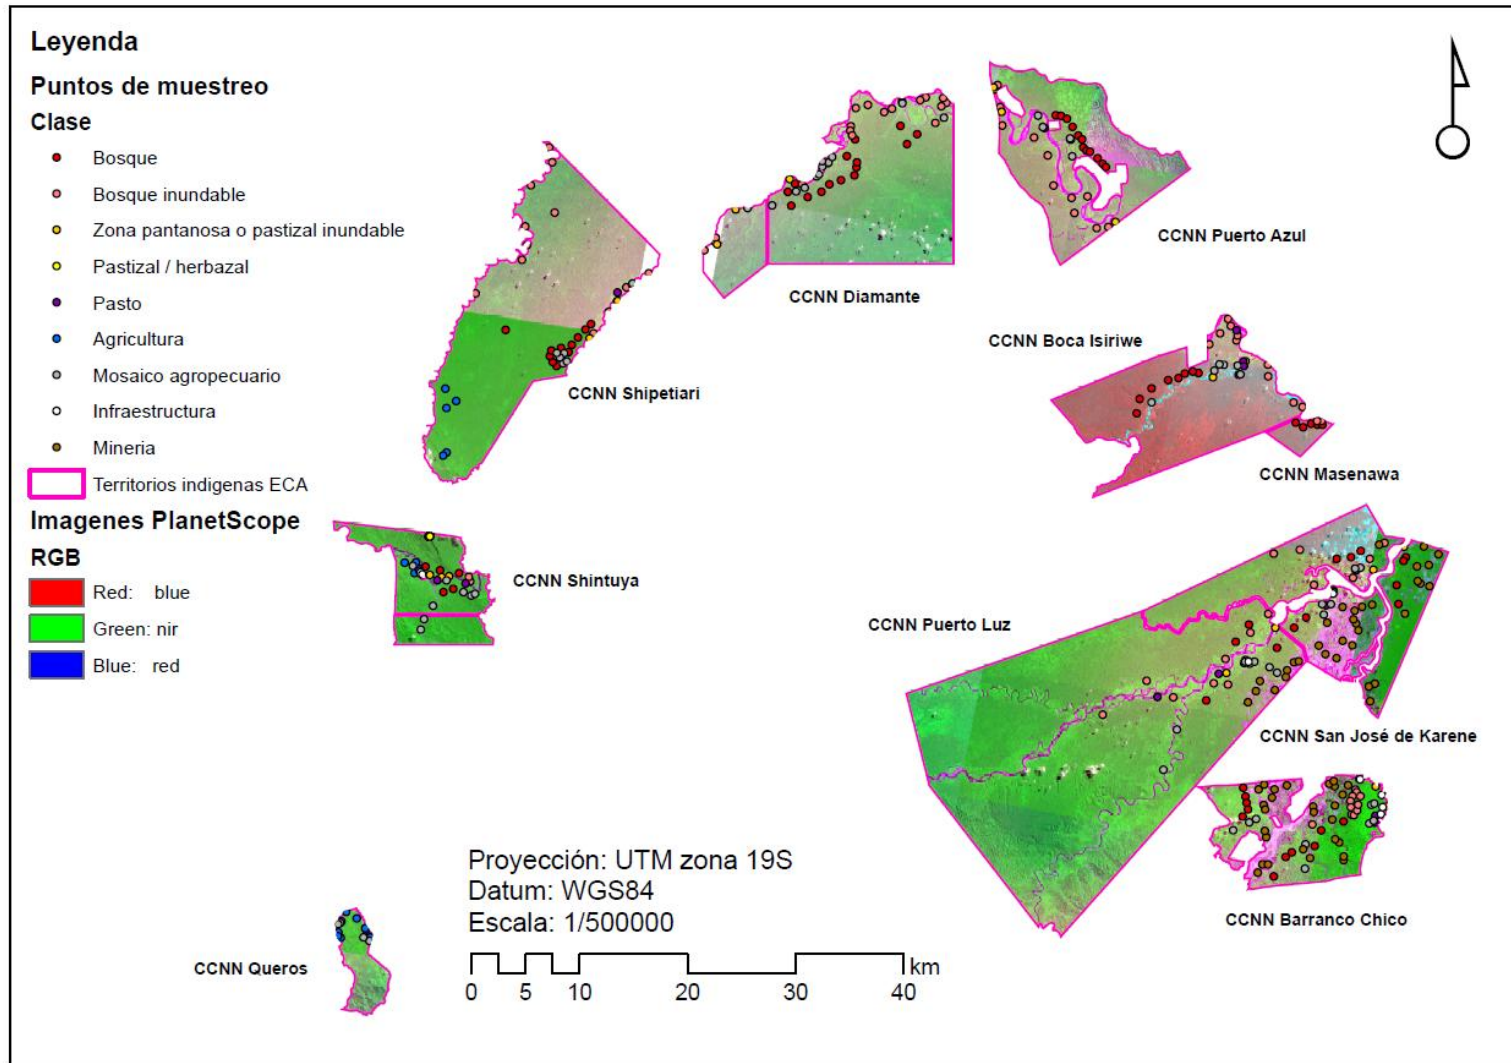


Figura 5.
Distribución de
muestras por
clases con fines
de validación.

3.5 Método y técnicas

Utilizamos imágenes ópticas de Planet (<https://www.planet.com/nicfi/>) para determinar la deforestación mediante el etiquetado de áreas de entrenamiento y procesar con el algoritmo de clasificación y mapear los resultados de la clasificación (Matosak et al. 2022; Wagner et al. 2023). Planet opera las constelaciones de imágenes de la Tierra SkySat y PlanetScope, que contienen 200 satélites (Yang et al. 2023). SkySat es una constelación de 21 satélites de imágenes de la Tierra de alta resolución que se han lanzado gradualmente desde 2013 (<https://www.planet.com/products/>). PlanetScope es una constelación de aproximadamente 130 satélites que pueden obtener imágenes de toda la superficie de la Tierra cada día (capacidad de recopilación de 200 millones de km²/día) (Yang et al. 2023). Las constelaciones tienen una resolución espacial de 0,72 a 0,8 m para SkySat y de 3,7 m para PlanetScope (Francini et al. 2020). Cada satélite proporciona imágenes azules, verdes, rojas e infrarrojas cercanas (NIR) (Francini et al. 2020).

Planet proporciona un producto de escena básico, un producto de escena orto y un producto de mosaico orto, basado en niveles de procesamiento de productos satelitales a través de la Iniciativa Internacional sobre Clima y Bosques de Noruega (NICFI <https://www.planet.com/nicfi/>) a nivel de producto Ortho Tile, que selecciona las mejores imágenes para representar cada parte del área de cobertura (Yang et al. 2023). La resolución varía con la latitud, 4,77 m es la dimensión máxima de píxeles, que se produce en el ecuador. Además, los mapas base del NICFI incorporan algoritmos avanzados de corrección atmosférica y enmascaramiento de nubes, mejorando la calidad de las imágenes (Yang et al. 2023). Seguidamente se elaborará un registro de mosaico multitemporal de PlanetScope, mitigando errores de geometría de 2018 y 2024 en el ámbito del área de estudio.

Los periodos de análisis (2018-2024) fueron definidos en función de la disponibilidad de imágenes PlanetScope sin nubosidad durante la estación seca (junio a septiembre), lo cual garantiza condiciones homogéneas para la comparación temporal. La selección de estos intervalos también responde a

la necesidad de capturar cambios progresivos relacionados con las dinámicas antrópicas en el territorio.

Para llevar a cabo nuestra evaluación se desarrolló en un enfoque de aprendizaje automático que aplicará el modelo de Redes Neuronales (Neural Net, NN, Figura 5) a imágenes de Planet dentro de la plataforma del Software Avanzado en Análisis Geoespacial (ENVI) (Pickering et al. 2021). El flujo de trabajo implicó recopilar imágenes satelitales de cobertura terrestre existentes, construir muestras etiquetadas, desarrollar un clasificador de NN e implementar algoritmos de aprendizaje automático en los que las muestras etiquetadas se separaran en conjuntos de datos de entrenamiento, prueba y comparación de productos en base a la metodología de MAPBIOMAS Perú de cobertura y uso de suelo, colección 2 nivel 2 (Pickering et al. 2021; Wagner et al. 2023). Las áreas de entrenamiento fueron en función a los patrones espaciales de suso y cobertura del suelo caracterizada en los pixeles de la imagen (Zhang et al. 2023).

El rendimiento del clasificador NN se evaluó en función a las áreas de muestreo (Rufin et al. 2022). La evaluación se basó en una matriz de confusión por frecuencia donde se calculó la precisión general e índice de concordancia kappa (k) (Tabla 4) (Cohen et al. 2003; Pickering et al. 2021). Con la finalidad de reducir impactos de las muestras entrenadas, el entrenamiento y las pruebas del modelo la validación se realizó con áreas diferentes (Cohen et al. 2003; Pickering et al. 2021).

La medición de la deforestación, tasas de pérdida, cambios de cobertura y uso de suelo (LULC) de 2018 y 2024 se realizó a través de la diferencia de información ráster de ArcGIS Pro (Ráster Calculator, Ecuación 4) (Puyravaud 2003; INRENA et al. 2006; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022).

3.6 Tratamiento de datos

3.6.1 Procesamiento de datos

Las imágenes de PlanetScope con una resolución espacial de aproximadamente 4 m por píxel fueron la fuente principal de datos para el mapeo de la deforestación en el área de estudio. Se siguió las siguientes fases:

1. Datos: Se procesó en el sistema de proyección World Geodetic System 1984 (WGS 84) zona 19 (Tabla 2). Se utilizó el producto PlanetScope Analytic de 4 bandas, que incluye tres bandas visuales (roja, verde y azul) y una banda de infrarrojo cercano, y está ortorrectificada y calibrada según la radiancia del sensor. Los datos de PlanetScope se obtuvieron mediante el visor de imágenes interactivo de Planet (<https://www.planet.com/explorer>) (Francini et al. 2020; Yang et al. 2023). El catálogo de Planet ofrece la capacidad de cargar una región de interés y buscar en el catálogo según un área objetivo. Durante una búsqueda en el catálogo de Planet para cada área de interés, se consideró una cobertura con la menor cantidad de nubes en la época de menor precipitación (junio a septiembre) (Planet-Team 2024). Nuestras imágenes abarcan las fechas de 2018 y 2024.

Tabla 2. Datos de adquisición del sensor PlanetScope

Fecha	Escenas	Nivel de adquisición	Resolución	Nubosidad
2018	20180928_151250_of33, 20180928_151249_of33, 20180928_151248_of33, 20180928_151243_of33, 20180928_151242_of33, 20180928_151241_of33, 20180928_151240_of33, 20180928_151239_of33, 20180928_143236_103b, 20180928_143235_103b, 20180928_143232_103b, 20180928_143230_103b, 20180928_143229_103b, 20180928_143228_103b, 20180928_143227_103b, 20180928_143226_103b, 20180928_143225_103b, 20180928_143153_of43, 20180928_143152_of43, 20180928_143151_of43, 20180928_143150_of43, 20180928_143148_of43, 20180928_143147_of43, 20180928_143146_of43, 20180928_143144_of43, 20180928_143143_of43, 20180928_143142_of43, 20180928_142954_103d, 20180928_142953_103d, 20180928_142952_103d, 20180928_142951_103d, 20180928_142950_103d, 20180928_142949_103d, 20180928_142948_103d, 20180928_142946_103d, 20180928_142945_103d, 20180928_142945_101b, 20180928_142944_101b,	Analytic de 4 bandas	3 m x 3 m	<10%

	20180928_142943_101b, 20180928_142941_101b, 20180928_142940_101b			
2024	20240804_152209_07_2498, 20240804_152207_22_2498, 20240804_152205_36_2498, 20240804_152203_51_2498, 20240804_152201_65_2498, 20240804_152159_80_2498, 20240804_152157_94_2498, 20240804_152156_09_2498, 20240804_151418_29_24e0, 20240804_151416_18_24e0, 20240804_151414_06_24e0, 20240804_151411_95_24e0, 20240804_151409_83_24e0, 20240804_151407_72_24e0, 20240804_151405_61_24e0, 20240804_150801_18_24f4, 20240804_150758_84_24f4, 20240804_150756_50_24f4, 20240804_150754_16_24f4, 20240804_150751_82_24f4, 20240804_150749_48_24f4, 20240804_150635_03_24d7, 20240804_150632_92_24d7, 20240804_150630_81_24d7, 20240804_150628_70_24d7, 20240804_141600_44_24a7 20240804_141558_19_24a7, 20240804_141555_94_24a7 20240804_141553_69_24a7, 20240804_141551_44_24a7, 20240804_141549_19_24a7	Analytic de 4 bandas	3 m x 3 m	<10%

El uso de imágenes PlanetScope frente a otras fuentes como Sentinel-2 o Landsat se justifica técnicamente por su alta resolución espacial (3-5 m), que permite una detección más precisa y detallada de cambios en la cobertura terrestre a escala local, especialmente en áreas heterogéneas o de pequeño tamaño. A diferencia de Sentinel-2 (10-20 m) o Landsat (30 m), PlanetScope ofrece una frecuencia de revisita diaria, lo que mejora significativamente la capacidad de monitoreo casi en tiempo real y reduce los problemas asociados a la cobertura nubosa en zonas tropicales. Estas ventajas lo convierten en una fuente ideal para estudios que requieren alta resolución temporal y espacial, como la detección de deforestación, monitoreo agrícola o cambios urbanos rápidos (Masolele et al. 2022).

2. Unidad de análisis: Está conformada por el pixel, con una resolución espacial de 3 m x 3 m (Pickering et al. 2021).
3. LULC: Según RAISG (2024) se utilizó la leyenda del Proyecto de “Mapeo Anual de Cobertura y Uso del Suelo en el Perú” que considera 6 categorías (Nivel 2, Tabla 3): formación boscosa, formación natural no boscosa, área agropecuaria, área sin vegetación, cuerpo de agua y no observado.

Tabla 3. Clases de cobertura y uso del suelo del Perú (MAPBIOMAS Colección 2.0)

CLASES	ID
1. Formación boscosa y áreas mayormente naturales	1
1.1. Bosque	3
1.2. Bosque seco	4
1.3. Manglar	5
1.4. Bosque inundable	6
1.5 Zona pantanosa o pastizal inundable	11
1.6 Pastizal / herbazal	12
3. Área agropecuaria	14
3.1. Pasto	15
3.2. Agricultura	18
3.3. Plantación forestal	9
3.4. Palma aceitera	35
3.5. Mosaico agropecuario	21
4. Área sin vegetación	22
4.1. Infraestructura	24
4.2. Minería	30
4.3. Otra área sin vegetación	25
5. Cuerpo de agua	26
5.1. Río, lago u océano	33
5.2. Acuicultura	31
5.3. Glaciar	34
6. No observado	27

Fuente: RAISG (2024).

4. Clasificación: Se obtuvo un conjunto de muestras de entrenamiento específicas de cada año para realizar una clasificación supervisada basada en píxeles (Matosak et al. 2022). Cada punto de muestra de entrenamiento se asignó a una clase LULC (Zhang et al. 2023). Se utilizó el clasificador Neural Net de redes neuronales en el software ENVI.

La clasificación automática de imágenes mediante NN, considero la imagen de entrada basada en un núcleo con un número determinado de neuronas y una capa de submodelado que reduce la salida de la convolución (Prasad et al. 2022). Seguidamente, se llevó a cabo una etapa de reducción de dimensionalidad y selección de características relevantes mediante la capa de conexión total (Malik et al. 2021). Por último, el modelo entrenado utilizo el gradiente estocástico con NN para clasificar a qué clase pertenece una imagen en particular, ajustando los pesos del filtro y reduciendo el error de lectura (Al-Dousari et al. 2023). Para ser más resistentes a la hora de la clasificación automática, los procesos NN necesitan grandes conjuntos de datos de entrenamiento. Si hay un problema con varias clases, también es necesario que los datos de las clases estén equilibrados (Al-Dousari et al. 2023).




Figura 6. Esquema metodológico del proceso de clasificación supervisada Neural Net.

Fuente: Malik et al. (2021).

5. Post clasificación: Se realizo la rectificación y clasificación de cada imagen mediante procesos de comparación de pixel (Jensen et al. 1991; Xiuwan 2002; Alarcón et al. 2016). Se aplico el algoritmo Majority/Minority (kernel de 3×3 y píxel central de 1) con el programa ArcGis Pro 3,2® (Handbook 1994; Mohammadi-Ghazi et al. 2020).

6. Cambios de LULC: La ecuación 2 se utilizó para determinar las diferencias entre las superficies inicial y final, y la matriz determinará los cambios en la LULC (R) (Puyravaud 2003; INRENA et al. 2006; CA 2007; Alarcón et al. 2016; Asner y Tupayachi 2017; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

$$R = (A1 - A2) / (t2 - t1) \quad (\text{Ecuación 2})$$

Donde A2 y A1 son las áreas de bosque en la fecha final (t2) e inicial (t1).

La tasa de variación anual (q) se calculará (Ecuación 3) utilizando la tasa porcentual anual, que se utiliza frecuentemente para cuantificar la pérdida de cobertura (Puyravaud 2003; INRENA et al. 2006; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

$$q = (A1 - A2) \left(\frac{1}{t2 - t1} \right)^{-1} \quad (\text{Ecuación 3})$$

Donde A1, A2, t1, t2 se definen en la Ecuación 3.

Se utilizará una operación de diferencia entre las coberturas de cada periodo (Ecuación 4) para determinar la variación de la cobertura entre 2018 y 2024 (Puyravaud 2003; INRENA et al. 2006; CA 2007; Alarcón et al. 2016; Asner y Tupayachi 2017; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023).

$$\text{Época 2018} * 10 + \text{Época 2024} \quad (\text{Ecuación 4})$$

3.6.3 Precisión de datos clasificados

En el proceso de validación, fue necesario utilizar datos de referencia de mejor resolución espacial. Dado que los mapas de la deforestación se basaron en imágenes de tipo PlanetScope, se utilizó datos de campo para 2024 y para 2018 imágenes de PeruSAT-1 (0,70 m x 0,70 m – 2,8 m x 2,8 m), WorldView (0,38 m x 0,38 m) y dron (0,05 m x 0,05 m) (Elijah y Jensen 1996; Chuvieco 2002; Chuvieco y Hantson 2010; Alarcón et al. 2016; Planet-Team 2022; Planet-Team 2023).




Figura 7. Imágenes de alta resolución para validación de la clasificación de LULC (bosque, bosque inundable, zona pantanosa o pastizal inundable, pastizal / herbazal, pasto, agricultura, mosaico agropecuario, infraestructura y minería. a) PeruSAT-1 (pancromático con 0,70 m y multiespectral con 2,8 m), b) WorldView (0,38 m) y c) Dron (0,05 m).

Fuente: Planet-Team (2025).

El procedimiento de validación se basó en un enfoque de muestreo aleatorio estratificado donde serán comparados con niveles de relación cualitativa

(Tabla 4) (Cohen 1960; Cohen et al. 2003; Cerda y Villarroel 2008; Kuhn y Johnson 2013; Alarcón et al. 2016; Rufin et al. 2022). El número de puntos de validación (n) se definió mediante la ecuación 1.

Se generó una matriz de confusión y se derivó la precisión general ajustada por área y la precisión de usos y productos por clase mediante el método de frecuencia propuesto por Cohen (1960). Con ello, se calcularon las métricas de la precisión general y el coeficiente Kappa (k) (Cohen 1960; Cohen et al. 2003; Cerda y Villarroel 2008; Alarcon-Aguirre et al. 2021; Rufin et al. 2022).

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

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 4. Valores del coeficiente kappa

Coeficiente Kappa	Fuerza de la 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).

El levantamiento de datos en campo siguió la metodología del Centro para el Estudio de Instituciones, Población y Cambio Ambiental (CIPEC) de la

Universidad de Indiana (Moran y Brondizio 1998; Chávez et al. 2013; Alarcón et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022).

3.6.4 Análisis estadístico

El análisis estadístico se desarrolló en marco de los objetivos planteados en la investigación.

Para el primer y segundo objetivo, sobre cuantificar y determinar la deforestación por tipo de actividad productiva en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024, se procesó en la plataforma de los softwares ENVI, Microsof Excel, SigmaPlot 15® y ArcGIS Pro 3,2®.

El tercer objetivo, sobre evaluar la precisión de la clasificación del algoritmo de redes neuronales de los periodos 2018 y 2024, se realizó mediante el uso de los softwares ENVI y ArcGIS Pro 3,2®.

El cuarto objetivo, sobre la caracterización de los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo) en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024, se procesó en la plataforma de los softwares ArcGIS Pro 3,2®, Microsof Excel y SigmaPlot 15®.

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1 Deforestación por tipo de actividades productivas en territorios indígenas del ECA Amarakaeri Madre de Dios

La distribución de la LULC en 2018 (Figura 8-9 y Tabla 5) por tipo de actividades productivas en territorios indígenas del ECA Amarakaeri Madre de Dios, está dominada por el bosque (3) y el bosque inundable (6) con un 94,94% (177 294,89 ha), mientras que las actividades antrópicas que mayor causan deforestación se encuentra la minería (30) con un 2,81% (5 252,96 ha).

Para 2024, la distribución de la LULC (Figura 8-9 y Tabla 5), está dominada por el bosque (3) y el bosque inundable (6) con un 94,02% (175 571,60 ha), mientras que como factor antrópico de mayor deforestación permanece la minería (30) con un 4,13% (7 716,30 ha). En este contexto, la agricultura (18) y el mosaico agropecuario (21) aportan el 1,48% (2 763,51 ha).

A partir de los resultados anteriores (Tabla 5), podemos observar una tendencia en la disminución de la superficie de formación boscosa y áreas mayormente naturales; de 178 716,80 ha en el 2018 a 176 137,13 ha para 2024, traduciéndose en una pérdida de cobertura en 6 años de 2 579,13 ha. Sin embargo, debe considerarse que al inicio de la evaluación (2018) se registra una deforestación de 8 020,31 ha, con aportes de actividades como la de pasto (15) con un 0,80%, agricultura (18) 0,10%, mosaico agropecuario (21) 33,48%, infraestructura (24) 0,13% y minería (30) con 65,50%.

Para 2024, se registra una deforestación de 10 599,44 ha, con aportes de actividades como la de pasto (15) con un 0,96%, agricultura (18) 0,29%, mosaico agropecuario (21) 25,79%, infraestructura (24) 0,17% y minería (30) con 72,80%. Esta última incrementándose en un 7,30%.

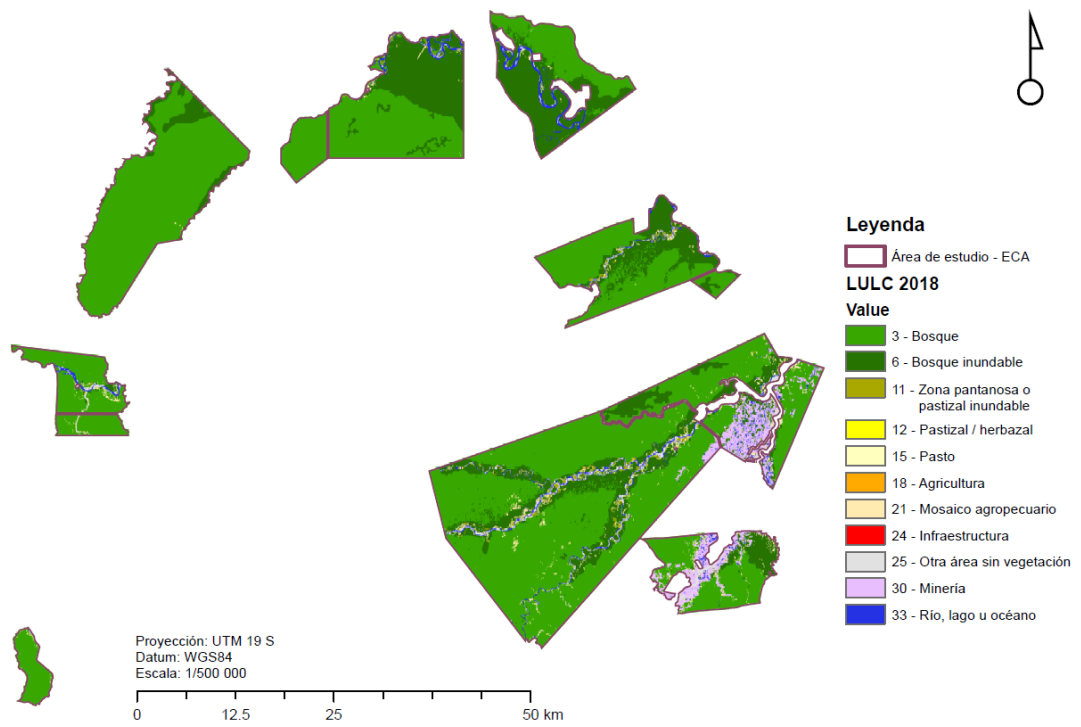


Figura 8. LULC en territorios indígenas del ECA AmaraKaeri Madre de Dios de 2018.

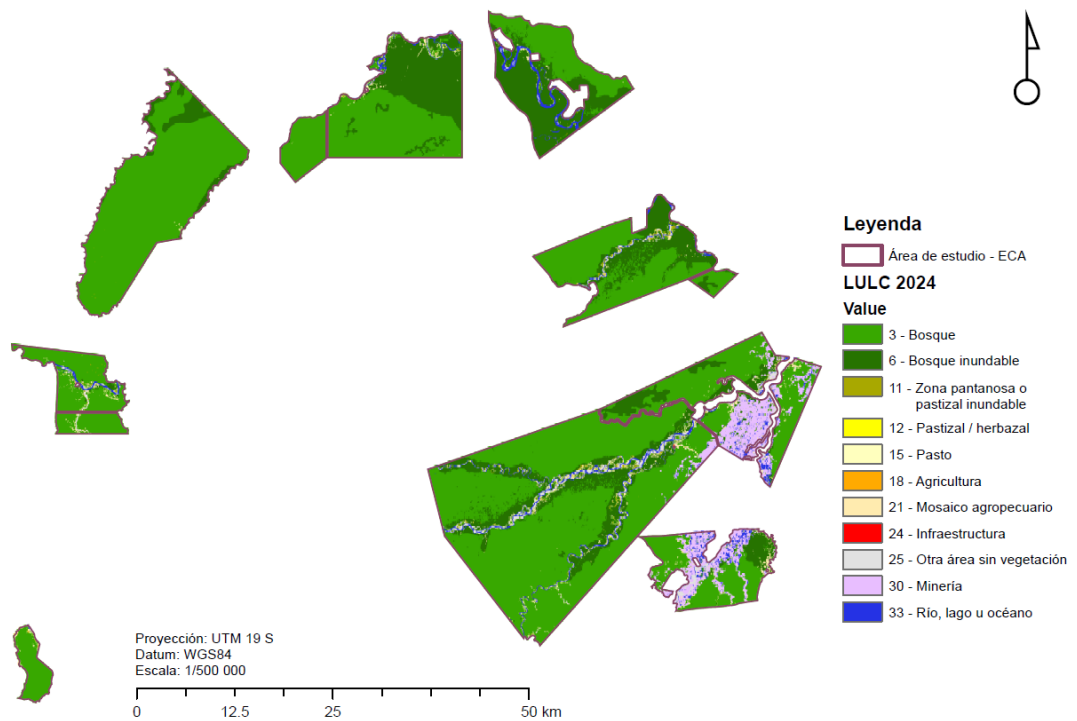


Figura 9. LULC en territorios indígenas del ECA AmaraKaeri Madre de Dios de 2024.

Tabla 5. *LULC en territorios indígenas del ECA Amarakaeri Madre de Dios de 2018 y 2024*

Periodo	Clases (ha)								
	3	6	11	12	15	18	21	24	30
2018	136200,00	41094,90	1421,91	0,00	63,99	7,67	2685,28	10,40	5252,96
2024	135801,25	39770,34	565,53	0,54	102,10	30,44	2733,07	17,54	7716,30

Leyenda: 3= Bosque, 6= Bosque inundable, 11= Zona pantanosa o pastizal inundable, 12= Pastizal / herbazal, 15= Pasto, 18= Agricultura, 21= Mosaico agropecuario, 24= Infraestructura y 30= Minería.

En cuanto a comunidades nativas, presenta a Puerto Luz (58 273,45 ha) como la de mayor extensión y a Masenawa (1 247,92 ha) como la más pequeña. Sin embargo, la superficie no necesariamente es proporcional con la cantidad de bosque y deforestación a nivel porcentual (Tabla 6 y Anexo 4).

Para 2018, el nivel porcentual de presencia de bosque y áreas mayormente naturales comprende a; Barranco Chico con 77,29%, Boca Ishiriwe con 99,29%, Diamante con 99,40%, Masenawa con 99,69%, Puerto Azul con 99,44%, Puerto Luz con 97,74%, Queros con 97,65, San José de Karene con 80,88%, Shintuya con 98,31% y Shipetiare con 99,95%. Mientras a que nivel de deforestación cuantifica a la comunidad nativa de Barranco con Chico con la mayor extensión de 2 493,67 ha (22,71%), seguida de San José de Karene con 3 624,12 ha (19,12%), Puerto Luz con 1 317,24 ha (2,26%) y con la menor extensión a la comunidad de Masenawa con 3,83 ha (0,31%) (Tabla 6 y Anexo 4).

Para 2024, el nivel porcentual de presencia de bosque y áreas mayormente naturales sufre una disminución en cuanto a superficie a excepción de Puerto Azul; Barranco Chico con 68,32%, Boca Ishiriwe con 99,20%, Diamante con 98,81%, Masenawa con 99,44%, Puerto Azul con 99,46%, Puerto Luz con 97,51%, Queros con 94,06%, San José de Karene con 75,19%, Shintuya con 97,10% y Shipetiare con 99,89%. Mientras a que nivel de deforestación cuantifica a la comunidad nativa de Barranco con Chico con la mayor extensión de 3 478,37 ha (31,68%), seguida de San José de Karene con 4 703,46 ha (24,81%), Puerto Luz con 1 449,76 ha (2,49%), y con la menor extensión a la comunidad de Masenawa con 7,01 ha (0,56%) (Tabla 6 y Anexo 4).

Para las comunidades de Barranco Chico, San José de Karene y Puerto Luz la deforestación está dominada por la minería oro y refleja con su realidad actual, comunidades dedicadas mayoritariamente a la actividad minera de oro. Sin embargo, también existe áreas deforestadas en menor proporción por actividades como la agricultura y mosaico agropecuario (Tabla 6 y Anexo 4). Por otro lado, comunidades como Boca Isiriwe, Diamante, Masenawa, Puerto Azul, Queros, Shintuya y Shipetiare la deforestación está afectada por actividades como la pastura, agricultura y mosaico agropecuario (Tabla 6).

Respecto al incremento de cobertura boscosa en la comunidad nativa Puerto Azul, a nivel espacial la deforestación esta influenciada completamente por el mosaico agropecuario, que es mínimo (84,12 ha para 2018 y 81,18 ha para 2024), por consiguiente, se presenta una recuperación del área abandonada (Tabla 6 y Anexo 4). Asimismo, podemos inferir que la comunidad de Puerto Azul titulada en la última década, es una comunidad peculiar, donde sus habitantes son perecientes de otras comunidades que se han traslado para formar Puerto Azul, donde un grupo considerable son flotantes, es decir radican en la ciudad y temporalmente se trasladan a la comunidad.

Tabla 6. *LULC por comunidades nativas del ECA Amarakaeri Madre de Dios de 2018*

Comunidad Nativa	Clases (ha)								Total
	3	6	11	15	18	21	24	30	
Barranco Chico	6599,96	1864,19	20,43	1,87	0,00	528,93	0,00	1962,88	10978,26
Boca Ishiriwe	11001,89	5475,63	204,38	1,38	0,00	118,53	0,00	0,00	16801,81
Diamante	15561,99	9164,18	175,08	2,33	0,00	148,56	0,00	0,00	25052,13
Masenawa	920,99	322,71	0,40	3,70	0,00	0,13	0,00	0,00	1247,92
Puerto Azul	6290,65	8702,00	32,71	0,00	0,00	84,12	0,00	0,00	15109,47
Puerto Luz	47369,25	8747,51	839,45	0,00	0,00	938,27	3,99	374,97	58273,45
Queros	2805,74	0,00	0,00	43,87	3,74	19,92	0,00	0,00	2873,26
San José de Karene	11278,80	3966,57	84,76	9,53	0,00	696,33	3,15	2915,12	18954,26
Shintuya	8139,14	177,22	58,56	1,31	3,94	135,36	3,26	0,00	8518,80
Shipetiare	26231,59	2674,88	6,13	0,00	0,00	15,14	0,00	0,00	28927,74

Leyenda: 3= Bosque, 6= Bosque inundable, 11= Zona pantanosa o pastizal inundable, 12= Pastizal / herbazal, 15= Pasto, 18= Agricultura, 21= Mosaico agropecuario, 24= Infraestructura y 30= Minería.

Tabla 7. *LULC por comunidades nativas del ECA Amaraeri Madre de Dios de 2024*

Comunidad Nativa	Clases (ha)									
	3	6	11	12	15	18	21	24	30	Total
Barranco Chico	6125,02	1366,76	8,11	0,00	3,07	0,00	479,80	0,00	2995,49	10978,26
Boca Ishiriwe	11083,72	5460,73	123,72	0,00	0,05	0,00	133,59	0,00	0,00	16801,81
Diamante	15622,43	9083,35	48,51	0,00	29,95	0,00	267,90	0,00	0,00	25052,13
Masenawa	921,62	319,29	0,00	0,00	2,38	0,00	4,63	0,00	0,00	1247,92
Puerto Azul	6340,64	8645,25	42,41	0,00	0,00	0,00	81,18	0,00	0,00	15109,47
Puerto Luz	47705,86	8851,54	266,29	0,00	1,80	0,00	882,54	7,83	557,59	58273,45
Queros	2702,45	0,00	0,00	0,00	56,59	27,07	87,15	0,00	0,00	2873,26
San José de Karene	10994,26	3223,06	33,48	0,00	6,20	0,00	527,98	6,07	4163,21	18954,26
Shintuya	8079,99	157,82	34,16	0,54	2,05	3,37	237,23	3,64	0,00	8518,80
Shipetiare	26225,27	2662,55	8,85	0,00	0,00	0,00	31,07	0,00	0,00	28927,74

Leyenda: 3= Bosque, 6= Bosque inundable, 11= Zona pantanosa o pastizal inundable, 12= Pastizal / herbazal, 15= Pasto, 18= Agricultura, 21= Mosaico agropecuario, 24= Infraestructura y 30= Minería.

Este estudio presenta un marco para el mapeo de paisajes complejos de territorios indígenas del ECA Amaraeri Madre de Dios con una resolución de 3 m utilizando datos de PlanetScope. Se combinó técnicas de preprocesamiento de vanguardia (redes neuronales) para crear mapas de LULC y determinar la deforestación. El marco de preprocesamiento para los mosaicos de PlanetScope produjo características de imagen consistentes, espacialmente detalladas y temporalmente precisas, listas para el análisis en una región con alta propensión a las nubes que en muchos casos se presenta desafiante. La creación de valores de reflectancia e índice de la mediana estacional mitigó la presencia de nubes y remanentes de sombras nubosas (Pickering et al. 2021; Masolele et al. 2022; Matosak et al. 2022; Wagner et al. 2023).

Los mapas resultantes mejoran sustancialmente los enfoques existentes en términos de resolución espacial y detalle temático, con precisiones en línea con o superiores a las de los enfoques anteriores sobre el mapeo de LULC en la Amazonia (Pickering et al. 2021; Masolele et al. 2022; Matosak et al. 2022; Wagner et al. 2023).

La comparación de los productos de LULC globales y regionales reveló una variación sustancial en la extensión total de la cobertura (Pickering et al.

2021). Si bien las discrepancias entre el año objetivo de nuestro estudio y las de los productos existentes pueden contribuir a las diferencias observadas, la interacción entre la resolución espacial o las unidades mínimas de mapeo, los métodos de producción, la cobertura espacial y, en consecuencia, las diferentes definiciones de clase, sin duda desempeñan un papel clave en las diferencias observadas (Pickering et al. 2021; González-Fernández et al. 2022; Matosak et al. 2022). La alta cadencia de las adquisiciones de Planet garantiza la inclusión de perturbaciones a corto plazo. La resolución de los datos de PlanetScope permite un mapeo más discreto de los campos espacialmente heterogéneos a pequeña escala de los territorios indígenas y de la dinámica de LULC, en comparación con los mapas existentes de 10 m, 20 m y 30 m de resolución utilizados para la clasificación (Pickering et al. 2021; González-Fernández et al. 2022; Matosak et al. 2022; Zhang y Li 2022; Zhang et al. 2023).

El conocimiento sobre la deforestación, específicamente en territorios indígenas del ECA AmaraKaeri es escaso, la mayoría está enfocado a un contexto regional, cuenca, microcuenca, provincial o distrital. Los resultados evidencian un incremento en superficie de actividades de 2018-202, como pasto (15) con un 59,55%, agricultura (18) 296,69%, mosaico agropecuario (21) 1,78%, infraestructura (24) 68,58% y minería (30) con 46,89%. Resultados que concuerdan a nivel de tendencia por investigadores locales e internacionales como Alarcón et al. (2016); Alarcon-Aguirre et al. (2021); Alarcon-Aguirre et al. (2023); Asner et al. (2013); Asner y Tupayachi (2017); Caballero et al. (2018); Chávez et al. (2013); Perz et al. (2013); Pickering et al. (2021); Swenson et al. (2011); Zhang et al. (2023).

Adicionalmente, el monitoreo de la deforestación es un área en la que la resolución de las imágenes satelitales puede desempeñar un papel importante. La deforestación que ocurre a una escala que históricamente ha sido difícil de mapear. Las imágenes de Planet nos brindan la capacidad de monitorear eventos de cambio de cobertura terrestre que son por definición temporales y a menudo no visibles en los datos Landsat debido a las limitaciones espaciales y temporales (Pickering et al. 2021; González-

Fernández et al. 2022; Matosak et al. 2022; Zhang y Li 2022; Alarcon-Aguirre et al. 2023; Zhang et al. 2023).

4.2 Tasa de deforestación

El análisis espacio-temporal de 2018-2024 mostró una tasa anual de cambio (q) de -0,24% y una deforestación total anual promedio (r) de 429,95 ha/año (Tabla 8). Donde la minería de oro es la actividad principal que genera mayor deforestación en el territorio de las comunidades indígenas del ECA Amarakaeri (Tabla 5), seguida del mosaico agropecuario, agricultura y pastos.

Tabla 8. *Tasa y deforestación anual promedio LULC en territorios indígenas del ECA Amarakaeri Madre de Dios*

Periodo	Tasa anual de cambio (%)	Deforestación total anual promedio (ha) (r)
2018-2024	-0,24	429,95

A nivel de comunidades nativas, Barranco Chico y San José de Karene presentan una tasa anual de cambio (q) de -2,04% y -1,21% respectivamente con una deforestación total anual promedio (r) de 164,12 ha/año y 179,89 ha/año (Tabla 9). Mientras que, en el caso de Puerto Luz, con una tasa anual de cambio (q) de -2,04% y una deforestación total anual promedio (r) de 22,09 ha/año, la cuantificación se minimiza por la gran extensión que presenta. Sin embargo, en los datos son superiores al promedio anual (-0,24% y 429,95 ha/año). Para todos los casos, la deforestación está dominada por la minería oro y refleja con su realidad actual, comunidades dedicadas mayoritariamente de actividad minera de oro. En menor medida, la deforestación también se atribuye a actividades agrícolas presentes a manera de mosaicos en el área de estudio.

Por otro lado, comunidades como Boca Isiriwe, Diamante, Masenawa, Puerto Azul, Queros, Shintuya y Shipetiare la tasa anual de cambio y deforestación anual promedio está afectada por actividades como la pastura, agricultura y

mosaico agropecuario (Tabla 9). En este contexto, Queros, la penúltima comunidad nativa más pequeña del ECA Amarakaeri presenta una tasa anual de cambio (q) de -0,62% y una deforestación total anual promedio (r) de 17,22 ha/año, donde la deforestación está relacionada a la conversión de bosques a áreas de pasturas, agricultura y mosaico agropecuario.

Un caso inusual es de la comunidad nativa Puerto Azul, donde presente una tasa anual de cambio (q) de 0,003% con una deforestación total anual promedio (r) de -0,49 ha/año (Tabla 9). El incremento de cobertura boscosa en la comunidad nativa Puerto Azul, es producto del abandono de áreas del mosaico agropecuario que vienen recuperándose.

Tabla 9. *Tasa y deforestación anual promedio por comunidades nativas del ECA Amarakaeri Madre de Dios*

Comunidad Nativa	Periodo	Tasa anual de cambio (%)	Deforestación total anual promedio (ha) (r)
Barranco Chico	2018-2024	-2,04	164,12
Boca Ishiriwe	2018-2024	-0,01	2,29
Diamante	2018-2024	-0,10	24,49
Masenawa	2018-2024	-0,04	0,53
Puerto Azul	2018-2024	0,003	-0,49
Puerto Luz	2018-2024	-0,04	22,09
Queros	2018-2024	-0,62	17,22
San José de Karene	2018-2024	-1,21	179,89
Shintuya	2018-2024	-0,21	17,16
Shipetiare	2018-2024	-0,01	2,66

Los bosques y áreas mayormente naturales sufre una presión frecuente para usos de minería aurífera, agricultura, mosaico agropecuario y pasturas (Perz et al. 2016; Alarcón et al. 2021). Por lo que su evaluación, implica el monitoreo mediante la aplicación de tecnologías de sensoramiento remoto (Pickering et al. 2021; González-Fernández et al. 2022; Matosak et al. 2022; Zhang y Li 2022; Alarcon-Aguirre et al. 2023; Zhang et al. 2023).

En el área de estudio, la minería de oro y la agricultura son las que ejercen una mayor presión sobre los bosques en territorios indígenas del ECA Amarakaeri. Los resultados se asemejan a lo obtenido por científicos e instituciones peruanas y extranjeras. Por ejemplo MINAM (2024) calculó una tasa anual de cambio (q) de -0,15% con una deforestación total anual promedio (r) de 4 083,65 ha/año. Por otro lado, autores como Alarcon-Aguirre et al. (2023); Wagner et al. (2023); Alarcón et al. (2021) y Alarcón et al. (2016) evaluaron la dinámica LULC en los bosques de la Amazonia, la Amazonia de Madre de Dios así como también en concesiones forestales no maderables. En términos espaciales, si bien la cuantificación de la deforestación total y la deforestación total anual promedio no coinciden por corresponder a áreas de estudios con diferente superficie, en términos de tasa anual de cambio son coincidentes.

En el territorio de las comunidades indígenas del ECA Amarakaeri se han deforestado 2 579,67 ha en un periodo de 6 años, lo que constituye una pérdida mínima en comparación con otros ámbitos de la región de Madre de Dios, la Amazonia del Perú (Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023) y la cuenca amazónica en general (Vijay et al. 2018; Aik y Ismail 2020; González-Fernández et al. 2022; Wagner et al. 2023; Zhang et al. 2023). En el área de estudio, la minería de oro es la principal causante de la deforestación (Alarcón et al. 2016; Caballero et al. 2018). Sin embargo, no se puede desestimar la amenaza que representa la agricultura para los bosques. La expansión de zonas para la agricultura y las pasturas son actividades que incrementan la deforestación, estos hallazgos han sido corroborados por otros científicos (Alarcón et al. 2016; Vijay et al. 2018; Aik y Ismail 2020; Alarcon-Aguirre et al. 2021; González-Fernández et al. 2022; Alarcon-Aguirre et al. 2023; Wagner et al. 2023; Zhang et al. 2023).

4.3 Evaluación de precisión

Para el año 2018, se determinó una precisión global a través de un análisis de una matriz de confusión que arrojó un porcentaje del 87,30% y una concordancia de kappa de 0,848, lo cual fue clasificado como un nivel de

precisión "Casi perfecta" según se muestra en la Tabla 4. Para el año 2024, se reportó una fiabilidad del 89,30% y una concordancia de 0,873, categorizado como "Casi perfecta" (Tabla 4) (Cohen 1960; Cohen et al. 2003). Esto proporciona una clara indicación del nivel más alto de concordancia entre la categoría establecida por el usuario y la categoría mencionada, como resultado de la alta resolución de las imágenes de satélite PlanetScope.

Tabla 10. *Matriz de confusión y concordancia de kappa de imágenes de alta resolución frente a imágenes clasificadas de PlanetScope de 2018*

Clases		Imágenes									f_{LULC} PlanetScope
		3	6	11	12	15	18	21	24	30	
LULC PlanetScope (2018)	3	68 (16)	8	5							81
	6	5	67 (17)	5				4			81
	11		3	18 (2)			1	2			24
	12				0						0
	15					16 (1)					16
	18						17 (1)	2			19
	21						4	58 (12)			62
	24							2	18 (1)	2	22
	30								3	55 (9)	58
	f_{PCxl}	73	78	28	0	16	22	68	21	57	363
$f_o=$	317			$f_c=$ 59							
$k=$	0,848			$k_M=$ 1,274							
$\sigma_k=$	0,0209			$\sigma_{k_o}=$ 0,0232							
$Z=$	36,549			Matriz de confusión= 0,873							

Las muestras escogidas de manera aleatoria durante el proceso de validación ($n=363$) en 2018 (Tabla 10) demostraron ser pertinentes para evaluar la deforestación mediante LULC. Los datos recogidos fueron examinados de acuerdo a un criterio de frecuencias periódicas (Cohen 1960; Cohen et al. 2003; Yaghoobi et al. 2019).

Con un valor de constante k igual a 0,848, se puede verificar de manera concluyente que una proporción mayoritaria de las muestras verificadas se encuentran en acuerdo con los datos de LULC, los cuales fueron obtenidas de imágenes de satélite PlanetScope. El valor de la constante k_M es

equivalente a 1,274, por lo que una porción considerable de las discrepancias se atribuye a diferencias marginales que podrían potencialmente afectar los resultados definitivos de manera significativa. El 95 por ciento de las probabilidades indican que el valor de x , considerado como parámetro poblacional, se sitúa dentro del intervalo comprendido entre 0,807 y 0,889 (Cohen 1960; Cohen et al. 2003; Feizizadeh et al. 2022). El valor de z (36,549) presenta un elevado nivel de significancia estadística, que respalda esta concordancia con una probabilidad que no supera $(P) < 0,001$ (Tabla 10), lo cual conlleva la confrontación entre un parámetro hipotético de la población y un valor estadístico observado (Yaghoobi et al. 2019; Pickering et al. 2021; Feizizadeh et al. 2022; Koley y Chockalingam 2022).

Tabla 11. *Matriz de confusión y concordancia de kappa de datos de campo e imágenes de alta resolución frente a imágenes clasificadas de PlanetScope de 2024*

Clases		Datos de campo									f_{LULC} PlanetScope
		3	6	11	12	15	18	21	24	30	
LULC PlanetScope (2024)	3	72 (17)	8	2							82
	6	5	66 (16)	4				1			76
	11		2	19 (2)			1	4			26
	12				18 (1)	2					20
	15					17 (1)					17
	18						18 (1)	2			20
	21						3	57 (11)			60
	24							1	18 (1)	3	22
	30								3	57 (10)	60
	f_{PCxI}	77	76	25	18	19	22	65	21	60	383
$f_o =$	342			$f_c =$						60	
$k =$	0,873			$k_M =$						1,130	
$\sigma_k =$	0,0187			$\sigma_{k_o} =$						0,0220	
$z =$	39,593			Matriz de confusión =						0,893	

Las muestras escogidas de manera aleatoria durante el proceso de validación ($n=383$) en 2024 (Tabla 11) demostraron ser pertinentes para evaluar la deforestación mediante LULC. Los datos recogidos fueron examinados de

acuerdo a un criterio de frecuencias periódicas (Cohen 1960; Cohen et al. 2003; Yaghobi et al. 2019).

Con un valor de constante k igual a 0,873, se puede verificar de manera concluyente que una proporción mayoritaria de las muestras verificadas se encuentran en acuerdo con los datos de LULC, los cuales fueron obtenidas de imágenes de satélite PlanetScope. El valor de la constante k_M es equivalente a 1,130, por lo que una porción considerable de las discrepancias se atribuye a diferencias marginales que podrían potencialmente afectar los resultados definitivos de manera significativa. El 95 por ciento de las probabilidades indican que el valor de x , considerado como parámetro poblacional, se sitúa dentro del intervalo comprendido entre 0,836 y 0,910 (Cohen 1960; Cohen et al. 2003; Feizizadeh et al. 2022). El valor de z (39,593) presenta un elevado nivel de significancia estadística, que respalda esta concordancia con una probabilidad que no supera $(P) < 0,001$ (Tabla 10), lo cual conlleva la confrontación entre un parámetro hipotético de la población y un valor estadístico observado (Yaghobi et al. 2019; Pickering et al. 2021; Feizizadeh et al. 2022; Koley y Chockalingam 2022).

4.4 Caracterización de los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo)

Los resultados reportan una tendencia leve pero creciente de la deforestación en territorios indígenas del ECA Amarakaeri. El periodo analizado de cambio de bosque y áreas mayormente naturales mostraron una cuantificación para 2018-2024 de 178 800,15 ha a 177 628,91ha. Traduciéndose en una deforestación inicial de 7 936,97 a una final de 9 107.66 ha (Figura 10 y Tabla 12).

El motor de cambio de LULC de los bosques en el territorio de las comunidades del ECA Amarakaeri a otros usos es la minería de oro, seguido de la agricultura (agricultura y mosaico agropecuario) y la pastura (Figura 10 y Tabla 12).

En cuanto a la persistencia, se tiene a bosque (3) con 135 468,55 ha, bosque inundable (6) con 38 809,02 ha, zona pantanosa o pastizal inundable (11) con 359.56 ha, pasto (15) con 22.00 ha, agricultura (18) con 1,98 ha, mosaico agropecuario (21) con 637,12 ha, infraestructura (24) con 10,74 ha y minería (30) con 4 625,31 ha (Figura 9 y Tabla 12). La pérdida de bosque por deforestación presenta un incremento constante en el periodo analizado, salvo situaciones peculiares como en la comunidad nativa Puerto Azul.

Esta tendencia, género que de 2018-2024 las áreas de pasto (15) aumentara en un 58,91%, agricultura (18) con 278,19%, mosaico agropecuario (21) con 1,66%, infraestructura (24) con 59,23% y minería (30) con un 20,49% (Figura 9). No obstante, el análisis espaciotemporal de LULC revela la presencia de reducidas extensiones con vegetación inicial, tanto arbustiva como arbórea, en terrenos agrícolas abandonados que están experimentando un proceso de regeneración. Estas áreas abarcan aproximadamente 2,04 ha y se localizan puntualmente en la comunidad autóctona de Puerto Azul.

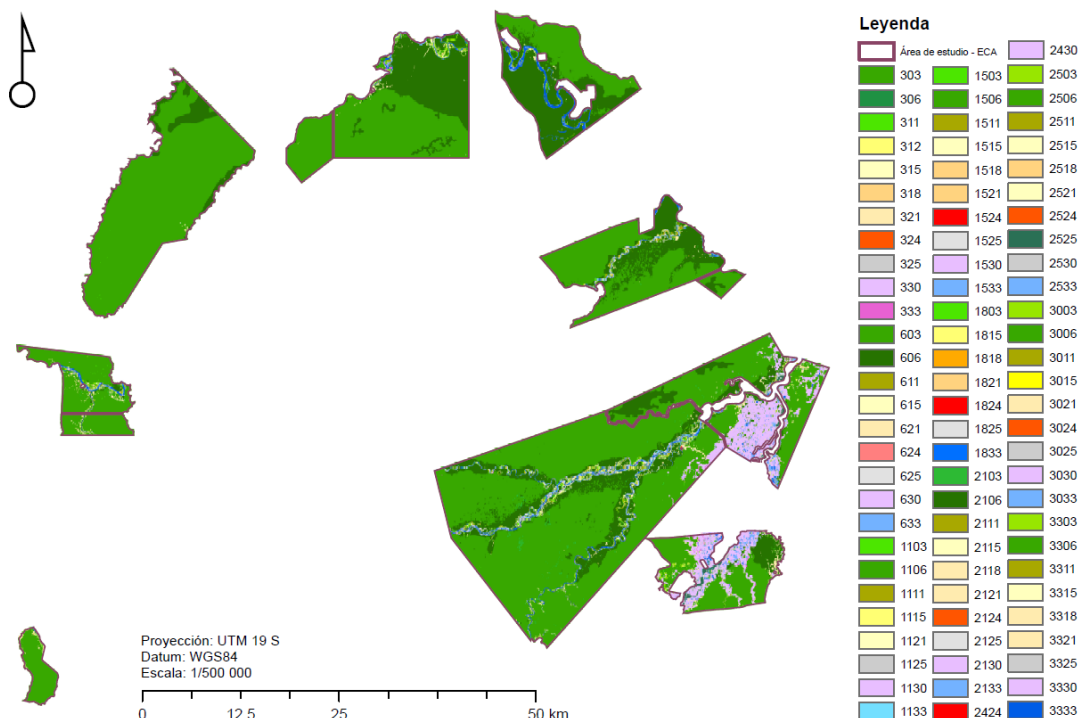


Figura 10. Cambios de LULC como patrones de deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios, 2018-2024.

Como se esperaba, la cuantificación del cambio espacial provocado por la actividad minera de oro, la expansión de la agricultura y la ganadería se manifestó con una mayor incidencia en las zonas cercanas a las infraestructuras de acceso (Southworth et al. 2011; Perz et al. 2013; Alarcón et al. 2016; Perz et al. 2016; Alarcón et al. 2021).

Tabla 12. *Cambios de LULC como patrones de deforestación en territorios indígenas del ECA Amaraeri Madre de Dios, 2018-2024*

Clases		Año 2024 (ha)									Total
		3	6	11	12	15	18	21	24	30	
Año 2018 (ha)	3	135468,55	12,14	97,20	0,54	39,42	17,63	780,08	0,23	0,00	136415,79
	6	342,22	38809,02	85,46	0,00	11,24	0,00	763,07	0,00	989,15	41000,17
	11	371,06	259,85	359,56	0,00	0,00	0,00	371,21	0,00	22,50	1384,18
	12	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	15	15,32	0,18	0,00	0,00	22,00	8,38	16,16	0,00	2,38	64,41
	18	2,04	0,00	0,00	0,00	1,17	1,98	2,64	0,18	0,00	8,00
	21	863,11	551,13	3,87	0,00	25,48	2,27	637,12	5,33	592,91	2681,23
	24	0,00	0,00	0,00	0,00	0,00	0,00	0,00	10,74	0,00	10,74
	30	309,11	75,94	3,13	0,00	3,05	0,00	155,43	0,62	4625,31	5172,59
	Total	137371,41	39708,27	549,23	0,54	102,36	30,26	2725,70	17,10	6232,25	186737,11

El mapa de cambios de LULC muestra que los patrones de la deforestación en territorios indígenas del ECA Amaraeri sigue siendo los mismos (minería de oro, agricultura y ganadería) y que los frentes de deforestación están activos (Figura 9), estos hallazgos coinciden con estudios previos desarrollados en la cuenca Amazónica incluido la Amazonia de Madre de Dios (Perz et al. 2013; Alarcón et al. 2016; Perz et al. 2016; Caballero et al. 2018; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2023). Nuestras cifras muestran que la deforestación sigue aumentando a un ritmo preocupante, con una tasa anual de cambio de -0,24% y deforestación total anual promedio de 429,95 ha (Gregory Paul et al. 2009; Perz et al. 2013; Alarcón et al. 2016; Perz et al. 2016; Asner y Tupayachi 2017; Caballero et al. 2018; Vijay et al. 2018; Alarcon-Aguirre et al. 2021; Matosak et al. 2022; Alarcon-Aguirre et al. 2023; Zhang et al. 2023; RAISG 2024). Sin embargo, también debemos considerar

la barrera que representa la Reserva Comunal Amarakeri, el Parque Nacional de Manu y sus áreas de amortiguamiento para el avance de la deforestación.

Los patrones espaciales observaron varios tipos de cambios en la LULC, desde la deforestación a pequeña escala hasta la deforestación a gran escala (Alarcon-Aguirre et al. 2021; Pickering et al. 2021; Alarcon-Aguirre et al. 2023). La deforestación observada en el área de estudio está relacionada principalmente con la minería de oro (Asner et al. 2009; Swenson et al. 2011; Asner y Tupayachi 2017; Caballero et al. 2018; Alarcon-Aguirre et al. 2021), la agricultura (Vijay et al. 2018; Matosak et al. 2022; Walker et al. 2022; Alarcon-Aguirre et al. 2023; Wagner et al. 2023; Zhang et al. 2023) y la ganadería (Alarcón et al. 2016; Cabral et al. 2024). Los cambios de LULC también registraron bosques en regeneración, básicamente áreas abandonadas por la agricultura (González-Fernández et al. 2022).

Finalmente, el estudio demuestra el potencial de mapear la deforestación con imágenes PlanetScope con una resolución espacial de 4 m, con una fiabilidad superior a lo obtenido con imágenes Landsat.

CONCLUSIONES

Se cuantificó una superficie de formación boscosa y áreas mayormente naturales para el periodo inicial (2018) de 178 716,80 ha a 176 137,13 ha para 2024, la deforestación paso de 8 020,31 ha a 10 599,44 ha, en 6 años de evaluación, la deforestación se incrementó en 2 579,13 ha. Siendo la mayor responsable la minería de oro con un 65,50% en el 2018 y 72,80% en el 2024. A nivel de deforestación en comunidades nativas, en ambos periodos cuantifica a Barranco con Chico, San José de Karene y Puerto Luz como las mayores afectadas por la minería de oro. Mientras que en comunidades como Boca Isiriwe, Diamante, Masenawa, Puerto Azul, Queros, Shintuya y Shipetiare la deforestación está afectada por actividades como la pastura, agricultura y mosaico agropecuario.

La pérdida de cobertura boscosa en el periodo de 2018-2024 mostró una tasa anual de cambio (q) de -0,24% y una deforestación total anual promedio (r) de 429,95 ha/año. Respecto a comunidades nativas, Barranco Chico, San José de Karene y Puerto Luz presentan una tasa anual de cambio (q) de -2,04%, -1,21% y -2,04% con una deforestación total anual promedio (r) de 164,12 ha/año, 179,89 ha/año y 22,09 ha/año, en todos los casos los datos son superiores al promedio anual general.

Para los años 2018 y 2024, se determinó una precisión global a través de un análisis de una matriz de confusión que arrojó un valor de 87,30% y 89,30%, respectivamente. La concordancia de kappa reportó una fiabilidad de 0,848 y 0,873, categorizada como "Casi perfecta".

El cambio de LULC cuantifica a la clase de bosque y áreas mayormente naturales con 178 800,15 ha para 2018 y con 177 628,91ha para 2024. Traduciéndose en una deforestación inicial de 7 936,97 a una final de 9 107.66 ha. Esta tendencia, género que de 2018-2024 las áreas de pasto (15) aumentara en un 58,91%, agricultura (18) con 278,19%, mosaico agropecuario (21) con 1,66%, infraestructura (24) con 59,23% y minería (30) con un 20,49%.

Se rechaza la hipótesis nula y se acepta la alterna, donde los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo) presenta una relación significativa con las actividades antrópicas en territorios indígenas del ECA Amarakaeri Madre de Dios durante los periodos 2018 y 2024 a partir de imágenes PlanetScope.

La metodología empleada, basada en el análisis multitemporal de imágenes PlanetScope y la clasificación de LULC, demostró ser efectiva para detectar y cuantificar con alta precisión los cambios inducidos por actividades antrópicas en territorios indígenas del ECA Amarakaeri. Su alta resolución espacial y temporal permitió una evaluación detallada y actualizada de los procesos de deforestación, incluso en zonas de pequeña escala. Además, el enfoque estructurado y el uso de matrices de transición para establecer umbrales de cambio aseguran la trazabilidad y reproducibilidad del análisis. Esta metodología puede ser fácilmente replicada en otras áreas con condiciones similares, convirtiéndose en una herramienta valiosa para la gestión territorial, la toma de decisiones y la vigilancia ambiental en contextos de alta vulnerabilidad socioecológica.

SUGERENCIAS

Es imperativo que las futuras indagaciones en torno al monitoreo de la Amazonia se realicen utilizando imágenes como PlanetScope u otros de alta resolución, dado que dichas imágenes se originan de una constelación de satélites que registran datos diariamente con una resolución de 3 a 5 m. Dado que facilitaría la identificación de cambios menores y recientes en la cobertura forestal, tales como nuevas trochas o zonas taladas ilegalmente, antes de su expansión, este aspecto es fundamental. Además, su frecuencia diaria es ideal para una zona como la Amazonía, donde las nubes son un problema continuo para otros satélites ópticos. Además, permitiría la ejecución de estudios casi en tiempo real, lo cual es fundamental para la decisión rápida en materia de conservación o control. La consistencia y la amplitud de PlanetScope ayudan a crear series temporales robustas para la comprensión de tendencias y patrones de deforestación.

REFERENCIAS BIBLIOGRÁFICAS

AIK, D. H. J. Y ISMAIL, M. H. Detection of deforestation and analysis land conversion from high resolution satellite imageries in Bintulu District, Serawak, Malaysia. IOP Conference Series: Earth and Environmental Science, 2020/08/01 2020, 561(1), 012010. doi:10.1088/1755-1315/561/1/012010

AL-DOUSARI, A. E., MISHRA, A. Y SINGH, S. Land use land cover change detection and urban sprawl prediction for Kuwait metropolitan region, using multi-layer perceptron neural networks (MLPNN). The Egyptian Journal of Remote Sensing and Space Science, 2023/08/01/ 2023, 26(2), 381-392. doi:<https://doi.org/10.1016/j.ejrs.2023.05.003>

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, 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>

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, 2010.

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

ASNER, G. P., LLACTAYO, W., TUPAYACHI, R. Y LUNA, E. R. Elevated rates of gold mining in the Amazon revealed through high-resolution monitoring. *Proceedings of the National Academy of Sciences*, 2013, 110(46), 18454-18459. doi:10.1186/1750-0680-8-7

ASNER, G. P. Y TUPAYACHI, R. Accelerated losses of protected forests from gold mining in the Peruvian Amazon. *Environmental Research Letters*, 2017, 12(9), 94-104. doi:10.1088/1748-9326/aa7dab

ASRAT, Z., TADDESE, H., ØRKA, H. O., GOBAKKEN, T., BURUD, I. Y NÆSSET, E. Estimation of Forest Area and Canopy Cover Based on Visual

Interpretation of Satellite Images in Ethiopia. *Land* [Type of Work]. 2018, vol. 7, no. 3. ISSN 2073-445X. doi:10.3390/land7030092.

BACCINI, A., WALKER, W., CARVALHO, L., FARINA, M., SULLA-MENASHE, D. Y HOUGHTON, R. A. Tropical forests are a net carbon source based on aboveground measurements of gain and loss. *Science*, 2017/10/13 2017, 358(6360), 230-234. doi:10.1126/science.aam5962

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., MARIK, M., MEDEIROS, H., MURPHY, S., ROCKWELL, C., SELAYA, G., SHENKIN, A., SILVEIRA, M., SOUTHWORTH, J., VASQUEZ COLOMO, G. H. Y PERZ, S. Effects of road infrastructure on forest value across a tri-national Amazonian frontier. *Biological conservation*, 2015/11/01/ 2015, 191, 674-681. doi:<https://doi.org/10.1016/j.biocon.2015.08.024>

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

CA ¿ Y POR DÓNDE COMENZAMOS? Prioridades de la Comunidad Andina ante el Cambio Climático. Lima, Peru: Secretaría General de la Comunidad Andina, 2007.

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>

CABRAL, B. F., YANAI, A. M., GRAÇA, P. M. L. D. A., ESCADA, M. I. S., DE ALMEIDA, C. M. Y FEARNSIDE, P. M. Amazon deforestation: A dangerous future indicated by patterns and trajectories in a hotspot of forest destruction

in Brazil. *Journal of Environmental Management*, 2024/03/01/ 2024, 354, 120354. doi:<https://doi.org/10.1016/j.jenvman.2024.120354>

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>

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.

CROVETTO, P. U. Comunidad Nativa y Derecho: Dos Experiencias en Madre de Dios–Perú. *Foro Jurídico*, 2013, (12), 288-303.

DELGADO-PUGLEY, D. Y BORG-RASMUSSEN, M. La agenda del movimiento indígena es grande, va más allá de las Reservas 2022. doi:<https://revistas.pucp.edu.pe/index.php/debatesensociologia/article/view/25365/23909>

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

ENGLAND, E. J., SPARKS, A. Y ROBINSON, M. D. Geo — EAS (Geostatistical Environmental Assessment Software). *Environmental Software*, 1989/06/01/ 1989, 4(2), 70-75. doi:[https://doi.org/10.1016/0266-9838\(89\)90033-6](https://doi.org/10.1016/0266-9838(89)90033-6)

FAO. FRA 2015: Terms and Definitions. In.: Food and Agriculture Organization of the UN Rome, Italy, 2012.

FAO Los bosques y el cambio climático en el Perú. Bosques y cambio climático. Documento de trabajo 14, 2016.

FAO. Evaluación de los recursos forestales mundiales 2020 – Principales resultados Roma: 2020.

FEIZIZADEH, B., DARABI, S., BLASCHKE, T. Y LAKES, T. QADI as a New Method and Alternative to Kappa for Accuracy Assessment of Remote Sensing-Based Image Classification. *Sensors* [Type of Work]. 2022, vol. 22, no. 12. ISSN 1424-8220. doi:10.3390/s22124506.

FRANCINI, S., MCROBERTS, R. E., GIANNETTI, F., MENCUCCI, M., MARCHETTI, M., SCARASCIA MUGNOZZA, G. Y CHIRICI, G. Near-real time forest change detection using PlanetScope imagery. *European Journal of*

Remote Sensing, 2020/01/01 2020, 53(1), 233-244.
doi:10.1080/22797254.2020.1806734

GONZÁLEZ-FERNÁNDEZ, A., SEGARRA, J., SUNNY, A. Y COUTURIER, S. Forest cover loss in the Nevado de Toluca volcano protected area (Mexico) after the change to a less restrictive category in 2013. *Biodiversity and Conservation*, 2022/03/01 2022, 31(3), 871-894. doi:10.1007/s10531-022-02368-y

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.

GREGORY PAUL, A., 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

HANDBOOK, T. D. A. The Data Analysis Handbook. In I.E. FRANK Y R. TODESCHINI eds. *Data Handling in Science and Technology*. Elsevier, 1994, vol. 14, p. 1-352.

HERNÁNDEZ-SAMPIERI, R. Y MENDOZA-TORRES, C. P. *Metodología de la investigación: las rutas cuantitativa, cualitativa y mixta*. Edtion ed. C.P. 01376, Ciudad de México: McGraw-Hill, 2018. ISBN 1456260960.

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

INRENA, SZF Y CDC-UNALM Hacia un Sistema de Monitoreo Ambiental Remoto Estandarizado para el SINANPE. Piloto V: Parque Nacional Manu, Parque Nacional Alto Purús, Reserva Comunal Purús y Santuario Nacional Megantoni (2000-2005). Lima-Perú 2006, 66.

JARRALLAH, Z. H. Y KHODHER, M. A. A. Satellite Images Classification Using CNN :A Survey. In *2022 International Conference on Data Science and Intelligent Computing (ICDSIC)*. 2022, p. 111-116.

JENSEN, J. R., LIN, H., YANG, X., RAMSEY III, E., DAVIS, B. A. Y THOEMKE, C. W. The measurement of mangrove characteristics in southwest Florida using SPOT multispectral data. *Geocarto International*, 1991, 6(2), 13-21. doi:<https://doi.org/10.1080/10106049109354302e>

KAVZOGLU, T. Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling & Software*, 2009/07/01/ 2009, 24(7), 850-858. doi:<https://doi.org/10.1016/j.envsoft.2008.11.012>

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, X., ZHOU, Y. Y WANG, F. Advanced Information Mining from Ocean Remote Sensing Imagery with Deep Learning. *Journal of Remote Sensing*, 2022, 2022. doi:10.34133/2022/9849645

MALIK, K., ROBERTSON, C., BRAUN, D. Y GREIG, C. U-Net convolutional neural network models for detecting and quantifying placer mining

disturbances at watershed scales. *International Journal of Applied Earth Observation and Geoinformation*, 2021/12/15/ 2021, 104, 102510. doi:<https://doi.org/10.1016/j.jag.2021.102510>

MASOLELE, R. N., DE SY, V., MARCOS, D., VERBESSELT, J., GIESEKE, F., MULATU, K. A., MOGES, Y., SEBRALA, H., MARTIUS, C. Y HEROLD, M. Using high-resolution imagery and deep learning to classify land-use following deforestation: a case study in Ethiopia. *GIScience & Remote Sensing*, 2022/12/31 2022, 59(1), 1446-1472. doi:10.1080/15481603.2022.2115619

MATOSAK, B. M., FONSECA, L. M., TAQUARY, E. C., MARETTO, R. V., BENDINI, H. D. Y ADAMI, M. Mapping Deforestation in Cerrado Based on Hybrid Deep Learning Architecture and Medium Spatial Resolution Satellite Time Series. *Remote Sensing* [Type of Work]. 2022, vol. 14, no. 1. ISSN 2072-4292. doi:10.3390/rs14010209.

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

MINAM. Bosque y perdida de bosque del Perú. Perú 2024.

MOHAMMADI-GHAZI, R., WELSCH, R. E. Y BÜYÜKÖZTÜRK, O. Kernel dependence analysis and graph structure morphing for novelty detection with high-dimensional small size data set. *Mechanical Systems and Signal Processing*, 2020/09/01/ 2020, 143, 106775. doi:<https://doi.org/10.1016/j.ymssp.2020.106775>

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.

NAIR, M. Y BINDHU, J. S. Supervised techniques and approaches for satellite image classification. *International Journal of Computer Applications*, 2016, 134(16).

PERZ, S., CASTRO, W., ROJAS, R., CASTILLO, J., CHÁVEZ, A., GARCÍA, M., GUADALUPE, Ó., GUTIÉRREZ, T., HURTADO, A., MAMANI, Z., MAYNA, J., MELLO, R., PASSOS, V., REYES, J., SAAVEDRA, M., DE WIT, F., ACUÑA, N., ALARCÓN, G. Y ROJAS, D. La Amazonia como un sistema socio-ecológico: Las dinámicas de cambios complejos humanos y ambientales en una frontera trinacional. In J. POSTIGO Y K. YOUNG eds. *Naturaleza y sociedad: Perspectivas socio-ecológicas sobre cambios globales en América Latina*. Lima-Perú: desco, IEP e INTE-PUCP, 2016, p. 444.

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

PICKERING, J., TYUKAVINA, A., KHAN, A., POTAPOV, P., ADUSEI, B., HANSEN, M. C. Y LIMA, A. Using Multi-Resolution Satellite Data to Quantify Land Dynamics: Applications of PlanetScope Imagery for Cropland and Tree-Cover Loss Area Estimation. *Remote Sensing* [Type of Work]. 2021, vol. 13, no. 11. ISSN 2072-4292. doi:10.3390/rs13112191.

PICZAK, K. J. Environmental sound classification with convolutional neural networks. In *2015 IEEE 25th International Workshop on Machine Learning for Signal Processing (MLSP)*. 2015, p. 1-6.

PLANET-TEAM Planet Application Program Interface: In Space for Life on Earth. Habitat International, 2022.

PLANET-TEAM Planet Application Program Interface: In Space for Life on Earth. Habitat International, 2023.

PLANET-TEAM Planet Application Program Interface: In Space for Life on Earth. Habitat International, 2024.

PLANET-TEAM Planet Application Program Interface: In Space for Life on Earth. Habitat International, 2025.

PRASAD, P., LOVESON, V. J., CHANDRA, P. Y KOTHA, M. Evaluation and comparison of the earth observing sensors in land cover/land use studies using machine learning algorithms. Ecological Informatics, 2022/05/01/ 2022, 68, 101522. doi:<https://doi.org/10.1016/j.ecoinf.2021.101522>

PUYRAVAUD, J.-P. Standardizing the calculation of the annual rate of deforestation. Forest Ecology and Management, 2003, 177(1), 593-596. doi:[https://doi.org/10.1016/S0378-1127\(02\)00335-3](https://doi.org/10.1016/S0378-1127(02)00335-3)

RADHIKA, K. Y VARADARAJAN, S. A neural network based classification of satellite images for change detection applications. Cogent Engineering, 2018/01/01 2018, 5(1), 1484587. doi:10.1080/23311916.2018.1484587

RAISG. Destrucción del Amazonas: las principales amenazas para la mayor selva tropical del mundo en los 9 países que la comparten (2001-2018). 2024.

RICO, J., PANLASIGUI, S., LOUCKS, C. J., SWENSON, J. Y PFAFF, A. S. P. Logging concessions, certification & protected areas in the Peruvian Amazon: Forest impacts from combinations of development rights & land-use restrictions. 2018.

RÍOS, J., LAGUADO, W., TRUJILLO, C. Y SÁNCHEZ, P. Análisis y modelación de deforestación para los años 1990, 2000 y 2010 en el corredor Manu-Amarakaeri. Setiembre de, 2012.

RUFIN, P., BEY, A., PICOLI, M. Y MEYFROIDT, P. Large-area mapping of active cropland and short-term fallows in smallholder landscapes using PlanetScope data. *International Journal of Applied Earth Observation and Geoinformation*, 2022/08/01/ 2022, 112, 102937. doi:<https://doi.org/10.1016/j.jag.2022.102937>

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

SOUTHWORTH, J., MARSIK, M., QIU, Y., PERZ, S., CUMMING, G., STEVENS, F., ROCHA, K., DUCHELLE, A. Y BARNES, G. Roads as Drivers of Change: Trajectories across the Tri-National Frontier in MAP, the Southwestern Amazon. *Remote Sensing*, 2011, 3(5), 1047-1066. doi:<https://doi.org/10.3390/rs3051047>

SURATMAN, M. N., ABD LATIF, Z., DE OLIVEIRA, G., BRUNSELL, N., SHIMABUKURO, Y. Y DOS SANTOS, C. A. C. *Forest Degradation Around the World*. Edtion ed.: BoD–Books on Demand, 2020. ISBN 1789238331.

SWENSON, J. J., CARTER, C. E., DOMEQ, J.-C. Y DELGADO, C. I. Gold mining in the Peruvian Amazon: global prices, deforestation, and mercury imports. *PloS one*, 2011, 6(4), e18875. doi:doi.org/10.1371/journal.pone.0018875

VANCUTSEM, C., ACHARD, F., PEKEL, J. F., VIEILLEDENT, G., CARBONI, S., SIMONETTI, D., GALLEGU, J., ARAGÃO, L. E. O. C. Y NASI, R. Long-term (1990–2019) monitoring of forest cover changes in the humid tropics. *Science Advances*, 7(10), eabe1603. doi:10.1126/sciadv.abe1603

VIJAY, V., REID, C. D., FINER, M., JENKINS, C. N. Y PIMM, S. L. Deforestation risks posed by oil palm expansion in the Peruvian Amazon*. *Environmental Research Letters*, 2018/11/01 2018, 13(11), 114010. doi:10.1088/1748-9326/aae540

WAGNER, F. H., DALAGNOL, R., SILVA-JUNIOR, C. H. L., CARTER, G., RITZ, A. L., HIRYE, M. C. M., OMETTO, J. P. H. B. Y SAATCHI, S. Mapping Tropical Forest Cover and Deforestation with Planet NICFI Satellite Images and Deep Learning in Mato Grosso State (Brazil) from 2015 to 2021. *Remote Sensing* [Type of Work]. 2023, vol. 15, no. 2. ISSN 2072-4292. doi:10.3390/rs15020521.

WALKER, K., FLORES-ANDERSON, A., VILLA, L., GRIFFIN, R., FINER, M. Y HERNDON, K. An analysis of fire dynamics in and around indigenous territories and protected areas in a Brazilian agricultural frontier. *Environmental Research Letters*, 2022/08/02 2022, 17(8), 084030. doi:10.1088/1748-9326/ac8237

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

XIUWAN, C. Using remote sensing and GIS to analyse land cover change and its impacts on regional sustainable development. *International journal of remote sensing*, 2002, 23(1), 107-124. doi:<https://doi.org/10.1080/01431160010007051>

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

YANG, F., JIANG, X., ZIEGLER, A. D., ESTES, L. D., WU, J., CHEN, A., CIAIS, P., WU, J. Y ZENG, Z. Improved Fine-Scale Tropical Forest Cover Mapping for Southeast Asia Using Planet-NICFI and Sentinel-1 Imagery. *Journal of Remote Sensing*, 2023, 3, 0064. doi:10.34133/remotesensing.0064

ZHANG, C. Y LI, X. Land Use and Land Cover Mapping in the Era of Big Data. *Land* [Type of Work]. 2022, vol. 11, no. 10. ISSN 2073-445X. doi:10.3390/land11101692.

ZHANG, Y., WANG, X., LI, X., DU, Y. Y ATKINSON, P. M. Monitoring monthly tropical humid forest disturbances with Planet NICFI images in Cameroon. *Agricultural and forest meteorology*, 2023/10/15/ 2023, 341, 109676. doi:<https://doi.org/10.1016/j.agrformet.2023.109676>

ANEXOS

Anexo 1. Matriz de consistencia.

Título: Evaluación espacio-temporal de la deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024.

PROBLEMA GENERAL	OBJETIVO GENERAL	HIPOTESIS GENERAL	VARIABLES/INDICADORES	METODOLOGÍA
¿Cuál es el comportamiento del espacio-temporal de la deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024?	Evaluar el espacio-temporal de la deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios a partir de imágenes PlanetScope, periodo 2018-2024.	La tendencia creciente de la deforestación no presenta una relación significativa con las actividades antrópicas en territorios indígenas del ECA Amarakaeri Madre de Dios durante los periodos 2018 y 2024 a partir de imágenes PlanetScope.	<p>Variable Dependiente:</p> <p>Deforestación y patrones espaciales en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.</p> <p>Indicadores:</p> <p>Deforestación por tipo de actividad productiva y patrones espaciales.</p> <p>Variable Independiente:</p> <p>Comportamiento de la deforestación por tipo de actividad productiva en la unidad mínima de medida del pixel de imágenes PlanetScope.</p> <p>Indicadores:</p> <ol style="list-style-type: none"> Superficie en hectáreas de deforestación. Tasa de deforestación. Precisión general e índice de kappa. Superficie en hectáreas de cambios de LULC. 	<p>Diseño: no experimental Transaccional (transversal) y longitudinal.</p> <p>Tipo: descriptiva y correlacional.</p> <p>Método:</p> <ol style="list-style-type: none"> Análisis de la deforestación de 2018 y 2024. La clasificación de imágenes PlanetScope de 2018 y 2024 mediante NN. Precisión de datos mediante matriz de confusión e índice de kappa. Tasa de deforestación. Cambios de LULC. <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> <p>“p: indica el porcentaje de aciertos estimado, 0,50 (50%)”.</p> <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>
PROBLEMAS ESPECIFICOS	OBJETIVOS ESPECÍFICOS			
<p>P.E.1 ¿Cuanto es la cuantificación de la deforestación por tipo de actividad productiva en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024?</p> <p>P.E.2 ¿Cuál es la tasa de deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024?</p> <p>P.E.3 ¿Cuánto es la precisión de la clasificación del algoritmo de redes neuronales de los periodos 2018 y 2024?</p> <p>P.E.4 ¿Cómo y cuánto son los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo) en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024?</p>	<p>O.E.1 Cuantificar la deforestación por tipo de actividad productiva en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.</p> <p>O.E.2 Determinar la tasa de deforestación en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.</p> <p>O.E.3 Evaluar la precisión de la clasificación del algoritmo de redes neuronales de los periodos 2018 y 2024.</p> <p>O.E.4 Caracterización de los patrones espaciales de la deforestación (cambios de uso y cobertura del suelo) en territorios indígenas del ECA Amarakaeri Madre de Dios en los periodos 2018 y 2024.</p>			

Anexo 2. Puntos de muestreo distribuidos al azar por clases en el área de estudio.

N.º	Clase	Código	Este	Norte
1	Bosque	3	253982	8598585
2	Bosque	3	252220	8598839
3	Bosque	3	250870	8599189
4	Bosque	3	252537	8596839
5	Bosque	3	253442	8597125
6	Bosque	3	263002	8617750
7	Bosque	3	262650	8618119
8	Bosque	3	262382	8618655
9	Bosque	3	262516	8619175
10	Bosque	3	263405	8619426
11	Bosque	3	264109	8619024
12	Bosque	3	264411	8619694
13	Bosque	3	264981	8620382
14	Bosque	3	265668	8621119
15	Bosque	3	266188	8621622
16	Bosque	3	258292	8621086
17	Bosque	3	285077	8634596
18	Bosque	3	284399	8633855
19	Bosque	3	284717	8632564
20	Bosque	3	286241	8633368
21	Bosque	3	287511	8633855
22	Bosque	3	288252	8634554
23	Bosque	3	289310	8634935
24	Bosque	3	290559	8635379
25	Bosque	3	290749	8636120
26	Bosque	3	290792	8636586
27	Bosque	3	289860	8637157
28	Bosque	3	290622	8638703
29	Bosque	3	294813	8639951
30	Bosque	3	296358	8639189
31	Bosque	3	295427	8638279
32	Bosque	3	309186	8640946
33	Bosque	3	309672	8640883
34	Bosque	3	310223	8640608
35	Bosque	3	310731	8639867
36	Bosque	3	311260	8639062
37	Bosque	3	311620	8638703
38	Bosque	3	311726	8637962
39	Bosque	3	312022	8637665
40	Bosque	3	312339	8637559
41	Bosque	3	313059	8636967

42	Bosque	3	313525	8636438
43	Bosque	3	313821	8636141
44	Bosque	3	322394	8617102
45	Bosque	3	321864	8617234
46	Bosque	3	321124	8617049
47	Bosque	3	320541	8616626
48	Bosque	3	319589	8616440
49	Bosque	3	318054	8615673
50	Bosque	3	316943	8614694
51	Bosque	3	316679	8613371
52	Bosque	3	331389	8612498
53	Bosque	3	332077	8612075
54	Bosque	3	332792	8612392
55	Bosque	3	333400	8612313
56	Bosque	3	333850	8612313
57	Bosque	3	341576	8600063
58	Bosque	3	341364	8599719
59	Bosque	3	340729	8597470
60	Bosque	3	340888	8595723
61	Bosque	3	337395	8600645
62	Bosque	3	336496	8600063
63	Bosque	3	335173	8599904
64	Bosque	3	332342	8594480
65	Bosque	3	331231	8593527
66	Bosque	3	329643	8591675
67	Bosque	3	327050	8593818
68	Bosque	3	325833	8592231
69	Bosque	3	323108	8586807
70	Bosque	3	326521	8578737
71	Bosque	3	326733	8577917
72	Bosque	3	326839	8577335
73	Bosque	3	326971	8576726
74	Bosque	3	326468	8576065
75	Bosque	3	335808	8575615
76	Bosque	3	333744	8574795
77	Bosque	3	333136	8573340
78	Bosque	3	331019	8572758
79	Bosque	3	330463	8572334
80	Bosque	3	329352	8570535
81	Bosque inundable	6	336900	8578564
82	Bosque inundable	6	337017	8578329
83	Bosque inundable	6	336632	8577960
84	Bosque inundable	6	336447	8577508
85	Bosque inundable	6	336481	8576921
86	Bosque inundable	6	336531	8576251

87	Bosque inundable	6	336766	8576200
88	Bosque inundable	6	337068	8576636
89	Bosque inundable	6	337151	8577173
90	Bosque inundable	6	337369	8577960
91	Bosque inundable	6	332927	8575345
92	Bosque inundable	6	339599	8601380
93	Bosque inundable	6	338241	8599905
94	Bosque inundable	6	336682	8598161
95	Bosque inundable	6	331770	8600743
96	Bosque inundable	6	329356	8600391
97	Bosque inundable	6	333078	8597491
98	Bosque inundable	6	328836	8594808
99	Bosque inundable	6	327194	8593082
100	Bosque inundable	6	324880	8590651
101	Bosque inundable	6	323807	8588404
102	Bosque inundable	6	325115	8588287
103	Bosque inundable	6	320052	8587097
104	Bosque inundable	6	313531	8585488
105	Bosque inundable	6	317588	8588622
106	Bosque inundable	6	333777	8612666
107	Bosque inundable	6	333353	8612666
108	Bosque inundable	6	332009	8613957
109	Bosque inundable	6	331184	8614359
110	Bosque inundable	6	328834	8616793
111	Bosque inundable	6	328813	8617873
112	Bosque inundable	6	325903	8620106
113	Bosque inundable	6	325998	8620561
114	Bosque inundable	6	325384	8621450
115	Bosque inundable	6	325130	8622106
116	Bosque inundable	6	324389	8620772
117	Bosque inundable	6	323394	8619756
118	Bosque inundable	6	314053	8630599
119	Bosque inundable	6	312968	8630493
120	Bosque inundable	6	310905	8631896
121	Bosque inundable	6	312122	8633430
122	Bosque inundable	6	310640	8633298
123	Bosque inundable	6	308973	8634436
124	Bosque inundable	6	308444	8637214
125	Bosque inundable	6	307174	8638881
126	Bosque inundable	6	304237	8639992
127	Bosque inundable	6	304032	8641692
128	Bosque inundable	6	303807	8643736
129	Bosque inundable	6	299058	8642082
130	Bosque inundable	6	297153	8642591
131	Bosque inundable	6	294037	8641533

132	Bosque inundable	6	291802	8641897
133	Bosque inundable	6	293310	8641235
134	Bosque inundable	6	298046	8640230
135	Bosque inundable	6	298602	8641764
136	Bosque inundable	6	285723	8634548
137	Bosque inundable	6	262322	8637954
138	Bosque inundable	6	262592	8636579
139	Bosque inundable	6	260634	8634462
140	Bosque inundable	6	260105	8630652
141	Bosque inundable	6	260266	8628916
142	Bosque inundable	6	255506	8624466
143	Bosque inundable	6	259808	8627562
144	Bosque inundable	6	255017	8597824
145	Bosque inundable	6	256493	8598913
146	Bosque inundable	6	254883	8598226
147	Bosque inundable	6	266420	8620762
148	Bosque inundable	6	267876	8622773
149	Bosque inundable	6	269463	8625022
150	Bosque inundable	6	262822	8631928
151	Bosque inundable	6	271527	8626319
152	Bosque inundable	6	276676	8628452
153	Bosque inundable	6	277625	8629282
154	Bosque inundable	6	277725	8629606
155	Bosque inundable	6	290233	8639925
156	Bosque inundable	6	290173	8639508
157	Bosque inundable	6	290342	8639068
158	Bosque inundable	6	290683	8641598
159	Bosque inundable	6	296649	8642339
160	Bosque inundable	6	298762	8642531
161	Zona pantanosa o pastizal inundable	11	252373	8598215
162	Zona pantanosa o pastizal inundable	11	253053	8598291
163	Zona pantanosa o pastizal inundable	11	251275	8598418
164	Zona pantanosa o pastizal inundable	11	266069	8620310
165	Zona pantanosa o pastizal inundable	11	268620	8623692
166	Zona pantanosa o pastizal inundable	11	268634	8623706
167	Zona pantanosa o pastizal inundable	11	268579	8623666
168	Zona pantanosa o pastizal inundable	11	268660	8623760
169	Zona pantanosa o pastizal inundable	11	277855	8628998
170	Zona pantanosa o pastizal inundable	11	279572	8632221
171	Zona pantanosa o pastizal inundable	11	284560	8635028
172	Zona pantanosa o pastizal inundable	11	303494	8643310
173	Zona pantanosa o pastizal inundable	11	303431	8643525
174	Zona pantanosa o pastizal inundable	11	304181	8641253
175	Zona pantanosa o pastizal inundable	11	314712	8631070
176	Zona pantanosa o pastizal inundable	11	326737	8618188

177	Zona pantanosa o pastizal inundable	11	323728	8616700
178	Zona pantanosa o pastizal inundable	11	341397	8601032
179	Zona pantanosa o pastizal inundable	11	338569	8598898
180	Zona pantanosa o pastizal inundable	11	338782	8578855
181	Zona pantanosa o pastizal inundable	11	339874	8576988
182	Zona pantanosa o pastizal inundable	11	324967	8589354
183	Zona pantanosa o pastizal inundable	11	329493	8593529
184	Pastizal / herbazal	12	251278	8602068
185	Pastizal / herbazal	12	251270	8602074
186	Pastizal / herbazal	12	251272	8602057
187	Pastizal / herbazal	12	251286	8602061
188	Pastizal / herbazal	12	251259	8602044
189	Pastizal / herbazal	12	251253	8602040
190	Pastizal / herbazal	12	251241	8602031
191	Pastizal / herbazal	12	251240	8602043
192	Pastizal / herbazal	12	251257	8602030
193	Pastizal / herbazal	12	251228	8602014
194	Pastizal / herbazal	12	251219	8602005
195	Pastizal / herbazal	12	251184	8601977
196	Pastizal / herbazal	12	251195	8601980
197	Pastizal / herbazal	12	251180	8601954
198	Pastizal / herbazal	12	251198	8601952
199	Pastizal / herbazal	12	251191	8601947
200	Pastizal / herbazal	12	251216	8601947
201	Pastizal / herbazal	12	251241	8601976
202	Pastizal / herbazal	12	251257	8601975
203	Pastizal / herbazal	12	251279	8601975
204	Pasto	15	251963	8597936
205	Pasto	15	254588	8597629
206	Pasto	15	268648	8624535
207	Pasto	15	269992	8625269
208	Pasto	15	282747	8634275
209	Pasto	15	288105	8636508
210	Pasto	15	294968	8642229
211	Pasto	15	308147	8639765
212	Pasto	15	310578	8638691
213	Pasto	15	326096	8616948
214	Pasto	15	325910	8621042
215	Pasto	15	326541	8618133
216	Pasto	15	326580	8617730
217	Pasto	15	336929	8598828
218	Pasto	15	334177	8595600
219	Pasto	15	324255	8589277
220	Pasto	15	318593	8587134
221	Pasto	15	338675	8575492

222	Pasto	15	338754	8576153
223	Pasto	15	337273	8579540
224	Agricultura	18	245829	8564952
225	Agricultura	18	245736	8564880
226	Agricultura	18	245392	8565621
227	Agricultura	18	245300	8565733
228	Agricultura	18	243037	8564860
229	Agricultura	18	242819	8565356
230	Agricultura	18	242779	8565005
231	Agricultura	18	243104	8566388
232	Agricultura	18	243540	8567248
233	Agricultura	18	244526	8566652
234	Agricultura	18	249864	8598587
235	Agricultura	18	250315	8598987
236	Agricultura	18	250302	8598821
237	Agricultura	18	249997	8599590
238	Agricultura	18	248956	8599558
239	Agricultura	18	252714	8615650
240	Agricultura	18	253720	8614507
241	Agricultura	18	252820	8613851
242	Agricultura	18	252831	8609745
243	Agricultura	18	252513	8609459
244	Mosaico agropecuario	21	243002	8566246
245	Mosaico agropecuario	21	242790	8566114
246	Mosaico agropecuario	21	245687	8564566
247	Mosaico agropecuario	21	245145	8564897
248	Mosaico agropecuario	21	250741	8594332
249	Mosaico agropecuario	21	250436	8593366
250	Mosaico agropecuario	21	251574	8595562
251	Mosaico agropecuario	21	254392	8596832
252	Mosaico agropecuario	21	255119	8596514
253	Mosaico agropecuario	21	255463	8596673
254	Mosaico agropecuario	21	252831	8597917
255	Mosaico agropecuario	21	249709	8599266
256	Mosaico agropecuario	21	263607	8617988
257	Mosaico agropecuario	21	263957	8618163
258	Mosaico agropecuario	21	263703	8618925
259	Mosaico agropecuario	21	263306	8618528
260	Mosaico agropecuario	21	263036	8618956
261	Mosaico agropecuario	21	270031	8625379
262	Mosaico agropecuario	21	280677	8632349
263	Mosaico agropecuario	21	282943	8632597
264	Mosaico agropecuario	21	285166	8633888
265	Mosaico agropecuario	21	285959	8634227
266	Mosaico agropecuario	21	287060	8635275

267	Mosaico agropecuario	21	287282	8635476
268	Mosaico agropecuario	21	287589	8636196
269	Mosaico agropecuario	21	288161	8636566
270	Mosaico agropecuario	21	287568	8636693
271	Mosaico agropecuario	21	288499	8637085
272	Mosaico agropecuario	21	294987	8642048
273	Mosaico agropecuario	21	298839	8640715
274	Mosaico agropecuario	21	307549	8640905
275	Mosaico agropecuario	21	307983	8639847
276	Mosaico agropecuario	21	310513	8638789
277	Mosaico agropecuario	21	310703	8637148
278	Mosaico agropecuario	21	326263	8616974
279	Mosaico agropecuario	21	326005	8617787
280	Mosaico agropecuario	21	324729	8617847
281	Mosaico agropecuario	21	323849	8617311
282	Mosaico agropecuario	21	324319	8617893
283	Mosaico agropecuario	21	318055	8614381
284	Mosaico agropecuario	21	337364	8599088
285	Mosaico agropecuario	21	336877	8599003
286	Mosaico agropecuario	21	334634	8595722
287	Mosaico agropecuario	21	333829	8595722
288	Mosaico agropecuario	21	333977	8594749
289	Mosaico agropecuario	21	327119	8590219
290	Mosaico agropecuario	21	327564	8590388
291	Mosaico agropecuario	21	328961	8589880
292	Mosaico agropecuario	21	329659	8589372
293	Mosaico agropecuario	21	320388	8584123
294	Mosaico agropecuario	21	319140	8580398
295	Mosaico agropecuario	21	338190	8575423
296	Mosaico agropecuario	21	338592	8575677
297	Mosaico agropecuario	21	338380	8577159
298	Mosaico agropecuario	21	338655	8577265
299	Mosaico agropecuario	21	327712	8575847
300	Mosaico agropecuario	21	327077	8575529
301	Mosaico agropecuario	21	325595	8574810
302	Mosaico agropecuario	21	332242	8571254
303	Mosaico agropecuario	21	332284	8573497
304	Infraestructura	24	250501	8598467
305	Infraestructura	24	250429	8598649
306	Infraestructura	24	250580	8598479
307	Infraestructura	24	334779	8596945
308	Infraestructura	24	334861	8596985
309	Infraestructura	24	334878	8596922
310	Infraestructura	24	334815	8596852
311	Infraestructura	24	334865	8596730

312	Infraestructura	24	334831	8596690
313	Infraestructura	24	326734	8590542
314	Infraestructura	24	326730	8590447
315	Infraestructura	24	326738	8590340
316	Infraestructura	24	326615	8590260
317	Infraestructura	24	339259	8576294
318	Infraestructura	24	339428	8576940
319	Infraestructura	24	339344	8578072
320	Infraestructura	24	337333	8579501
321	Infraestructura	24	326656	8590396
322	Infraestructura	24	326735	8590390
323	Infraestructura	24	327013	8590393
324	Minería	30	335721	8595454
325	Minería	30	336833	8595110
326	Minería	30	337520	8595481
327	Minería	30	336965	8593920
328	Minería	30	337177	8593285
329	Minería	30	336621	8591909
330	Minería	30	335166	8590718
331	Minería	30	334134	8591089
332	Minería	30	333525	8591882
333	Minería	30	331223	8590348
334	Minería	30	330588	8589607
335	Minería	30	328075	8588602
336	Minería	30	327704	8587675
337	Minería	30	326964	8586644
338	Minería	30	329451	8587781
339	Minería	30	330456	8588972
340	Minería	30	334293	8593999
341	Minería	30	338447	8595666
342	Minería	30	342918	8597624
343	Minería	30	342600	8599211
344	Minería	30	341489	8594846
345	Minería	30	343765	8597386
346	Minería	30	331673	8590427
347	Minería	30	328657	8574155
348	Minería	30	328419	8577145
349	Minería	30	329186	8577833
350	Minería	30	329424	8578574
351	Minería	30	330562	8578944
352	Minería	30	332996	8576986
353	Minería	30	333049	8576484
354	Minería	30	335007	8577092
355	Minería	30	335721	8578098
356	Minería	30	334980	8578865

357	Minería	30	332070	8573044
358	Minería	30	332705	8572224
359	Minería	30	335827	8572039
360	Minería	30	335404	8573679
361	Minería	30	328313	8571642
362	Minería	30	327863	8570874
363	Minería	30	328816	8571642
364	Minería	30	328525	8574737
365	Minería	30	328551	8576722
366	Minería	30	327943	8578574
367	Minería	30	328472	8579024
368	Minería	30	335827	8572383
369	Minería	30	335033	8573970
370	Minería	30	334769	8575796
371	Minería	30	334478	8579103
372	Minería	30	334901	8579341
373	Minería	30	336224	8578971
374	Minería	30	338705	8588357
375	Minería	30	338142	8588092
376	Minería	30	338275	8586736
377	Minería	30	335728	8592326
378	Minería	30	336720	8594310
379	Minería	30	339101	8601222
380	Minería	30	342673	8597849
381	Minería	30	343699	8599337
382	Minería	30	344591	8600329
383	Minería	30	343236	8601057

Anexo 3. Panel fotográfico.



Foto 1. Bosque y áreas mayormente naturales.



Foto 2. Deforestación por minería de oro.



Foto 3. Áreas inundables.



Foto 4. Reunión con comuneros.



Foto 5. Áreas deforestadas para fines agrícolas.



Foto 6. Deforestación con fines agrícolas



Foto 7. Mosaico agropecuario.



Foto 8. Inicio de trabajo de campo.

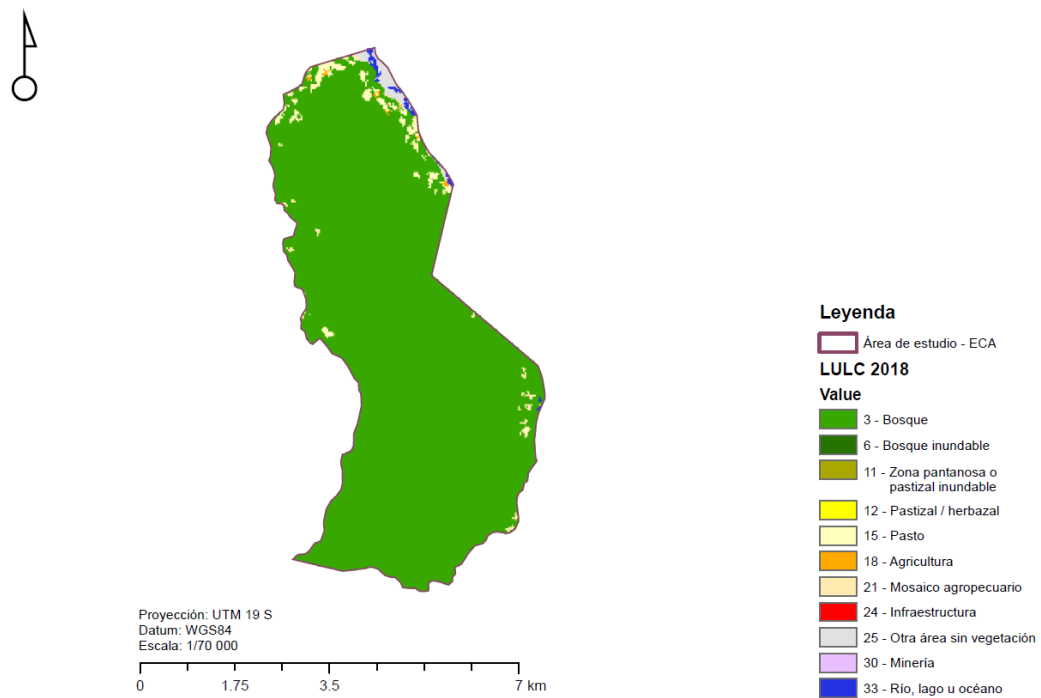


Foto 9. Final de jornada.

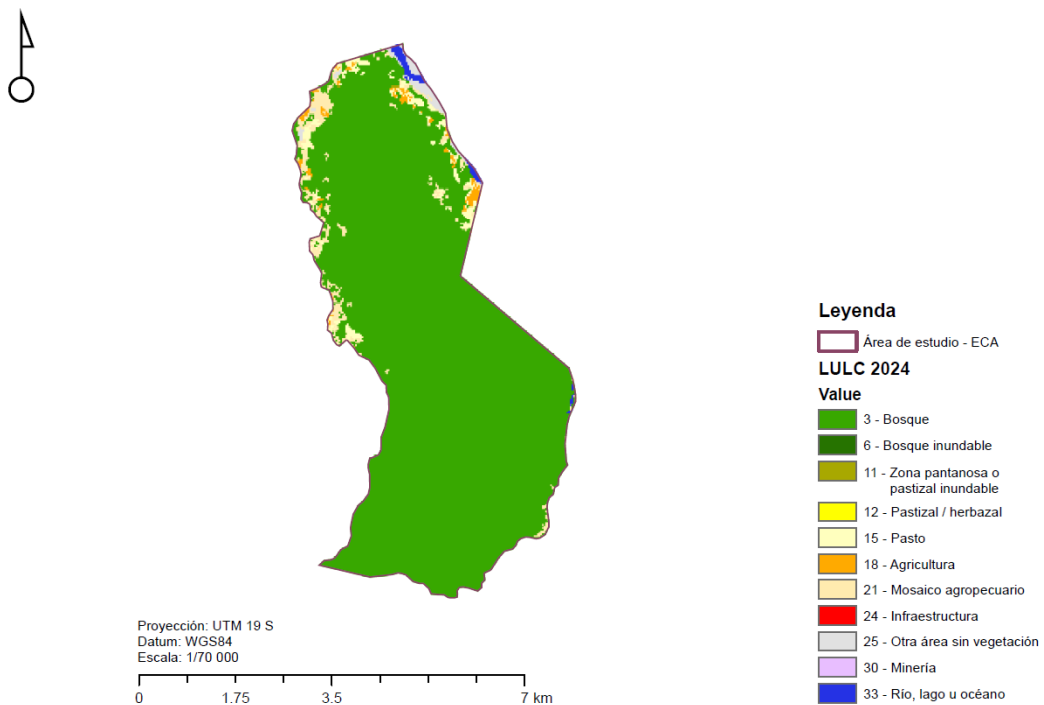


Foto 10. Retorno de campo.

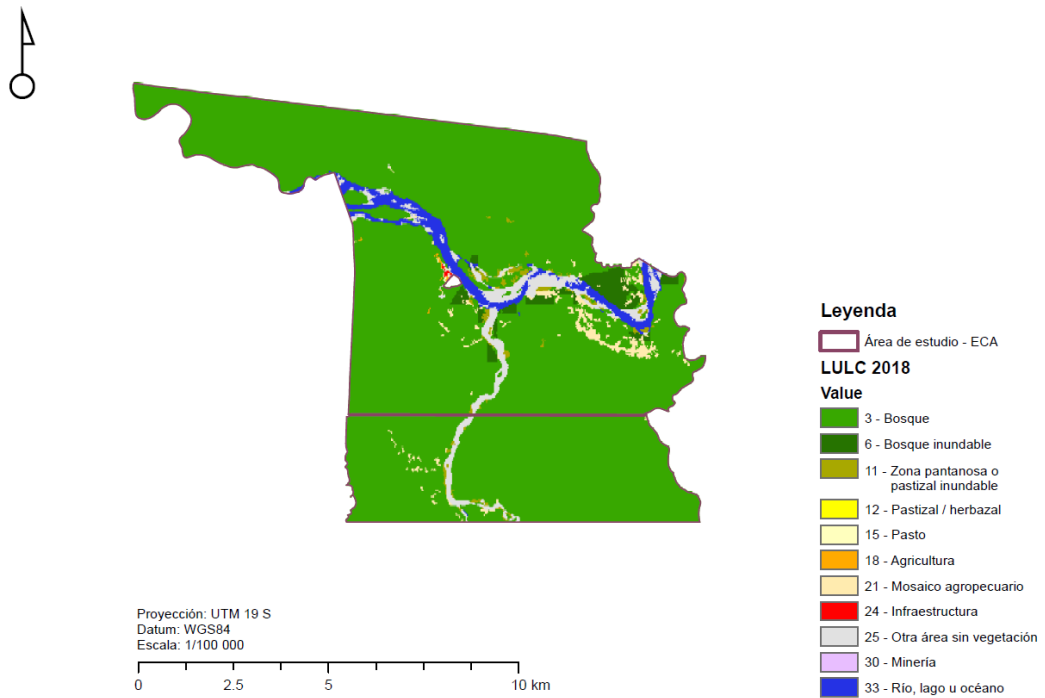
Anexo 4. LULC por comunidades nativas.



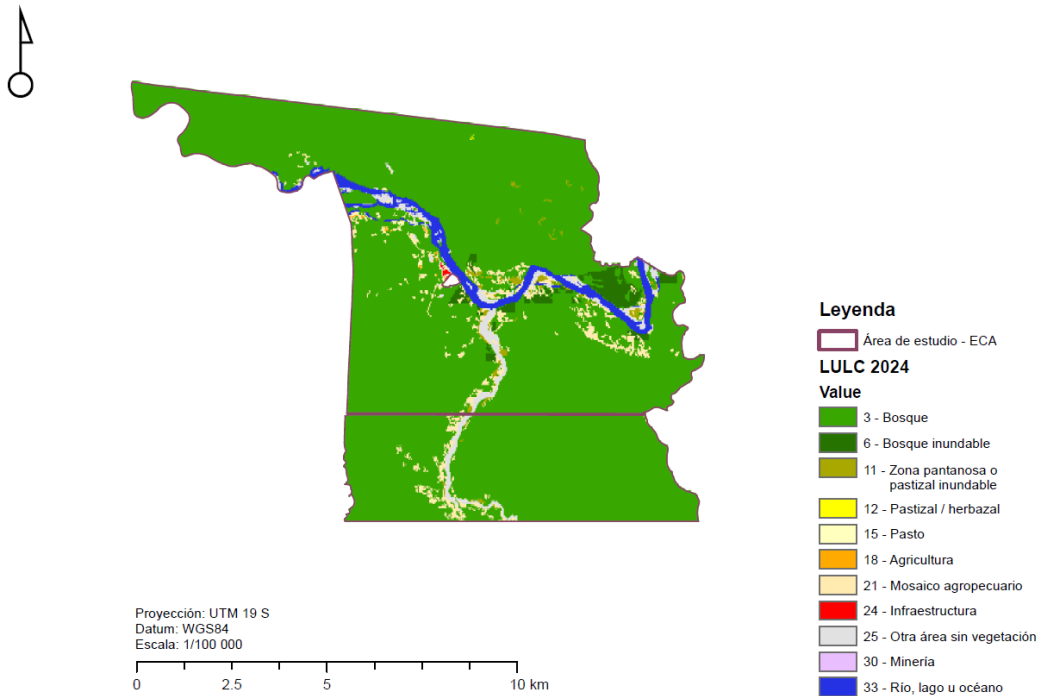
Anexo 4.1. LULC 2018 de la comunidad nativa de Queros.



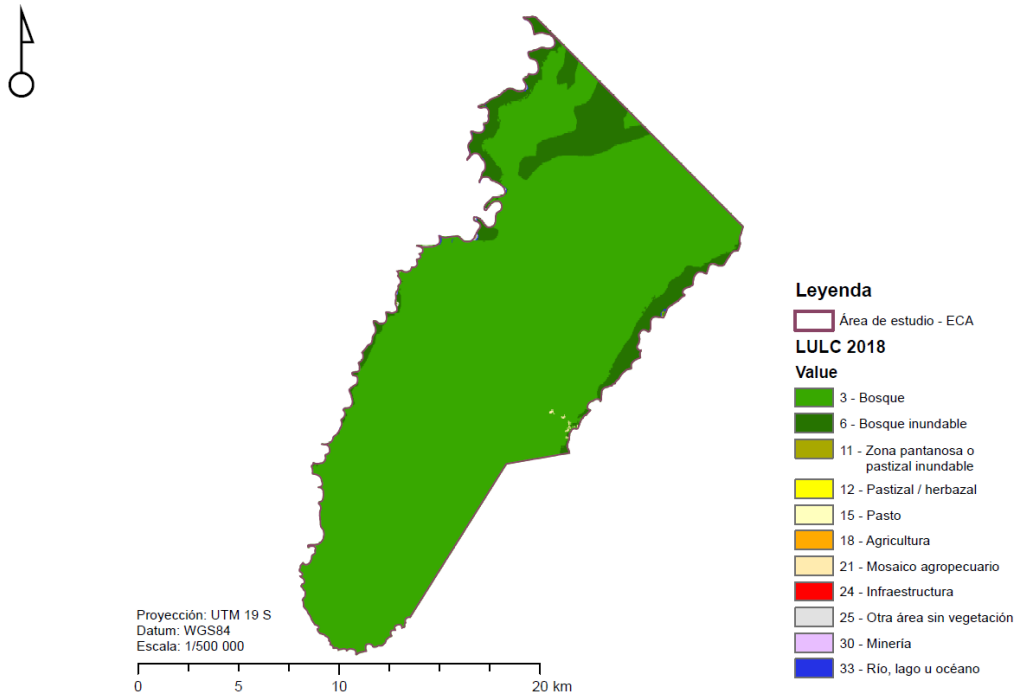
Anexo 4.2. LULC 2024 de la comunidad nativa de Queros.




Anexo 4.3. LULC 2018 de la comunidad nativa de Shintuya.



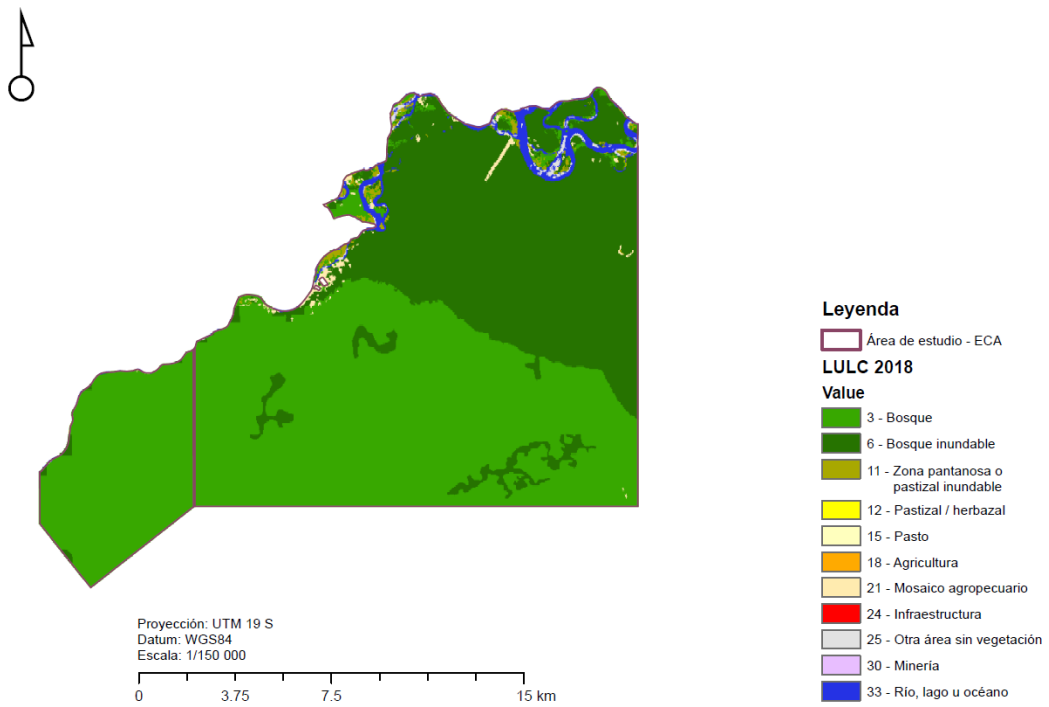
Anexo 4.4. LULC 2024 de la comunidad nativa de Shintuya.



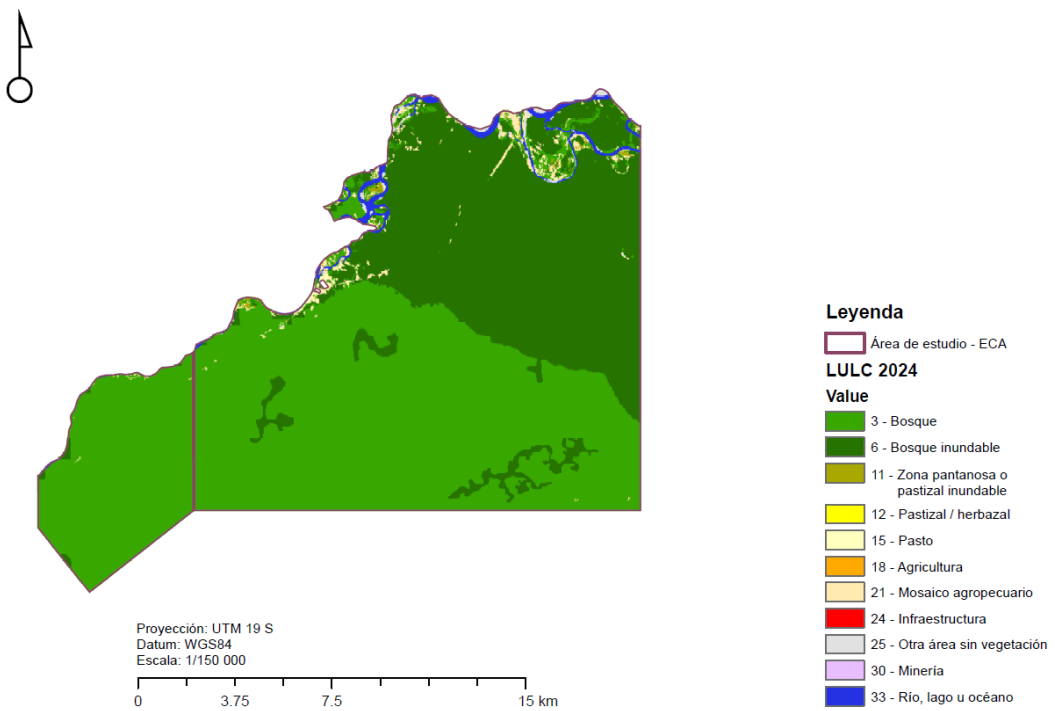
Anexo 4.5. LULC 2018 de la comunidad nativa de Shipetiare.



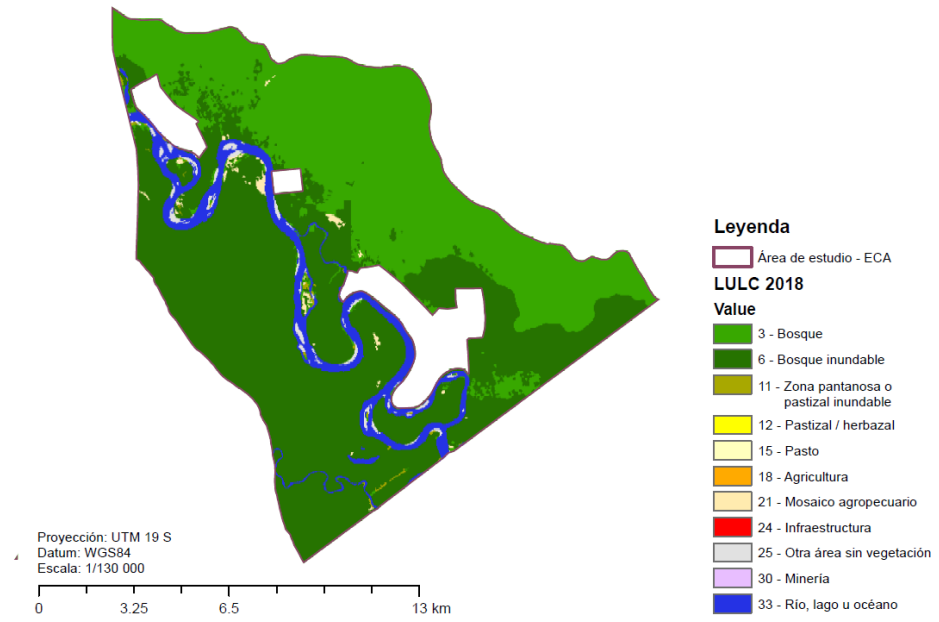

Anexo 4.6. LULC 2024 de la comunidad nativa de Shipetiare.



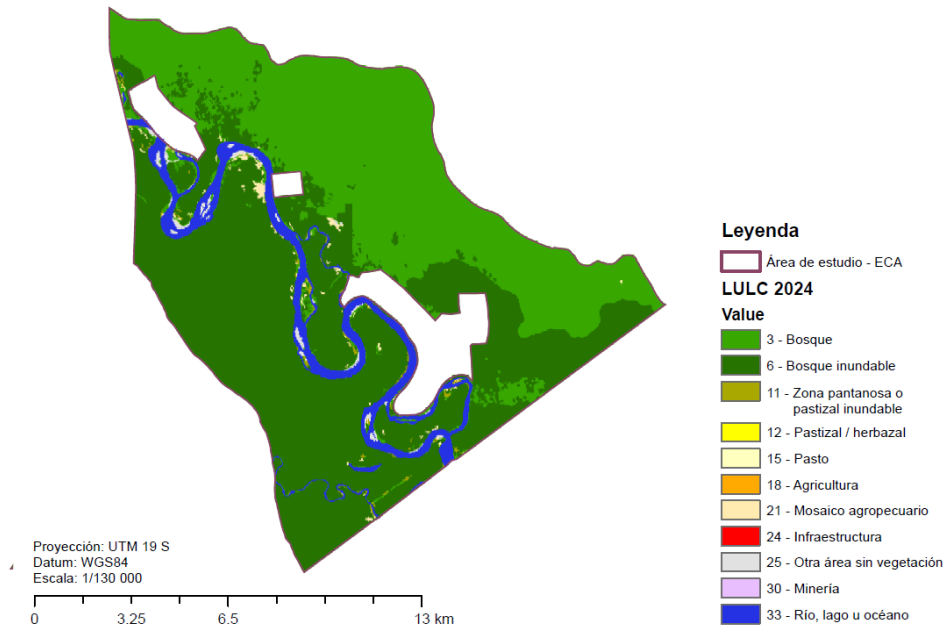

Anexo 4.7. LULC 2018 de la comunidad nativa Diamante.



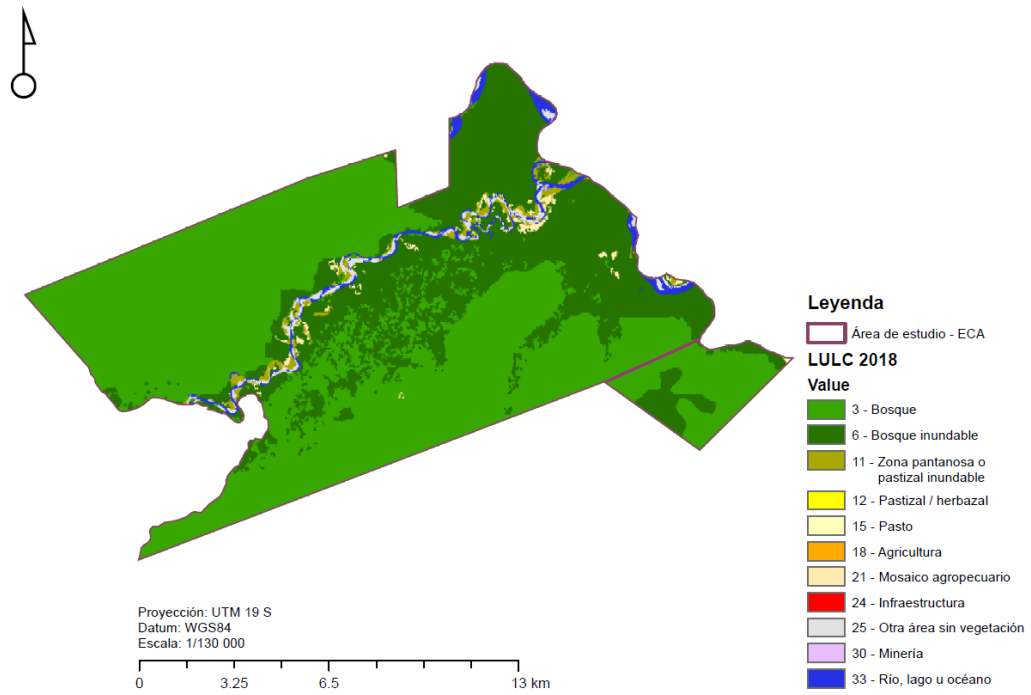
Anexo 4.8. LULC 2024 de la comunidad nativa Diamante.



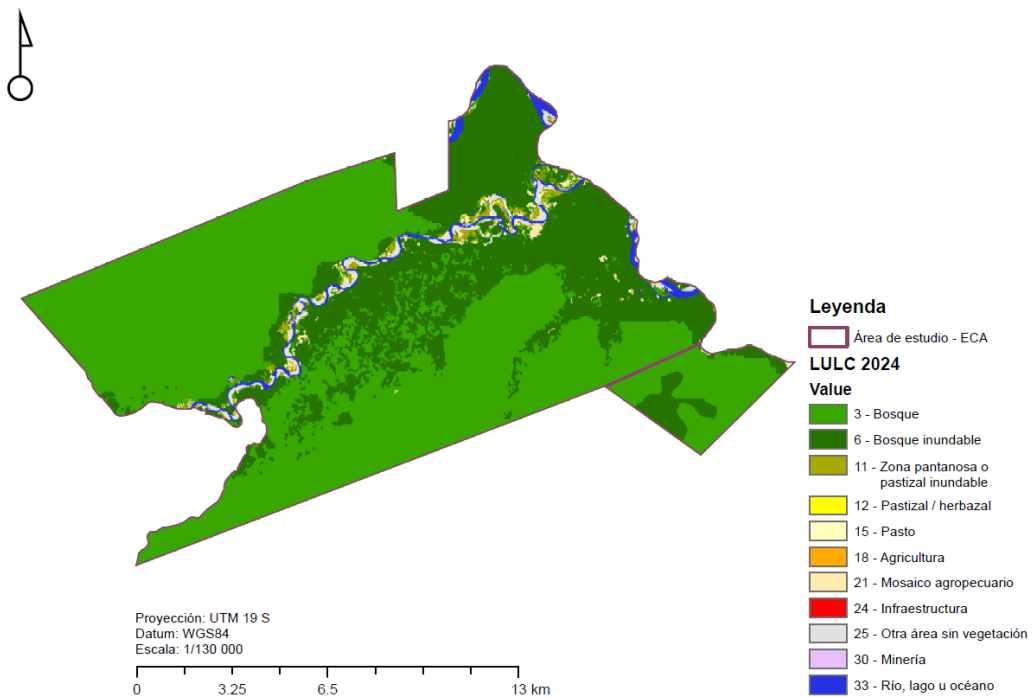
Anexo 4.9. LULC 2018 de la comunidad nativa Puerto Azul.



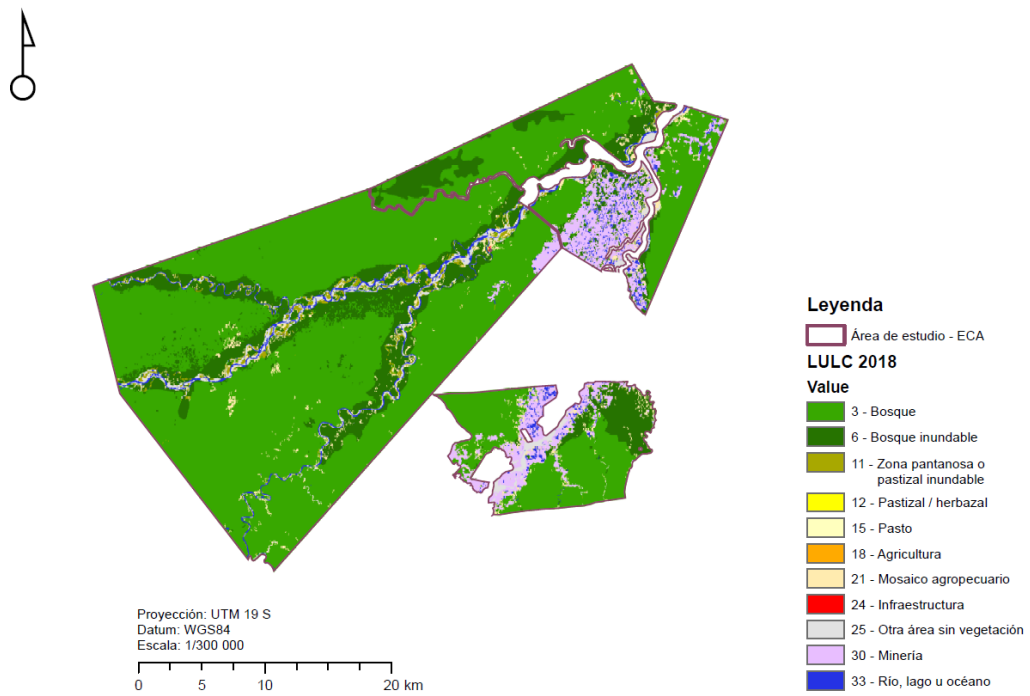
Anexo 4.10. LULC 2024 de la comunidad nativa Puerto Azul.



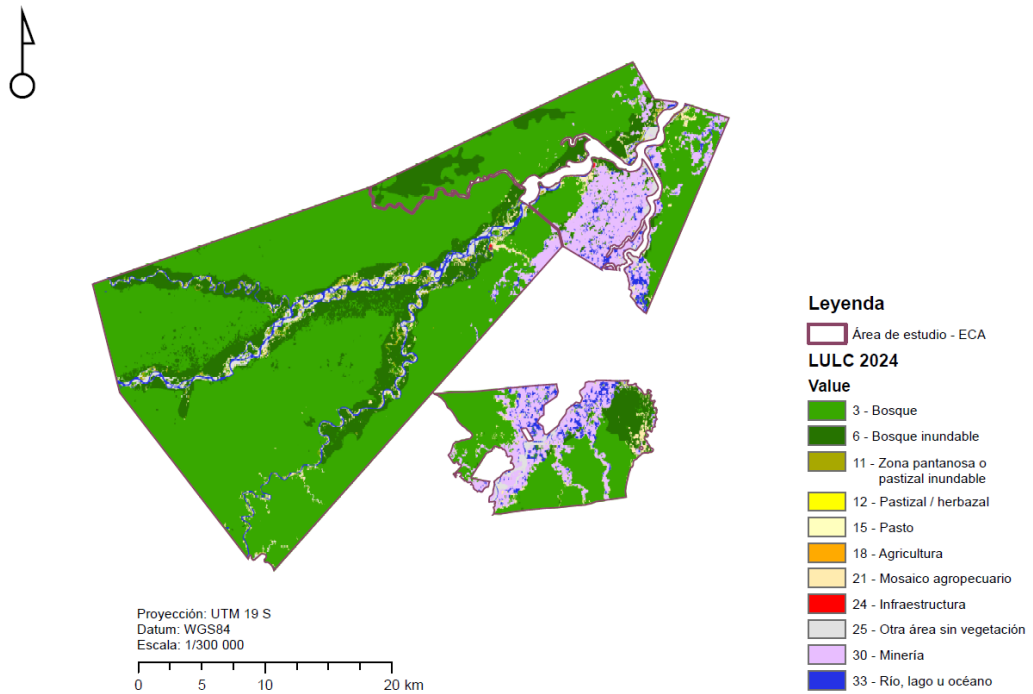
Anexo 4.11. LULC 2018 de la comunidad nativa de Boca Isiriwe y Masenawa.



Anexo 4.12. LULC 2024 de la comunidad nativa de Boca Isiriwe y Masenawa.



Anexo 4.13. LULC 2018 de la comunidad nativa de Puerto Luz, San José de Karene y Barranco Chico.



Anexo 4.14. LULC 2024 de la comunidad nativa de Puerto Luz, San José de Karene y Barranco Chico.