

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS

FACULTAD DE INGENIERÍA

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



TESIS

**“Cuantificación de la deforestación mediante la combinación
de datos de sensores ópticos y de radar en el sureste de la
Amazonia Peruana, provincia de Tahuamanu – Madre
de Dios, periodo 2021”**

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

AUTOR:

Bach: DEL AGUILA SURI, Jhon
Enrique

Asesor:

Dr. Gabriel Alarcón Aguirre

Puerto Maldonado, abril 2026

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS

FACULTAD DE INGENIERÍA

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



TESIS

**“Cuantificación de la deforestación mediante la combinación
de datos de sensores ópticos y de radar en el sureste de la
Amazonia Peruana, provincia de Tahuamanu – Madre
de Dios, periodo 2021”**

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

AUTOR:

Bach: DEL AGUILA SURI, Jhon
Enrique

Asesor:

Dr. Gabriel Alarcón Aguirre

Puerto Maldonado, abril 2026

RST-RI_Cuantificación de la deforestación mediante la combinación de datos de sensores ópticos y de radar en el sureste de la Amazonia Peruana, provincia de Tahuamanu – Madre de Dios, periodo 2021

INFORME DE ORIGINALIDAD

18%	17%	2%	4%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.unamad.edu.pe	17%
	Fuente de Internet	
2	Submitted to Universidad de Costa Rica	1%
	Trabajo del estudiante	
3	repositoriobibliotecas.uv.cl	1%
	Fuente de Internet	

Excluir citas	Activo	Excluir coincidencias	< 1%
Excluir bibliografía	Activo		

Dedicatoria

Al señor todo poderoso, por protegerme y darme fuerzas para rebasar los obstáculos a lo largo de mi vida.

A mi mamá Aida Norma, a mi abuelo Emiliano, a mi tío Wilson y demás familiares, por apoyarme en todo momento, por los valores que me han inculcado, por creer en mí, por los consejos que todos los días me brindan, en ser una persona de bien y poder cumplir una de mis metas, del ser Ingeniero Forestal y Medio Ambiente. También quiero agradecer a mis compañeros de la universidad, por sus apoyos y consejos. A mi abuela, que desde el cielo me guía en todo paso que doy.

Este trabajo con mucho cariño va para ustedes.

Agradecimientos

A mi casa de estudio, la universidad Nacional Amazónica de Madre de Dios por brindarme la oportunidad de recibir una formación profesional, a la Facultad de ingeniera Forestal y Medio Ambiente por proyectarme en esta profesión y a los docentes por contribuir con sus enseñanzas para mi formación como profesional.

De igual forma, agradecer a mi asesor de tesis, el Dr. Gabriel Alarcón Aguirre, por su guía, orientación, aporte y conocimientos a la presente investigación.

Por último, agradecer todas mis amistades que con su aporte y sugerencia han contribuido en la culminación del presente trabajo de investigación.

Resumen

La fusión y/o combinación de imágenes de satélites ópticas y SAR tiene el potencial de optimizar el monitoreo de cubierta terrestre en la Amazonia tropical, donde los fenómenos climáticos dificultan las observaciones de satélites ópticos. La investigación “análisis la fusión de datos Landsat y de radar de apertura sintética (SAR) de banda C para cuantificar la deforestación” en la provincia de Tahuamanu – Madre de Dios, sur este de la Amazonia peruana. Se clasificó los datos de Landsat-8 bandas 6, 5, 4, y SAR “Sentinel-1 de la Agencia Espacial Europea (ESA)”, usando el algoritmo de clasificación Random Forest para detectar y cuantificar la deforestación para 2021. Se comparó las precisiones de clasificación de los datos de sensores individuales versus combinados. Los datos combinados de Landsat-8 (incluido NDVI) y SAR Sentinel-1 de banda C con polarizaciones VV y VH produjeron las mejores precisiones de clasificación general e índice de kappa (88% - 0,84), superando a los datos de sensores individuales (84% - 0,80 para Landsat y 82% - 0,78 para SAR). El SAR fue un predictor influyente en la determinación profunda de áreas húmedas relacionadas con la deforestación, a diferencia de los ópticos que muestra un panorama general del paisaje. La deforestación cuantificó para Landsat-8 19435,65 ha, 142,14 ha para SAR Sentinel-1, y 27125,04 ha para la combinación de Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1. Los resultados de la fusión de datos Landsat y SAR de banda C proporciona una mejor precisión y contexto de los motores de la deforestación y la dinámica del paisaje de bosques tropicales.

Palabras clave: Bosque, pérdida de bosques, Landsat-8, Sentinel-1, Random Forest.

Abstract

The fusion and/or combination of optical and SAR satellite imagery has the potential to optimize land cover monitoring in tropical Amazonia, where climatic phenomena hinder optical satellite observations. The research "analyzed the fusion of Landsat and C-band synthetic aperture radar (SAR) data to quantify deforestation" in the province of Tahuamanu - Madre de Dios, southeastern Peruvian Amazon. We classified Landsat-8 bands 6, 5, 4, and European Space Agency (ESA) Sentinel-1 SAR data using the Random Forest classification algorithm to detect and quantify deforestation by 2021. The classification accuracies of the individual versus combined sensor data were compared. Combined Landsat-8 (including NDVI) and C-band Sentinel-1 SAR data with VV and VH polarizations produced the best overall classification accuracies and kappa index (88% - 0.84), outperforming individual sensor data (84% - 0.80 for Landsat and 82% - 0.78 for SAR). SAR was an influential predictor in the deep determination of wet areas related to deforestation, unlike optics which shows a general landscape overview. Deforestation quantified for Landsat-8 19435.65 ha, 142.14 ha for SAR Sentinel-1, and 27125.04 ha for the combination of Landsat-8 (bands; 6,5,4+NDVI) and SAR Sentinel-1. The results of merging Landsat and C-band SAR data provide better accuracy and context of the drivers of deforestation and tropical forest landscape dynamics.

Key words: Forest, forest loss, Landsat-8, Sentinel-1, Random Forest.

Índice de contenidos

Pág.

Dedicatoria.

Agradecimientos

Resumen

Abstract.

Introducción ..

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN1

1.1 Planteamiento del problema de investigación1

1.2 Formulación del problema.....3

1.2.1 Problema general3

1.2.2 Problemas específicos.....3

1.3 Justificación e importancia3

1.4 Objetivos de la investigación5

1.4.1 Objetivo general5

1.4.2 Objetivos específicos.....5

1.5 Hipótesis.....6

1.6 Variables de la investigación6

1.6.1 Identificación de variables6

1.6.2 Operacionalización de variables.....7

1.7 Consideraciones éticas8

CAPÍTULO II: MARCO TEÓRICO.....9

2.1 Antecedentes de la investigación9

2.2 Base teórica13

2.2.1 Bosque13

2.2.2 Deforestación	13
2.2.4 Sistemas de Información Geográfica (SIG)	17
2.2.5 Teledetección	15
2.2.3 Energía electromagnética	16
2.2.4 Tipos de teledetección	18
2.2.5 Plataforma y sensores	19
2.2.6 Sistemas de exploración lateral u oblicua (RADAR)	21
Resolución espacial	23
2.2.8 Clasificación de imágenes	25
Clasificación supervisada	26
2.2.9 Random Forest (RF)	27
2.2.10 Software de procesamiento de imágenes	27
SNAP ESA	27
Google Earth Engine (GEE)	27
ArcGIS	28
2.2.11 Misiones Landsat	28
Landsat 8	29
2.2.11 Programa Copérnico	31
Sentinel-1	31
2.3 Definición de términos	33
CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN	34
3.1 Tipo de investigación	34
3.2 Diseño de la investigación	34
3.3 Delimitación espacial y temporal	34
3.3.1 Clima e hidrografía	36
3.4 Población y muestra	36

3.5 Técnicas e instrumentos de recolección de datos.....	38
3.5.1 Método y técnicas	38
3.5.2 Procesamiento de datos y análisis estadístico	41
Tratamiento y análisis de imágenes Landsat y SAR	43
Tratamiento de datos	47
Análisis estadístico.....	48
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	50
4.1 Clasificación y superficie de la deforestación en la provincia de Tahuamanu	50
4.1.1 Clasificación de imágenes de satélite Óptica, SAR, y Óptica-SAR.....	50
4.1.2 Deforestación por tipo de sensor; Óptica, SAR, y Óptica-SAR.....	55
4.1.3 Evaluación de precisión de clasificación.....	60
CONCLUSIONES	63
RECOMENDACIONES	64
REFERENCIAS BIBLIOGRÁFICAS	65
ANEXOS	81

Índice de Tablas

	Pág.
Tabla 1. Operacionalización de variables.....	7
Tabla 2. Misiones de satélite SAR y radiómetro	23
Tabla 3. Características de Landsat 8 Operational Land Imager (OLI) y Thermal Infrared Sensor (TIRS).....	30
Tabla 4. Características de la imagen de satélite Sentinel-1.....	32
Tabla 5. Información de adquisición de imágenes Landsat y Sentinel-1	43
Tabla 6. Leyenda de cobertura de la tierra adaptada al área de estudio	45
Tabla 7. Valoración del coeficiente kappa	47
Tabla 8. Deforestación en la provincia de Tahuamanu por tipo de sensor, periodo 2021	56
Tabla 9. Precisión de resultados del sensor óptico Landsat-8, SAR Sentinel-1, y la combinación de Óptico-SAR.....	61

Índice de Figuras

	Pág.
Figura 1. Detección remota mediante sensores activos y pasivos.	17
Figura 2. Onda electromagnética; vectores eléctricos (E) y magnéticos (M).	17
Figura 3. Relaciones entre longitud de onda, frecuencia y energía.	18
Figura 4. El espectro electromagnético.	18
Figura 5. Tipos de sensores y plataformas.....	21
Figura 6. Ángulo de incidencia del radar y local.	22
Figura 7. Errores geométricos en RADAR.	23
Figura 8. Proceso de clasificación de imágenes de satélite.	28
Figura 9. Ubicación de área estudio.	35
Figura 10. Distribución de muestras para validar la deforestación en la provincia de Tahuamanu.....	38
Figura 11. Imagen óptica landsat-8 con bandas RGB: 6-5-4 (2021) y Sentinel- 1 (2021), polarización VV y VH, y RGB VV-VH-VV/VH de la provincia de Tahuamanu.....	42
Figura 12. Validación de áreas artificializadas, áreas agrícolas, bosques y áreas mayormente naturales, y áreas húmedas continentales con imágenes WorldView de 0,38 m x 0,38 m de resolución espacial (a y b), imágenes PlanetScope de 3 m x 3 m de resolución espacial (c), y CBERS de 2 m x 2 m de resolución espacial.	48
Figura 13. Imagen de Satélite Sentiel-1, firmas espectrales en las bandas R (VV) G (VH) B (VV-VH); (a) Áreas artificializadas, (b) Áreas Agrícolas, (c) Bosques y áreas mayormente naturales, (d) Áreas húmedas continentales, y (e) Superficies de agua.	52
Figura 14. Imagen de Satélite Landsat-8 OLI, firmas espectrales en las bandas R (6) G (5) B (4); (a) Áreas artificializadas, (b) Áreas Agrícolas, (c)	

Bosques y áreas mayormente naturales, (d) Áreas húmedas continentales, y (e) Superficies de agua.	53
Figura 15. Índice de Vegetación de Diferencia Normalizada (NDVI) de Satélite Landsat-8 OLI.	54
Figura 16. Clasificación de cobertura y uso de suelo de imagen óptico Landsat-8 para cuantificar la deforestación de la provincia de Tahuamanu al año 2021.....	56
Figura 17. Clasificación de cobertura y uso de suelo de imagen SAR Sentinel-1 con polarización VV/VH/VV-VH para cuantificar la deforestación de la provincia de Tahuamanu al año 2021.	57
Figura 18. Clasificación de cobertura y uso de suelo mediante la combinación de imágenes Landsat-8 (bandas 6,5,4 + NDVI) y SAR Sentinel-1 (VV/VH/VV-VH) para cuantificar la deforestación de la provincia de Tahuamanu al año 2021.	58
Figura 19. Pérdida de la cubierta forestal y deforestación en la provincia de Tahuamanu al año 2021, mediante el sensor óptico Landsat-8 y SAR Sentinel-1.....	59

Índice de anexos

	Pág.
Anexo 1. Puntos de muestreo tomados en la microcuenca del río Paríamanu.	85
Anexo 2. Panel fotográfico	97

Introducción

La tercera parte de la tierra está cubierta por bosques, lo que representa 4 060 hectáreas (ha), de los cuales se ha deforestado 420 millones de hectáreas desde 1990 (FAO 2020; Hernández 2020). En esta situación, en ese tiempo se perdió el 6,3% de bosque primario húmedo en el mundo. Mientras que la proporción y distribución de la superficie por zona climática, los bosques tropicales representan el 45% (FAO 2020), donde el cambio cobertura y uso del suelo (CCUS), y en particular la pérdida de bosque por deforestación, en total, 4,2 millones de ha de bosques fueron afectados, esta pérdida se tradujo en 2,64 gigatoneladas de emisiones de CO₂, correspondiendo al segundo lugar en cuanto a emisiones después de la combustión de combustibles fósiles (FAO 2020; Hernández 2020). A nivel de la cuenca Amazónica en general, en promedio, se deforesta aproximadamente a un ritmo de 70 km²/día, perteneciendo a la Amazonia brasileña las mayores pérdidas (RAISG, 2020). En cuanto a la Amazonia peruana, del 2001 al 2019 se deforestaron alrededor de 2 433 314 ha, para el mismo periodo, Madre de Dios reporta una pérdida de 231,111 ha (9,50%) y la provincia del Tahuamanu con 56 528 ha (24,46% respecto a Madre de Dios y 2,32 al Perú) (INPE 2020a; INPE 2020b; MINAM 2020).

En la región amazónica, el mapeo anual de la deforestación (tala rasa) se han dado principalmente a partir de datos sensores ópticos, con mayor frecuencia el Landsat, Spot y CBERS, y más recientemente Sentinel y PlanetScope, a través de instituciones como el Ministerio del Ambiente de Perú (MINAM), Comisión Nacional de Investigación y Desarrollo Aeroespacial (CONIDA), el “Instituto Nacional de Investigaciones Espaciales de Brasil (Instituto Nacional de Pesquisas Espaciais, INPE)”, y la Red Amazónica de Información Socioambiental Georreferenciada (RAISG 2015; INPE 2020a; INPE 2020b; MINAM 2020; RAISG 2020), así como investigadores locales e internacionales (Swenson et al. 2011; Asner et al. 2013; Chávez et al. 2013; Perz et al. 2013; Asner et al. 2014; Alarcón et al. 2016; Perz et al. 2016; Asner y Tupayachi 2017; Bax y Francesconi 2018; Caballero et al. 2018; Cabral et al. 2018; Carvalho et al. 2019; Rezende y Vieira 2019)

Varios son los factores que han contribuido a estos cambios observados de bosque a deforestación, como la mejora y la apertura nuevas estradas de comunicación secundaria conectadas a la Vía Interoceánica Sur. Por otro lado, la mejora de senderos carrozables y accesos para extracción de madera que se ejecutan sin autorización ambiental. Asimismo, conecta espacios de bosques primarios con actividades que en su mayoría son motores de la pérdida de bosques, desde agricultura de pan llevar y cultivos permanentes, hasta aquellas actividades como la minería de oro ilegal, tráfico de tierras, tala ilegal, entre otros. (Alarcón, et al. 2016; Asner y Tupayachi 2017; Bax y Francesconi 2018; Caballero, et al. 2018; Cabral, et al. 2018; Murad y Pearse 2018; Carvalho, et al. 2019; Velásquez et al. 2021). La deforestación generalmente da como resultado el reemplazo de bosques por tierras de cultivo y pastos, pero estos a menudo se abandonan después de unos años y se reemplazan por bosques secundarios (Lennox et al. 2018; Elias et al. 2020; Huamani et al. 2021). El mapeo de la cobertura terrestre son obtenidos generalmente del proceso de sensores pasivos de alta y mediana resolución (Rajah et al. 2018), sin embargo, la aplicación de estos métodos a veces se ve gravemente obstaculizada por la nubosidad frecuente en las regiones tropicales, lo que lleva a que algunas regiones tengan una cobertura deficiente de los sensores ópticos (Asner, et al. 2013; Asner, et al. 2014; Alarcón, et al. 2016; Asner y Tupayachi 2017). Por esta razón, los productos de “radar de apertura sintética (SAR)” Sentinel-1 es funcional para todo clima y se utilizan y promueven cada vez más para mejorar el monitoreo del CCUS suelo terrestre en las regiones tropicales (Reiche et al. 2015; Sica et al. 2019; Puzzi et al. 2020). Los datos SAR pueden proporcionar información relacionada con los parámetros estructurales de pérdida de bosque (Reiche, et al. 2015; Sica, et al. 2019; Puzzi, et al. 2020) que podría resultar útil a la hora de cuantificar la deforestación, así como complementar y combinar con la información proporcionada por los sensores ópticos (Reiche, et al. 2015; Rajah, et al. 2018).

La aplicación de SAR para cuantificar la deforestación no es novedoso, sin embargo, la información es limitada y no es de acceso abierto (Rajah, et al. 2018; Puzzi et al. 2021). Conocida la fiabilidad de los SAR en diferentes

tipos de cobertura, contrasta con los diferentes tipos de bosque, zonas de transición, pasturas y agricultura de la provincia de Tahuamanu. El objetivo de la investigación es el uso combinado de una sola fecha óptica (Landsat 8 OLI) y SAR (Sentinel-1) en fase de banda C para: “determinar la deforestación en la Amazonia de Tahuamanu – Madre de Dios”.

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1 Planteamiento del problema de investigación

La deforestación de la Amazonia afecta directamente y reduce los recursos naturales forestales y los servicios de los ecosistemas; dañando el hábitat, reducir la biodiversidad y fuentes de suministros, contaminar ríos y tierras, degradando el suelo, y afectando la producción de las personas y los animales que se benefician (Perz, et al. 2016; Chirif 2018).

En ese sentido, la cuantificación y los motores que la impulsan son los desafíos de los países Amazónicos y de las entidades gestoras, donde, la precisión de las tasas de deforestación es relativo, y depende de la tecnología a utilizar (Rajah, et al. 2018; Steinhausen et al. 2018; Puzzi, et al. 2021).

Los métodos tradicionales están basados en el uso de sensores ópticos para el monitoreo de la pérdida de bosques, sin embargo, están limitados al alto costo (imágenes de alta resolución) y las barreras atmosféricas que limitan su visibilidad, principalmente por la alta nubosidad presente en la Amazonia (Rajah, et al. 2018; Steinhausen, et al. 2018; Huang et al. 2020; Puzzi, et al. 2021).

Recientemente, la aplicación de sensores activos en la teledetección ha permitido mejorar el potencial como fuente complementaria de información a las imágenes ópticas de teledetección. El “radar de apertura sintética (SAR)” ofrece información de mayor gama de las características de los objetos que se hacen complicados identificar, como la forma, la humedad y la rugosidad (Chen et al. 2010; Rajah, et al. 2018; Steinhausen, et al. 2018; Puzzi, et al. 2021). A pesar de ello, la adopción de imágenes SAR para detectar la deforestación, se ve limitada por las limitaciones en el acceso y el alto costo de adquisición, así como su complejidad en el preprocesamiento y procesamiento de datos (McNairn et al. 2009; Rajah, et al. 2018; Steinhausen,

et al. 2018; Puzzi, et al. 2021). Sin embargo, el reciente lanzamiento de Sentinel-1 (abril de 2014), una iniciativa entre la CE y la ESA, posteriormente la provisión de sus datos SAR gratuitos brinda nuevas oportunidades para mapear la pérdida de bosques. Sentinel-1 tiene un barrido aproximado de 400 km y está equipado con un sensor SAR de banda C que funciona en cuatro modos de imagen exclusivos (ESA 2013; Potin 2013). Los datos SAR pueden operar en longitudes de onda independientemente de las condiciones de las nubes o la falta de iluminación y son capaces de adquirir datos durante el día y la noche (ESA 2013; Potin 2013).

La complementariedad entre el SAR y las imágenes ópticas multiespectrales tiene un gran potencial en el sensoramiento remoto. Las imágenes ópticas multiespectrales poseen información de reflectancia y emisividad de la superficie, mientras que las imágenes de SAR capturan la estructura y la retrodispersión de los objetos de la superficie terrestre (Zhu et al. 2012; Rajah, et al. 2018; Steinhausen, et al. 2018; Puzzi, et al. 2021). Dicha complementariedad, lograda mediante combinación de datos, mejora la interpretación de los datos de origen, incluyendo una mayor confiabilidad de la salida, menor incertidumbre en torno a las características del objetivo con reflectancia espectral (Zhang 2010; Gharbia et al. 2014; Rajah, et al. 2018; Steinhausen, et al. 2018; Puzzi, et al. 2021).

Las mediciones de sensores SAR de cobro revertido de retrodispersión en decibeles (dB) depende de la rugosidad, la geometría y el contenido del objeto de destino (Hong et al. 2014; Rajah, et al. 2018; Steinhausen, et al. 2018; Puzzi, et al. 2021), mientras las imágenes ópticas, proporcionan imágenes adecuadas e interpretables para la medición de amplias clases “cobertura y uso del suelo”. Esta complementariedad aumenta la precisión en la delimitación y caracterización más precisa (McNairn, et al. 2009; Hong, et al. 2014; Sameen et al. 2016; Huang, et al. 2020).

Bajo esta premisa, la investigación propone un método novedoso, el uso combinado de una sola fecha óptica (Landsat 8 OLI) y SAR (Sentinel-1) en fase de banda C para: “determinar la deforestación en la Amazonia de Tahuamanu – Madre de Dios”.

1.2 Formulación del problema

1.2.1 Problema general

¿Cuánto será la superficie deforestada mediante la combinación de datos de sensores Ópticos y de Radar en el sureste de la Amazonia peruana, provincia de Tahuamanu – Madre de Dios, periodo 2021?

1.2.2 Problemas específicos

P.E.1 ¿Cuánto será la superficie deforestada mediante el uso del sensor óptico Landsat 8 OLI en el sureste de la Amazonia peruana - Tahuamanu, periodo 2021?

P.E.2 ¿Cuánto será la superficie deforestada mediante el uso del sensor de radar de apertura sintética (SAR) Sentinel-1 en el sureste de la Amazonia peruana – Tahuamanu, periodo 2021?

P.E.3 ¿Cuánto será la superficie deforestada mediante la combinación de datos de sensores ópticos Landsat 8 OLI y SAR Sentinel-1 en el sureste de la Amazonia peruana – Tahuamanu, periodo 2021?

P.E.4 ¿Cuál es el nivel de precisión en la cuantificación de la deforestación mediante el uso del sensor óptico Landsat 8 OLI, SAR Sentinel-1, y la combinación de sensores ópticos y de radar en el sureste de la Amazonia peruana, Tahuamanu?

1.3 Justificación e importancia

La teledetección proporciona datos a nivel mundial por satélites y localmente por aviones tripulados y no tripulados conocidos como Drones (Steinhausen, et al. 2018). Estos conjuntos de datos pueden utilizarse para obtener información detallada sobre diversos procesos relacionados con el “cambio de cobertura y uso de suelo (CCUS)”, como la “deforestación o pérdida de bosques”.

En las últimas décadas, los datos de teledetección se han vuelto más disponibles y accesibles y pueden considerarse una piedra angular en diferentes campos de análisis y monitoreo ambiental (Dong et al. 2019), especialmente en agricultura (Lesiv et al. 2018), silvicultura (Hansen et al. 2013), crecimiento urbano (Melchiorri et al. 2018; Zhu et al. 2019), y el monitoreo de la deforestación (Alarcón, et al. 2016; Asner y Tupayachi 2017).

Aunque los datos de teledetección multiespectrales se han utilizado con éxito durante mucho tiempo para las clasificaciones de la cobertura terrestre (Alarcón, et al. 2016; Joshi et al. 2016; Caballero, et al. 2018), los sistemas ópticos de observación de la Tierra afrontan el desafío de adquirir datos con una cobertura mínima de nubes. Muchos estudios han demostrado la dificultad de obtener imágenes adecuadas sin nubes a partir de sistemas ópticos (Asner, et al. 2013; Alarcón, et al. 2016; Asner y Tupayachi 2017; Caballero, et al. 2018). Por lo que, la disponibilidad de datos se vuelve limitada cuando se necesita más de una observación por periodo (Asner, et al. 2013; Asner y Tupayachi 2017), lo que parece particularmente relevante en cuantificar la deforestación. La Amazonia de la provincia del Tahuamanu está sujeta a esas características. La temporada de lluvias en el área de investigación se asocia principalmente con el monzón sudamericano de invierno (octubre-abril) (Mariaca y Andrés 2007). Por lo tanto, es difícil adquirir suficientes imágenes ópticas para mapear con precisión el CCUS durante temporadas de lluvias.

Los sistemas activos, como el radar, no dependen de la luz solar, pueden operar independientemente de las condiciones climáticas y la hora del día y, por lo tanto, superan las limitaciones de los sistemas pasivos (Mariaca y Andrés 2007). Los datos de radar son adecuados para las clasificaciones CCUS en regiones propensas a las nubes como la selva Amazónica (Rajah, et al. 2018; Steinhausen, et al. 2018). Además, los datos d SAR proporcionan información diferente pero complementaria sobre CCUS, en comparación con imágenes multiespectrales. Aunque la combinación del uso de la tierra de datos multiespectrales y de radar en la medición de CCUS es atractiva, rara vez se utiliza (Joshi, et al. 2016). Sin embargo, muchos investigadores

determinaron una mayor precisión cartográfica mediante el uso combinado de datos ópticos y de radar en comparación con las clasificaciones de cobertura terrestre mono-sensoriales (Stefanski et al. 2014; Rajah, et al. 2018; Steinhausen, et al. 2018; Puzzi, et al. 2021) .

En particular, con respecto a las áreas deforestadas que se caracterizan por una gran variabilidad temporal, la alta tasa de repetición de la constelación Sentinel y la mediana repetición del Landsat parecen prometedoras. “La investigación se centra en la clasificación supervisada de imágenes ópticas, de Radar de Apertura Sintética (SAR), y la combinación de ambos para la cuantificación de la deforestación en la Amazonia peruana – Tahuamanu”. Para el desarrollo favorable de la investigación, “se contará con el apoyo del Centro de Teledetección para el Estudio y Gestión de los Recursos Naturales (CETEGERN)”.

1.4 Objetivos de la investigación

1.4.1 Objetivo general

Cuantificar la superficie deforestada mediante la combinación de datos de sensores Ópticos y de Radar en el sureste de la Amazonia peruana, provincia de Tahuamanu, periodo 2021

1.4.2 Objetivos específicos

O.E.1 Cuantificar la superficie deforestada mediante el uso del sensor óptico Landsat 8 OLI en el sureste de la Amazonia peruana - Tahuamanu, periodo 2021.

O.E.2 Cuantificar la superficie deforestada mediante el uso del sensor de radar de apertura sintética (SAR) Sentinel-1 en el sureste de la Amazonia peruana – Tahuamanu, periodo 2021.

O.E.3 Cuantificar la superficie deforestada mediante la combinación de datos de sensores ópticos Landsat 8 OLI y SAR Sentinel-1 en el sureste de la Amazonia peruana – Tahuamanu, periodo 2021.

O.E.4 Determinar el nivel de precisión en la cuantificación de la deforestación mediante el uso del sensor óptico Landsat 8 OLI, SAR Sentinel-1, y la combinación de sensores ópticos y de radar en el sureste de la Amazonia peruana - Tahuamanu.

1.5 Hipótesis

Hipótesis nula (H_0): La cuantificación de la deforestación en la Amazonia peruana (Tahuamanu) mediante la combinación del sensor óptico Landsat 8 OLI y SAR Sentinel-1, no reporta una mayor precisión respecto a los resultados del sensor óptico y SAR.

Hipótesis alterna (H_1): La cuantificación de la deforestación en la Amazonia peruana (Tahuamanu) mediante la combinación del sensor óptico Landsat 8 OLI y SAR Sentinel-1, reporta una mayor precisión respecto a los resultados del sensor óptico y SAR.

1.6 Variables de la investigación

1.6.1 Identificación de variables

Variable Dependiente

- ✓ Categorías de cobertura y uso de suelo en la unidad mínima de la imagen (píxel) en imágenes ópticas Landsat 8 OLI, SAR Sentinel-1, y la combinación de sensores ópticos y de radar.

Variable Independiente

- ✓ Áreas deforestadas y de bosques en el periodo 2021.

1.6.2 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				
Análisis de la superficie deforestada mediante imágenes L8 OLI permite cartografiar y clasificar en un espacio de tiempo.	Cuantificar las áreas deforestadas y de bosques en la provincia de Tahuamanu, periodo 2021.	Áreas deforestadas por actividad agrícola, pasturas, infraestructuras, entre otras.	Superficie en hectáreas por tipos de cobertura y uso de suelo.	1
Análisis de la superficie deforestada mediante el uso de SAR S1 permite cartografiar y clasificar en un espacio de tiempo.	Cuantificar las áreas deforestadas y de bosques en la provincia de Tahuamanu, periodo 2021.	Áreas deforestadas por actividad agrícola, pasturas, infraestructuras, entre otras.	Superficie en hectáreas por tipos de cobertura y uso de suelo.	2
Análisis de la superficie deforestada mediante la combinación de datos de sensores ópticos Landsat 8 OLI y SAR Sentinel-1 permite cartografiar y clasificar en un espacio de tiempo con mayor precisión.	Cuantificar las áreas deforestadas y de bosques en la provincia de Tahuamanu, periodo 2021.	Áreas deforestadas por actividad agrícola, pasturas, infraestructuras, entre otras.	Superficie en hectáreas por tipos de cobertura y uso de suelo.	3
La medición de la precisión de la cuantificación de la deforestación mediante el uso del L8 OLI, SAR S1, y la combinación de sensores ópticos y de radar permite validar los resultados.	Validación de resultados con información de campo y sensores de alta resolución.	Matriz de Confusión (Índice Global) e Índice de Kappa (k).	Índices.	4
Variable dependiente				
Comportamiento de la cobertura y uso de suelo en el pixel en L8 OLI, SAR S1, y la combinación de L8 y S1.	Firma espectral por tipo categoría en la unidad de medida (pixel).	Rango espectral por cobertura y uso de suelo en imágenes ópticas Landsat 8 OLI, SAR Sentinel-1.	Coberturas y uso de suelo.	5

1.7 Consideraciones éticas

La investigación se desarrolló de acuerdo a los lineamientos del Reglamento de Grados y Títulos de la UNAMAD.

Por situación de emergencia sanitaria, el tesista no ingreso a las instalaciones del CETEGERN, por lo que, solo utilizo las licencias comerciales de manera remota.

En cuanto a directriz nacional, la investigación se enmarca en la política nacional del CONIDA “Comisión Nacional de Investigación y Desarrollo Aeroespacial”.

En cuanto a la validación en campo, se cumplió todas las medidas de seguridad (COVID19), ello permitirá evitar riesgos en el transporte, alimentación, y entrevista en caso de ser necesario.

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de la investigación

De Alban et al. (2018) clasificaron la cobertura terrestre y la detección de cambios en paisajes tropicales dinámicos de Tanintharyi, en el sur de Myanmar mediante la combinación de datos Landsat y SAR de banda L. Para ello Clasificaron los datos de Landsat y SAR de banda L, el algoritmo Random Forest fue empleado para mapear y cuantificar las transiciones de cambio de cobertura y uso de suelo entre 1995 y 2015. Compararon las recisiones de clasificación de datos de sensores individuales versus combinados, y contribuciones evaluadas de las capas ópticas y de radar a la precisión de la clasificación. La fusión de Landsat y SAR de banda L produjeron las mejores precisiones de clasificación general (92,96% a 93,83%), superando los datos de sensores individuales (91,20% a 91,93% para Landsat solo; 56,01% a 71,43% para SAR solo). El cambio de paisaje fue extenso (16 490 km²; 39% del área total), así como la conversión total de bosques en plantaciones agrícolas (3 214 km²), la pérdida bruta de bosques (5 133 km²) en 1995 se debió principalmente a la conversión a arbustos/huertos y plantaciones de árboles (palma aceitera, caucho), y las ganancias brutas en plantaciones de palma aceitera (5 471 km²) y caucho (4 025 km²) para 2015 fueron principalmente por la conversión de arbustos/huertos y bosques.

Erinjery et al. (2018) mapearon y evaluaron los tipos de vegetación en las selvas tropicales de los Ghats occidentales utilizando imágenes de satélite multiespectrales Sentinel-2 y SAR Sentinel-1. El estudio determinó la capacidad de las bandas ópticas multiespectrales Sentinel-2 MSI, su NDVI, y bandas SAR Sentinel-1 utilizando la clasificación de bosque de máxima verosimilitud y aleatoria. La clasificación tuvo una alta precisión (> 75%), especialmente en comparación con los esfuerzos de clasificación anteriores,

asimismo enfatizan la importancia de utilizar índices de vegetación y texturas para la clasificación de tipos de vegetación en los Ghats occidentales.

Rajah, et al. (2018) estudiaron la fusión de imágenes ópticas y radar de apertura sintética (SAR) para la detección y el mapeo de especies de plantas exóticas invasoras, para ello, fusionaron dos medios espaciales e imágenes de resolución espectral (Sentinel-2 y Landsat 8) con datos de teledetección activos (imágenes de radar de apertura sintética) para determinar la estación óptima para detectar y mapear la zarza americana (*Rubus cuneifolius*). Adoptaron la fusión de imágenes a nivel de función para integrar imágenes de detección remota pasivas y activas, así como la clasificación Support vector machine (SVM, clasificación supervisada por máquina de vectores de soporte), algoritmo utilizado para discriminar la zarza americana de la vegetación nativa circundante, los resultados estacionales mostraron que los datos de Sentinel-2, fusionados con los datos de SAR, generaron la mayor precisión de clasificación durante el verano (76%), mientras que las imágenes de Landsat 8 fusionadas con los datos de SAR se desempeñaron mejor en invierno (72%). Estos hallazgos demuestran que la fusión de SAR con imágenes ópticas tradicionales se puede utilizar para detectar y mapear la zarza americana a escala regional. Llegando a la conclusión de que los datos de SAR se pueden utilizar de forma sinérgica con la teledetección óptica para mejorar la discriminación y el mapeo de la zarza americana (Rajah, et al. 2018).

Reiche et al. (2018) mejoraron la detección y cuantificación de la pérdida de bosques secos tropicales en Bolivia mediante la “combinación de series de tiempo Sentinel-1 con Landsat-7/ETM+, 8/OLI, y ALOS-2 PALSAR-2”. Los resultados mostraron que la deforestación se detecta más oportunamente con Sentinel-1 que en comparación con Landsat y ALOS-2 PALSAR-2. Las precisiones espaciales y temporales del enfoque multisensor fueron más altas que los resultados de un solo sensor, mejorando la precisión de los datos de referencia derivados de la serie temporal de satélites multisensores, lo que permitió una estimación más sólida de la precisión temporal. La deforestación se detectó con una precisión del usuario del 88%,

una precisión del productor del 89% en tiempo medio de 31 días utilizando todos los sensores.

Steinhausen, et al. (2018) mapearon la cobertura terrestre de las regiones monzónicas; Chennai, ubicada en el norte de Tamil Nadu y el sur de Andhra Pradesh, India, combinando datos de Sentinel-1 y Sentinel-2. El estudio tuvo como objetivo generar un mapa cobertura y uso del suelo para la temporada de cultivo de Rabi (2015/16) y evaluar la combinación de los satélites Sentinel-1 y -2 de la ESA Copérnico en las precisiones de clasificación. Se aplicó un enfoque de envoltura basado en Random Forest para seleccionar las imágenes de radar (Sentinel-1) más relevantes para la combinación con los datos ópticos (Sentinel-2). La precisión general más alta de $91,53\% \pm 0,89$ pp se logró con una combinación de 1 escena Sentinel-2 y 8 escenas Sentinel-1. El estudio muestra cómo se pueden mejorar la “clasificación de la cobertura y uso del suelo” en regiones propensas a las nubes con monzones con agricultura a pequeña escala y patrones de cultivo múltiples combinando datos de Sentinel-1 y Sentinel-2.

Chatziantoniou et al. (2017) mapearon el CCUS con sensores Sentinel-1 y -2 en humedales de un entorno mediterráneo; Parque Nacional Koronia y los Lagos Volvi (NPKV) ubicado en Grecia. Este estudio tuvo como objetivo evaluar el uso sinérgico de los datos Sentinel-1 y Sentinel-2 combinados con el clasificador de aprendizaje automático Support Vector Machines (SVM). La evaluación de la precisión de CCUS se basó en el cálculo de las estadísticas de error de clasificación y el coeficiente kappa. Los resultados de nuestro estudio ejemplificaron la idoneidad de la resolución espacial y espectral de los datos de Sentinel para obtener una cartografía CCUS rápida y rentable. Los resultados de clasificación más precisos se obtuvieron cuando se incluyó la información espectral adicional para ayudar a la implementación de la clasificación, aumentando la precisión general de 90,83% a 93,85% y kappa de 0,894 a 0,928. Una corrección posterior a la clasificación (PCC) que utiliza reglas lógicas basadas en el conocimiento mejoró aún más la precisión general a 94,82% y kappa a 0,936. Una corrección posterior a la clasificación (PCC) que utiliza reglas lógicas basadas en el conocimiento mejoró aún más

la precisión general a 94,82% y kappa a 0,936. Este estudio proporciona más evidencia de apoyo sobre la idoneidad de los datos de los Sentinels-1 y -2 para mejorar nuestra capacidad de mapear un área compleja que contiene clases CCUS de humedales y no humedales.

Reiche, et al. (2015) fusionaron series de tiempo de Landsat y SAR para detectar la deforestación en los trópicos (noroeste de la isla Viti Levu, Fiji), para ello, se modeló la relación de dos series de tiempo univariadas superpuestas utilizando una correlación ponderada optimizada. Utilizando el enfoque MulTiFuse fusionamos Landsat NDVI y la retrodispersión de band L de ALOS PALSAR. Posteriormente, utilizaron la serie de tiempo fusionada en un marco de detección de cambios multisensor para detectar la deforestación entre el 01/2008 y el 09/2010 en una plantación forestal gestionada en los trópicos (*Pinus caribea*; 2 859 ha). Utilizaron datos de referencia trimestrales que cubrían toda el área de estudio para validar y evaluar la precisión espacial y temporal. La serie de tiempo de relación de retrodispersión PALSAR HVHH filtrada multitemporalmente (HVHH_{mt}) estaba más fuertemente correlacionada con la serie de tiempo NDVI, mientras que para Landsat solo la precisión espacial y temporal de la deforestación detectada disminuyó significativamente con el aumento de los datos faltantes, las precisiones para el caso fusionado NDVI-PALSAR permanecieron altas y se observó que estaban por encima de los casos de NDVI y PALSAR solo para todos los porcentajes de datos faltantes. Para la serie de tiempo fusionada NDVI-HVHH_{mt}, la precisión general fue del 95,5% con un lapso de tiempo medio de 1,59 meses de cambios detectados.

Reiche et al. (2013) fusionaron las características de ALOS PALSAR multitemporal y datos Landsat 2007 y 2010 para el “mapeo y monitoreo de la deforestación tropical y la degradación de los bosques en el distrito minero en el centro de Guyana”. Los resultados muestran precisiones generales del 88% y 89,3% para mapear la cobertura forestal y detectar la deforestación y degradación forestal, respectivamente. Se reportan tasas de deforestación y degradación de 0,1% y 0,08% para el período de observación.

2.2 Base teórica

2.2.1 Bosque

Es un sistema ecológico complejo en el que los son la forma de vida dominante. Para ser denominado bosque debe presentar una cubierta de copas superior a 10% y áreas mayor a 0,5 ha (FAO 2012; FAO 2016; FAO 2020).

Los bosques pueden aparecer dondequiera que las temperaturas superen los 10 °C (50 °F) en los meses más cálidos y la precipitación anual supere los 200 mm (8 pulgadas). Pueden desarrollarse bajo una variedad de condiciones dentro de estos límites climáticos, y el tipo de vida del suelo, las plantas y los animales difiere según los extremos de las influencias ambientales. En las regiones subpolares frías de latitudes altas, los bosques están dominados por árboles resistentes. En el hemisferio norte, estos bosques, llamados taiga, o bosques boreales, tienen inviernos prolongados y entre 250 y 500 mm (10 y 20 pulgadas) de precipitaciones anuales. Los bosques de coníferas también cubren montañas en muchas partes templadas del mundo (FAO 2012; FAO 2016; FAO 2020).

2.2.2 Deforestación

La deforestación probablemente se originó con el uso del fuego, y se estima que se ha perdido entre el 40% y el 50% del área forestal original de la Tierra. Parte de esa pérdida ocurrió antes de que comenzara la agricultura asentada, hace aproximadamente 10 000 años, pero solo en las últimas décadas hay información confiable sobre las tasas de deforestación. En contraste con la deforestación de los siglos XIX y XX en las zonas templadas del mundo, la deforestación en los trópicos no comenzó en serio hasta después de 1950, alcanzando tasas de 12 millones de hectáreas por año en la década de 1990 (FAO 2016; FAO 2020; Leite-Filho et al. 2020).

La deforestación tropical es impulsada por una combinación sofisticada de impulsores directos e indirectos de diferente naturaleza (sociales, ecológicos, económicos, ambientales, biofísicos), que interactúan entre sí, a

menudo de manera sinérgica; las combinaciones específicas de impulsores varían dentro de una región del mundo, por países y entre localidades dentro de los países. Los impulsores directos son básicamente actividades humanas a nivel local y pueden categorizarse ampliamente en aquellos relacionados con la expansión agrícola, la extracción de madera y la extensión de la infraestructura (FAO 2016; FAO 2020; Leite-Filho, et al. 2020).

2.2.4 Sistemas de Información Geográfica (SIG)

Sistema compuesto por el software, el hardware y varias funciones de la computadora. Este sistema se utiliza para respaldar la recopilación, gestión, procesamiento, análisis y modelado y visualización de datos espaciales, de modo que se puedan resolver problemas complejos de planificación y gestión. El GPS es también una especie de sistema de apoyo a la toma de decisiones, que tiene estrechas relaciones con otros sistemas de información. La información almacenada y procesada se codifica en el SIG. La posición geográfica y la información relativa a los atributos de los objetos terrestres son los principales recursos para la recuperación de información (Wieczorek y Delmerico 2009; Jiang 2020).

El SIG incorporado es una de las direcciones de desarrollo importantes para el SIG actual. Un sistema de información geográfica integrado (SIG integrado) es un tipo de sistema con productos de sistemas integrados que tienen una función GIS integrada, una aplicación de nivel de diseño y desarrollo del sistema, software y hardware complejos. El GIS integrado ofrece una solución ideal para la navegación, el posicionamiento, la consulta de mapas y la gestión de datos espaciales. El GIS incorporado tiene una amplia aplicación en muchos campos, como el militar, el transporte inteligente, el turismo, la encuesta de recursos naturales y el estudio del medio ambiente, etc. SIG es una parte clave de todo el SIG integrado. Como principal módulo de software en el sistema, las funciones principales del GIS integrado son el mapa electrónico, el análisis de rutas, la recuperación de consultas, la navegación y el posicionamiento, y la anotación de información (Wieczorek y Delmerico 2009; Jiang 2020).

2.2.5 Teledetección

La teledetección es el proceso de observar y obtener imágenes precisas de la superficie terrestre, el uso de la teledetección permite mejorar los informes de indicadores forestales clave, como el seguimiento de la pérdida de bosques, el seguimiento de daños por tormentas y el mapeo de la cobertura del suelo (Kerle, et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

Los satélites pueden colocarse en diversas órbitas alrededor del planeta. La órbita terrestre baja (entre 160 y 2,000 km sobre la Tierra), la órbita terrestre media (entre 2,000 y 35,500 km sobre la Tierra) y la órbita terrestre alta (por encima de los 35,500 km sobre la Tierra) son los tres tipos de órbitas más comunes. A 35 786 kilómetros, los satélites se encuentran en lo que se conoce como órbita geosincrónica (GSO), en la que su velocidad orbital coincide con la rotación del planeta. Además, un satélite en órbita geosincrónica (GSO) se ubicará inmediatamente sobre el ecuador. Una órbita geoestacionaria permite que un satélite mantenga su posición directamente sobre el mismo lugar en la superficie de la Tierra (Kerle, et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

El LIDAR, el RADAR, la radiación infrarroja (IR), la tecnología térmica, la sísmica, el sonar, la detección de campos eléctricos y el GPS son ejemplos de tecnologías de teledetección. Estos diferentes sensores pueden instalarse en un satélite, una aeronave, un barco, un submarino, un dron UAV o en otro lugar de observación adecuado, como el techo de un edificio, dependiendo de lo que se esté observando. Una de las tecnologías clave que hace posible el Internet de las cosas es la teledetección, la cual permite que casi cualquier objeto imaginable tenga una identidad única y la capacidad de enviar datos por sí mismo a través de una red. Ciertas aplicaciones de teledetección, incluidas aquellas cuyo objetivo es medir cambios mínimos a lo largo del tiempo, pueden requerir un monitoreo frecuente o continuo. La geología, la oceanografía, la hidrología, la ecología y la meteorología son solo algunos de los campos que utilizan datos de teledetección; por ejemplo, se pueden emplear para identificar variaciones en la presión de las válvulas de una tubería. Para obtener más información, se podrían instalar sensores externos fuera de la tubería. Además, se puede utilizar la teledetección para investigar las tendencias de las precipitaciones

y las aves acuáticas (Kerle, et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

2.2.3 Energía electromagnética

la energía electromagnética es un término utilizado para describir las diversas energías que viajan como longitudes de onda a través del espacio a la velocidad de la luz. La radiación EM no tiene masa ni carga. Más bien, viaja en un haz de energía luminosa llamado fotones (Kerle, et al. 2004; Jensen 2009).

Un principio físico fundamental en el que se basa la teledetección es que diferentes características en la superficie de la Tierra interactúan con longitudes de onda específicas del EMS de diferentes maneras. Cuando se trabaja con sensores ópticos, la propiedad más importante utilizada para identificar características en la superficie de la Tierra es la reflectancia espectral ; la relación de la intensidad de la luz reflejada desde una superficie dividida por la intensidad de la luz incidente. Diferentes características tienen diferentes propiedades de reflectancia espectral y podemos usar esta información para identificar características individuales. Por ejemplo, la arena blanca refleja la mayoría de la luz visible y del infrarrojo cercano, mientras que la vegetación verde absorbe la mayoría de las longitudes de onda rojas y refleja la mayoría de las longitudes de onda del infrarrojo cercano (Kerle, et al. 2004; Jensen 2009).

Las longitudes de onda generalmente se miden en unidades estándar y, cuando se usan para describir ondas electromagnéticas, generalmente se expresan en metros (m). Volviendo a nuestro ejemplo de la playa, la distancia entre los picos de cada ola es lo que puedes considerar la longitud de onda (Figura 1 y 2) (Kerle, et al. 2004; Jensen 2009).




Figura 1. Detección remota mediante sensores activos y pasivos.

Fuente: Kerle, et al. (2004).




Figura 2. Onda electromagnética; vectores eléctricos (E) y magnéticos (M).

Fuente: Kerle, et al. (2004)

Un principio físico fundamental en el que se basa la teledetección es que diferentes características en la superficie de la Tierra interactúan con longitudes de onda específicas del EMS de diferentes maneras. Cuando se trabaja con sensores ópticos, la propiedad más importante utilizada para identificar características en la superficie de la Tierra es la reflectancia espectral : la relación entre la intensidad de la luz reflejada desde una superficie dividida por la intensidad de la luz incidente. Diferentes características tienen diferentes propiedades de reflectancia espectral y

podemos usar esta información para identificar características individuales. La arena blanca refleja la mayoría de la luz visible y del infrarrojo cercano, mientras que la vegetación verde absorbe la mayoría de las longitudes de onda rojas y refleja la mayoría de las longitudes de onda del infrarrojo cercano (Kerle, et al. 2004; Jensen 2009).




Figura 3. Relaciones entre longitud de onda, frecuencia y energía.

Fuente: Kerle, et al. (2004).




Figura 4. El espectro electromagnético.

Fuente: Kerle, et al. (2004).

2.2.4 Tipos de teledetección

En la teledetección se pueden utilizar tanto la detección pasiva como la activa. Las tecnologías de sensores pasivos miden un fenómeno observable que ya existe. Por ejemplo, un sensor como una cámara de dispositivo de acoplamiento de carga (CCD) instalada en un satélite puede registrar la luz solar. Un sensor interno envía una señal para recopilar información durante la detección activa. Por lo general, el dispositivo sensor cuenta con un transmisor que emite una señal, como electrones que rebotan

en el objetivo o una longitud de onda específica de luz. Posteriormente, el sensor recopila información sobre el rebote. LiDAR y Raider son dos ejemplos de esto. Una vez recibidos los datos, se procesan para extraer la información más relevante, ya sea relacionada con la teledetección o no. Con el fin de enfocarse en conjuntos de datos más pequeños y pertinentes, los datos se reconstruyen y procesan, lo que incluye el filtrado. Por lo general, los datos se dividen en tres capas. El primer nivel se caracteriza por datos no estructurados, artefactos e información ocasionalmente redundante. Una organización podría beneficiarse del segundo nivel de datos, que suele ser más específico y estar enfocado en un objetivo concreto. El tercer nivel de datos requiere menos recursos en términos de volumen de datos y es aún más refinado. En general, este nivel se utiliza con mayor frecuencia (Kerle, et al. 2004; Jensen 2009).

2.2.5 Plataforma y sensores

La cobertura terrestre se puede detectar de forma remota desde varias plataformas instaladas en transbordadores espaciales. Se identifica cuatro tipos de plataformas: barcos, globos, aviones y satélites. Durante cincuenta años, se han utilizado barcos, boyas, submarinos y otros submarinos como plataformas de teledetección, principalmente en combinación con ecómetros y sonares. El sonar se desarrolló en 1918 y se utilizó por primera vez en aplicaciones de pesca en la década de 1930, y la mayoría de los barcos pesqueros modernos están equipados con sonda o unidades de tubo de rayos catódicos (CRT). Sin embargo, hoy en día, el sonar con sistema de sonido se está volviendo cada vez más popular, es un método para transmitir información de manera rápida y efectiva. La detección de peces por boyas y submarinos por vista o por eco es principalmente experimental. Se han instalado sonares o sonares en submarinos que son remolcados a una distancia del barco nodriza para minimizar la interferencia con las especies objetivo debido al ruido del motor del barco. Los submarinos como el RUFAS

(Sistema de evaluación remota de pesquerías submarinas) equipados con cámaras de televisión subacuáticas se han utilizado con éxito para evaluar las poblaciones de mariscos. Los globos flotantes o atados se han utilizado de forma limitada para fotografiar cuerpos de agua como bahías y lagos aéreos, para rastrear ciclos de agua, sedimentos y más. Debido a su inestabilidad y baja velocidad, los globos aerostáticos tienen un uso limitado en la teledetección de la vasta superficie del océano. Las misiones de teledetección pueden llevarse a cabo en áreas específicas y en momentos específicos (si el clima lo permite) y pueden repetirse bajo condiciones controladas. Puede elegir la altura adecuada para optimizar la resolución y la cobertura. Los aviones comerciales pueden alcanzar una altitud de 15 km. La aeronave puede equiparse con una cámara en blanco y negro, en color o infrarroja en color (CIR). Las principales desventajas de la teledetección aérea son la plataforma inestable, el alcance geográfico limitado (debido a la altitud relativamente baja de la aeronave), el alto costo y la dependencia de las condiciones climáticas. Por lo tanto, este método se utiliza principalmente para trabajos que requieren tiempo. Cuando una misión requiere imágenes duplicadas de la misma área, a menudo se prefieren los datos satelitales debido a los costos de acceso significativamente más bajos. El uso de satélites como plataforma de teledetección ha permitido superar algunas de las dificultades encontradas con la teledetección aérea. Los satélites pueden rastrear regularmente toda la superficie de la Tierra, cubriendo una gran escala con cada revolución. Normalmente, los satélites de teledetección no están tripulados en condiciones de funcionamiento. Sin embargo, algunos satélites tripulados como SKYLAB, SOYUZ y el transbordador espacial brindan información valiosa a pesar de la corta duración de la misión (Figura 1 y 5) (Kerle, et al. 2004; Jensen 2009).




Figura 5. Tipos de sensores y plataformas.

Fuente: Kerle, et al. (2004).

2.2.6 Sistemas de exploración lateral u oblicua (RADAR)

Los sistemas de imágenes por radar (detección por radio y alcance) fueron desarrollados en la década de 1950 principalmente por las fuerzas armadas. El radar es un sistema activo de detección remota, lo que significa que proporciona su propia fuente de energía para producir una imagen. Por lo tanto, no requiere luz solar (como los sistemas ópticos) y los datos se pueden adquirir tanto de día como de noche. Además, debido a la especificidad de la onda del SAR, se puede penetrar la capa de nubes sin ningún efecto en las imágenes (Figura 6) (Kerle, et al. 2004; Jensen 2009).

Los instrumentos de radar permiten obtener data para todo clima que pueden generar imágenes de superficies planetarias independientemente de las condiciones de iluminación atmosférica o solar locales. Las imágenes de radar brindan información sobre las superficies que son complementarias a la química que generalmente se deduce de las imágenes visibles e infrarrojas. En cambio, las imágenes de radar están fuertemente influenciadas por la rugosidad y la geomorfología de la superficie y, en menor medida, por las propiedades eléctricas generales de la superficie. Este capítulo describe

los principios básicos de los radares de apertura sintética (SAR) de alta resolución, así como las implementaciones avanzadas de SAR. La polarimetría de radar proporciona información sobre la rugosidad de la superficie y las propiedades eléctricas, mientras que la interferometría de radar permite medir la topografía de la superficie y la deformación de la superficie después de eventos como terremotos o inflación volcánica. Los generadores de imágenes de radar han arrojado información espectacular sobre las superficies de Venus y Titán, cuerpos con atmósferas densas y opacas que son difíciles de fotografiar con los sistemas de cámaras tradicionales. Se analizan ejemplos de observaciones planetarias y terrestres con SAR para ilustrar la utilidad de estas imágenes (Figura 7) (Kerle, et al. 2004; Jensen 2009).




Figura 6. Ángulo de incidencia del radar y local.

Fuente: Kerle, et al. (2004).




Figura 7. Errores geométricos en RADAR.

Fuente: Kerle, et al. (2004).

Resolución espacial

Las principales características de la resolución espacial de imágenes de satélite RADAR son (Kerle, et al. 2004; Jensen 2009):

Tabla 2. Misiones de satélite SAR y radiómetro

Satélite o instrumento	Años de operación	Instrumento	Frecuencia	Resolución nominal
SMOS	2009-presente	Radiómetro	Banda L	35 kilómetros
Acuario	2011–2015	Radiómetro	Banda L	40 kilómetros
AMSR-E	2002–2011	Radiómetro	Multibanda	5-50 km
SMAP	2015-presente	Radiómetro	Banda L	36 kilómetros
SMAP	2015-presente	SAR	Banda L	300 metros
Radarsat-1/2	1995–2013	SAR	Banda C	3-8 m

Satélite o instrumento	Años de operación	Instrumento	Frecuencia	Resolución nominal
	2007-presente			
Sentinel-1	2014-presente	SAR	Banda C	5 m
PALSAR	2006-presente	SAR	Banda L	7-100 m
ERS-1/2	1991–2011	SAR	Banda C	30 m

Radar de Apertura Sintética (SAR)

Un SAR basado en satélites escanea la superficie de la tierra por medio de radiación de microondas . La antena SAR transmite pulsos de microondas y recibe el eco retrodispersado de la superficie. En base a estos ecos, se pueden producir datos de imagen de alta resolución y productos de datos. La tecnología SAR tiene varias características especiales en comparación con otros métodos de detección remota de imágenes. Por un lado, es posible observar la superficie terrestre incluso en días nublados y de noche. Por otro lado, se pueden derivar variables físicas como el coeficiente de retrodispersión o las diferencias de longitud de trayectoria en la dirección de visualización de la antena SAR. El coeficiente de retrodispersión depende de las propiedades físicas de las superficies observadas. Las principales propiedades son la rugosidad superficial , la geometría y las propiedades dieléctricas, afectadas principalmente por la humedad superficial. Otra característica importante de la teledetección por radar es la profundidad de penetración, respectivamente la penetración de sedimentos sueltos y vegetación en relación con la longitud de onda utilizada (más información: EO college). Para la teledetección geocientífica, la medición de la rugosidad de la superficie es un parámetro importante y, por lo tanto, se utiliza junto con las técnicas de teledetección óptica para el mapeo geológico. La capacidad de penetrar a través de sedimentos sueltos es un parámetro importante para mapear estructuras tectónicas. La capacidad de penetrar a través de la

vegetación es una característica importante para el mapeo geológico y tectónico. El reconocimiento de objetos basado en datos de radar es de particular importancia para las aplicaciones geocientíficas en regiones con frecuente cobertura de nubes. Por ejemplo, la detección de cambios en la superficie con alta resolución temporal, entre otros en el contexto de riesgos geológicos, el seguimiento de actividades mineras (ilegales) acompañadas de actividades de asentamiento. La determinación de las diferencias de longitud de trayectoria relativa se basa en la superposición de la fase de dos imágenes SAR. Esta llamada "fase interferométrica" se puede utilizar para derivar un modelo de elevación digital o para monitorear los desplazamientos de la superficie a lo largo del tiempo (Kerle, et al. 2004; Jensen 2009).

2.2.8 Clasificación de imágenes

Método que se utiliza para categorizar los píxeles en los datos satelitales para diferenciar las diversas características de la tierra, como tierras baldías, bosques, carreteras, asentamientos, cuerpos de agua, rocas en función de la reflectancia espectral. Esta técnica es muy utilizada para generar el LULC (Land Use Land Cover Map). Aquí se explican los tipos de técnicas de clasificación de imágenes. He usado Arc GIS, QGis, Erdas, Arc Map para el procesamiento de imágenes para las imágenes de muestra que se usan a continuación. Hay tres técnicas para clasificar la imagen: 1. Clasificación Supervisada, 2. Clasificación no supervisada, 3. Clasificación basada en objetos u orientada a objetos (Figura 8) (Kerle, et al. 2004; Jensen 2009).




Figura 8. Proceso de clasificación de imágenes de satélite.

Fuente: Kerle, et al. (2004).

Clasificación supervisada

Para ejecutar esta clasificación, debe recopilar los datos para elegir las clases de cobertura terrestre (sitios de capacitación) mediante un método de digitalización visual con la ayuda del usuario. Asegúrese de que el software que está utilizando clasifique con precisión todos los datos satelitales. Los datos de ubicación del sitio de Training se recopilarán en imágenes de alta resolución. Esto se considera como un representante de ciertos tipos de cobertura del suelo. Tienes que hacer una elección dependiendo del área cubierta en un rango completo de variabilidad dentro de la clase. El software permitirá clasificar la imagen con precisión. Sin embargo, la máquina determina la firma espectral de los píxeles dentro del área de entrenamiento para encontrar una coincidencia cercana. La información se define con la ayuda de estadísticas que incluyen la media y la varianza de cada clase para relacionarlas con todas las entradas. Pero la clasificación será menos precisa si las áreas de entrenamiento no son representativas del rango de variabilidad encontrado dentro de un tipo particular de cobertura terrestre. Puede seleccionar múltiples sitios de entrenamiento pequeños para cada clase. Ha seleccionado y recopilado los datos del sitio de entrenamiento con un esfuerzo óptimo para generar mejores resultados de clasificación. Los algoritmos de clasificación más comunes utilizados para la clasificación supervisada son Distancia mínima al clasificador medio, Clasificador de

paralelepípedos, Clasificador de máxima verosimilitud gaussiana, Distancia de Mahalanobis, Mapeador de ángulo espectral, Red neuronal, Codificación binaria, Mapeador de ángulo espectral, Clasificación híbrida, Clasificación de conjunto difuso (Kerle, et al. 2004; Jensen 2009; Nair y Bindhu 2016).

2.2.9 Random Forest (RF)

Random Forest es un algoritmo de aprendizaje conjunto para regresión y clasificación. Dado que es un método de aprendizaje automático, los bosques aleatorios no son paramétricos porque no se basan en suposiciones sobre la distribución de datos. A diferencia de los enfoques estadísticos, el aprendizaje automático son datos impulsados por la relación entre variables independientes y dependientes (Breiman 1996).

2.2.10 Software de procesamiento de imágenes

SNAP ESA

La puesta en marcha de la Agencia Espacial Europea (ESA) implicó la ampliación de las capacidades “interferométricas de SentiNel Application Platform (SNAP) para permitir el análisis de series de tiempo interferométrico SAR a través del paquete de software Stanford Method of Persistent Scatterer (StaMPS)” (Zuhlke et al. 2015). “En el trabajo actual, demostramos el procesamiento de interferometría de dispersores persistentes (PSI) habilitado de los datos de la misión Copernicus Sentinel-1 a través del procesamiento integrado SNAP-StaMPS” (Zuhlke, et al. 2015).

Google Earth Engine (GEE)

GEE es una plataforma de computación en la nube que fue lanzada por Google en 2010. Desde entonces, GEE ha demostrado su capacidad de preprocesamiento y minería de big data geográfico. GEE permite la computación en la nube y es una herramienta eficaz para llevar a cabo el análisis de grandes datos geoespaciales globales. (Gorelick, et al. 2017).

ArcGIS

Es un conjunto de productos desarrollado por el Instituto de Investigación de Sistemas Ambientales (Esri), que se compone de varias tecnologías que van desde el escritorio y el servidor hasta el dispositivo portátil o el cliente de código abierto. Estas tecnologías se integran entre sí, lo que permite que alguien use el software para crear datos, realizar análisis geoespaciales avanzados y publicarlos como un servicio para que puedan consumirse en aplicaciones web, dispositivos móviles u otro software de escritorio (Shaner y Wrightsell 2000).

2.2.11 Misiones Landsat

Desde 1972, la serie de satélites de observación de la Tierra USGS/NASA Landsat ha adquirido continuamente imágenes de la superficie de la Tierra, proporcionando datos continuos para ayudar a los administradores de tierras y a los tomadores de decisiones a tomar decisiones informadas sobre los recursos naturales y el medio ambiente. Landsat es parte del programa National Land Imagery (NLI) del USGS. El programa Landsat es una serie de misiones satelitales de observación de la Tierra administradas conjuntamente por la NASA y los Estados Unidos. Estudio geológico. El 23 de julio de 1972, se lanzó el Satélite de Tecnología de Recursos Terrestres (ERTS-1) en asociación con la NASA. Más tarde pasó a llamarse Landsat 1. Se lanzaron más satélites Landsat, poniendo a disposición del mundo datos de teledetección. Los satélites en funcionamiento y en las órbitas actuales son Landsat 7, Landsat 8 y Landsat 9. La NASA y el USGS han planeado desarrollar más misiones SLI, incluido Landsat Next, el sucesor de Landsat 8. El satélite Landsat tiene el mejor rango espectral y resolución terrestre para monitorear de manera efectiva el uso de la tierra y registrar cambios en la tierra debido al cambio climático, urbanización, sequía, incendios, cambio de biomasa (evaluación de carbono) y muchos otros cambios naturales y antropogénicos. El Archivo de Continuidad del Programa Landsat (1972-presente) proporciona datos de referencia sobre cambios en la tierra e información sobre tendencias que de otro modo no estarían

disponibles. Landsat representa la colección más grande del mundo de datos de teledetección terrestre de resolución media recopilados continuamente en el espacio. Landsat es una función importante del Departamento del Interior de los Estados Unidos. Administre las tierras federales sabiamente. Personas de todo el mundo están utilizando datos de Landsat para investigación, negocios, educación y otras actividades (Markham et al. 2018).

Landsat 8

Programa colaborativo de la NASA y el USGS , adquiere mediciones globales del planeta Tierra en el visible, infrarrojo cercano, onda corta e infrarrojo térmico. Landsat 8 amplía el notable récord de Landsat de 40 años y tiene capacidades mejoradas que incluyen nuevas bandas espectrales en la porción del espectro de detección de nubes cirros y azul, dos bandas térmicas, rendimiento mejorado de la relación señal-ruido del sensor y mejoras asociadas en la resolución radiométrica, y un ciclo de trabajo mejorado que permite recopilar una cantidad significativamente mayor de imágenes por día. Este documento presenta los esfuerzos del equipo científico Landsat actual (2012-2017) para establecer una comprensión inicial de las capacidades de Landsat 8 y los pasos a seguir en apoyo de las prioridades identificadas por el equipo. Se describe la evaluación preliminar de las capacidades de Landsat 8 y la identificación de nuevas oportunidades científicas y de aplicaciones con respecto a la calibración y la caracterización radiométrica; reflectancia superficial ; albedo superficial ; temperatura superficial, evapotranspiración y sequía; agricultura; cobertura terrestre, condición, perturbación y cambio; agua dulce y costera; y nieve y hielo. Se brindan conocimientos sobre el desarrollo de productos Landsat de 'nivel superior' derivados en reconocimiento de la creciente necesidad de registros de datos terrestres a largo plazo, de resolución espacial moderada y procesados consistentemente para la gestión de recursos y para estudios de cambio climático y global. El documento concluye con perspectivas futuras, enfatizando las oportunidades para constelaciones de imágenes terrestres mediante la combinación de datos de Landsat con datos recopilados de otros

sistemas de detección internacionales, y la consideración de los requisitos de la misión sucesora de Landsat. (Tabla 3) (Roy et al. 2014).

Tabla 3. Características de Landsat 8 Operational Land Imager (OLI) y Thermal Infrared Sensor (TIRS)

Sensor	Bandas	Nombre de banda	Longitud de onda (μm)	Resolución (m)
OLI	1	Costera (Coastal)	0,43 - 0,45	30
OLI	2	Azul	0,45 - 0,51	30
OLI	3	Verde	0,53 - 0,59	30
OLI	4	Roja	0,63 - 0,67	30
OLI	5	Infrarrojo Cercano (NIR)	0,85 - 0,88	30
OLI	6	Infrarrojo de Onda Corta 1 (SWIR 1)	1,57 - 1,65	30
OLI	7	Infrarrojo de Onda Corta 2 (SWIR 2)	2,11 - 2,29	30
OLI	8	Pancromática (Pan)	0,50 - 0,68	15
OLI	9	Cirros (Cirrus)	1,36 - 1,38	30
TIRS	10	Sensor Térmico Infrarrojo 1 (TIRS 1)	10,60 - 11,19	30 (100)
TIRS	11	Sensor Térmico Infrarrojo 2 (TIRS 2)	11,50 - 12,51	30 (100)

Fuente: Tomado y traducido por Roy, et al. (2014).

2.2.11 Programa Copérnico

Copérnico tiene como objetivo monitorear y predecir las condiciones ambientales en la tierra, el mar y la atmósfera, apoyar las estrategias de mitigación y adaptación al cambio climático, gestionar de manera efectiva las situaciones de crisis y mejorar la mitigación del cambio climático y mejorar la seguridad de todos los ciudadanos. La información proporcionada por Copérnico mejora la seguridad humana, incl. proporcionando información sobre desastres naturales como incendios o inundaciones, ayudando así a prevenir la pérdida de vidas y propiedades y el daño al medio ambiente. Copérnico es un programa orientado al usuario en el que los usuarios (principalmente autoridades públicas) tienen acceso completo, abierto y gratuito a los servicios de información proporcionados. El programa Copérnico incluye satélites dedicados (la familia Copernicus Sentinel) y una gama de misiones de contribución adicionales (satélites administrados por varias agencias comerciales y gubernamentales). Desde el lanzamiento de Sentinel-1A en 2014, la Unión Europea ha iniciado el proceso de poner en órbita la constelación junto con casi 20 satélites más para 2030. Estos datos satelitales se complementan y validan con datos de campo (Torres et al. 2012; Li et al. 2020).

Sentinel-1

Compuesta por dos satélites de radar de apertura sintética (SAR); 1A y 1B de banda C “operada por la ESA como parte del Programa Copernicus”. Actualmente, la misión recopila datos cada 6 a 12 días sobre África con una resolución espacial de aproximadamente 20 m. La retrodispersión del radar mide la cantidad de radiación de microondas reflejada de regreso al sensor desde la superficie del suelo. Esta medida es sensible a la rugosidad de la superficie, el contenido de humedad y la geometría de visualización. DE Africa proporciona retrodispersión de Sentinel-1 como gamma-0 (γ_0) con corrección radiométrica del terreno (RTC) donde se ha mitigado la variación debida a cambios en las geometrías de observación. La serie de tiempo del retrovisor de polarización dual se puede

utilizar en aplicaciones para bosques, agricultura, humedales y clasificación de cobertura terrestre. La capacidad del SAR para 'ver a través de' las nubes lo hace fundamental para mapear y monitorear los cambios en la cobertura terrestre en los trópicos húmedos (Torres, et al. 2012; Li, et al. 2020), las características se presentan en la tabla 4.

Tabla 4. *Características de la imagen de satélite Sentinel-1*

Parámetro	Sentinel-1
Fecha de lanzamiento	03 de abril de 2014 de S1-A 22 de abril de 2016 de S1-B
Tipo de órbita	SSO (órbita sincrónica del sol) ciclo de repetición de 12 días LTAN = 18:00 horas
Altitud orbital	693 kilómetros
Complemento de sensor	C-SAR (radar de apertura sintética de banda C)
Masa de la nave espacial Tamaño de la nave espacial Potencia de la nave espacial	2300 kg 3,4 mx 1,3 mx 1,3 m 4,8 kW (EOL)
Velocidad de datos de banda X de enlace descendente	520 Mbit/s
Banda S TT&C	64 kbit/s enlace ascendente 128 kbit/so 2 Mbit/s enlace descendente
Almacenamiento de datos científicos	1,4 Tbit (EOL)
Calidad de datos requerida	BER (tasa de error de bit): $< 10^{-9}$
Autonomía operativa	8 días
contratista principal	TAS-I (Thales Alenia Space-Italia)
Lanzador de línea de base	Soyuz (Kourou)

Fuente: Serrano et al. (2015).

2.3 Definición de términos

Teledetección: uso de tecnologías donde se detecta información a distancia mediante ondas electromagnéticas (Chuvieco 1996).

NDVI: el índice de vegetación de diferencia normalizada (NDVI) es una representación gráfica codificada por colores de las plantas en un campo o en otro lugar (Carlson y Ripley 1997).

SAR: los sistemas SAR aprovechan las características de propagación de largo alcance de las señales de radar y la compleja capacidad de procesamiento de información de la electrónica digital moderna para proporcionar imágenes de alta resolución (Handbook 2005).

Polarimetría: la polarimetría es la medida del grado de polarización de la radiación reflejada desde la superficie de un satélite . Las características de polarización dependen de la forma, el tamaño y las propiedades ópticas de las partículas superficiales (Handbook 2005).

Firma espectral: las firmas espectrales es la respuesta de los objetos a partir de las diferentes longitudes de onda presentes en la luz/radiación (Hernández y Montaner 2009).

Ráster: Patrón rectangular de líneas que sigue un haz de electrones en una pantalla de televisión o computadora (Hijmans y van Etten 2014).

Pixel: “unidad mínima de una imagen digital” (Li et al. 2017).

Tierra: todos los elementos físicos, otorgados por la naturaleza, a un área o propiedad específica: el medio ambiente, los campos, los bosques, los minerales, el clima, los animales y los cuerpos o fuentes de agua (Lund 2006).

Bosque: “porción de tierra de más de media hectárea (5 000 m²) con árboles y una cubierta de dosel de árboles de más del 10 %” (FAO 2012).

No bosque: “se define como áreas cubiertas por asentamientos, áreas urbanas y vegetación de pasto y arbustos visibles como tales en las imágenes de satélite” (Lund 2006).

Deforestación: “conversión de tierras boscosas en tierras no forestadas como resultado directo de las actividades humanas” (Lund 2006).

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN

3.1 Tipo de investigación

El estudio desarrollo la cuantificación de la deforestación en el sureste de la Amazonia peruana – Tahuamanu, mediante la combinación de sensores ópticos Landsat 8 OLI y SAR Sentinel-1, periodo 2021. Para ello, se aplicó “una investigación de tipo descriptiva, correlacional y predictivo” (Castro 2003; Baray 2006; Cazau 2006; Hernández et al. 2010).

3.2 Diseño de la investigación


La investigación corresponde a un “diseño Transaccional (transversal)”, porque se cuantifica la deforestación en el sureste de la Amazonia peruana – Tahuamanu en un solo periodo (2021) (Castro 2003; Baray 2006; Cazau 2006; Hernández, et al. 2010).

3.3 Delimitación espacial y temporal

La Amazonia de Madre de Dios se localiza en el sureste del Perú, limita internacionalmente con los países de Brasil y Bolivia, e interno con las regiones de Puno (sur), Cusco (oeste) y Ucayali (norte). La región de Madre de Dios es conocida como “la capital de la biodiversidad del Perú” y es considerado uno de los ecosistemas con mayor biodiversidad del mundo y ha sido priorizado para su conservación. Comprende una superficie aproximada de 85 183,96 km² (8 518 396 ha) (6,64 % del territorio nacional), “con una población aproximada de 141 070 habitantes” (INEI 2017). La construcción de la Carretera Interoceánica, una vía que se extiende por aproximadamente 2 600 km conecta a Brasil y Perú, y ha llevado a una mayor urbanización,

industrialización y extracción de recursos naturales, todo lo cual ha degradado el medio ambiente.

Espacialmente el área de estudio se encuentra en la provincia de Tahuamanu, con una área de 21 197 km² (2 119 700 ha) (Figura 9), donde interactúan títulos habilitantes (concesiones forestales maderables y no maderables), plantaciones, áreas agrícolas, y tierras indígenas (Dourojeanni 2019). Geográficamente se encuentra entre los paralelos 9° 51' 15" y 11° 56' 53" de latitud Sur y los meridianos 68° 57' 29" y 72° 20' 48" de longitud Oeste; altitud entre 200 m y 550 msnm (GOREMAD y IIAP 2009; Chávez, et al. 2013; Perz, et al. 2013; Alarcón, et al. 2016; Perz, et al. 2016).



En cuanto a la evaluación temporal, la cuantificación de la deforestación en el sureste de la Amazonia peruana – Tahuamanu, corresponde al 2021.

3.3.1 Clima e hidrografía

La vegetación de la región de estudio se compone principalmente de bosques aluviales y de *tierra firme* con bosques de bambú de ladera baja (*Guadua* sp.) (Chávez, et al. 2013). Los bosques aluviales cubren terrazas bajas ubicadas a lo largo de las fronteras de los ríos principales y sus áreas cambian debido a la migración de los ríos (Chávez, et al. 2013). El bosque se encuentra sobre el terreno aluvial lejos de cursos de ríos y lagos y se caracteriza por una diversidad de tipos de bosques de topografía relativamente plana (Chávez, et al. 2013).

Según las Estaciones Puerto Maldonado, Iñapari, Iberia, Pakitza, y Assis-Brasil (GOREMAD y IIAP 2009; Perz, et al. 2016) Con pocas variaciones a lo largo del año, la temperatura media anual oscila entre los 22 °C y los 26 °C. Entre mayo y septiembre, el «friaje», es decir, el aire gélido procedente de la masa polar antártica, provoca descensos de temperatura (GOREMAD y IIAP 2009; Perz, et al. 2016).

La precipitación corresponde a una media anual total de 1 800 mm. La menor precipitación se da en los meses de mayo a septiembre (caen del 20 al 25% del total anual). Mientras que el 75 al 80% del total se da entre los meses de octubre a abril. “La tendencia de intensidad de lluvias ocurre en sentido de Sureste a Noroeste”. Con clima muy lluvioso, cálido, muy húmedo y época seca marcada, la humedad alta es permanentemente, generalmente estas son muy inestables; donde la temperatura disminuye con la altura, “la humedad relativa fluctúa entre 63% y 90%, y la evapotranspiración entre 598,4 mm y 652,6 mm” (GOREMAD y IIAP 2009; Perz, et al. 2016).

A nivel hidrográfico está conformado por los ríos Pariamanu, Manuripe, Tahuamanu, Acre, Muymanu, Yaverija, Noya, entre otros afluentes de menor orden (GOREMAD y IIAP 2009; Perz, et al. 2016).

3.4 Población y muestra

La población está conformada por la provincia de Tahuamanu, que comprende una superficie de 21 197 km² (2 119 700 ha).

Para cuantificar la deforestación mediante la combinación de sensores ópticos Landsat 8 OLI y SAR Sentinel-1, se empleó la “distribución binomial de probabilidad” (Anaya y Chuvieco 2010; Chuvieco y Hantson 2010; Ochoa y Páez 2019). El número de muestra se calculó mediante (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%).

$$n = \frac{(1,96)^2 * 0,5(0,5 * 21\ 197)}{(21\ 197 - 1) * 0,05^2 + 1,96^2 * (0,5 * 0,5)}$$

$$n = 356,64 = 357$$

357 correspondió al número de puntos de muestreo. “Siendo la unidad mínima de cada punto de muestreo de 0,005 km² (0,5 ha)”.

La muestra fue distribuida de manera representativa en la provincia de Tahuamanu. Las muestras se distribuyeron bajo un criterio estratificado al azar, en la que todas las áreas tienen las mismas posibilidades de ser elegidas (inclusión) (Ochoa y Páez 2019).

La distribución considero 207 muestras levantadas en campo y 150 mediante imágenes: (1) 80 (32 con imágenes) muestras en áreas artificializados; “áreas urbanizadas, áreas industriales e infraestructura”, y “áreas de extracción de minería e infraestructura y escombreras”, (2) 80 (32 con imágenes) en áreas agrícolas; “cultivos transitorios, cultivos permanentes,

pastos, y áreas agrícolas heterogéneas, (3) 117 (49 con imágenes) en bosques y áreas mayormente naturales, (4) 80 (32 con imágenes) en áreas húmedas continentales, y (5) (imágenes) 0 en superficies de agua (aguas continentales)". Esta última solo se empleó áreas de entrenamiento para la clasificación.




Figura 10. Distribución de muestras para validar la deforestación en la provincia de Tahuamanu.

3.5 Técnicas e instrumentos de recolección de datos

3.5.1 Método y técnicas

Cuantificar la deforestación en áreas sometidas a constante cambio es fundamental para el programa Landsat (sensor Landsat 8 OLI) y programa Copérnico (sensor Sentinel-1) (Williams et al. 2006; Potin 2013)

Sentinel-1 de la ESA proporciona datos de radar de banda C con polarización dual. Los datos terrestres se adquieren con el llamado modo de franja ancha interferométrica a una resolución espacial de 5 m por 20 m, y en polarización VV + VH o HH + HV. Los datos terrestres de referencia para este estudio serán recogidos en campo de mayo a julio de 2021. Las imágenes de satélite (Tabla 3 y 4) se descargarán a través de la plataforma Google Earth Engine (GEE) (Mutanga y Kumar 2019). Los datos de los satélites Landsat 8 OLI y Sentinel-1 serán cubiertas entre los meses de mayo y junio de 2021, para el caso del sensor óptico, la mejor escena y el SAR, el más próximo a fines de junio. En esta época se llevan a cabo los preparativos para las temporadas forestal y agrícola. Para cubrir toda la provincia de Tahuamanu, se necesitan dos imágenes del Landsat 8. Las escenas de Sentinel-1 banda C se capturarán en modo de franja ancha interferométrica (IW), con polarización VV/VH.

El procesamiento se llevó a cabo por separado para los tres tipos de datos; del satélite Landsat 8, Sentinel-1 y combinación de Landsat 8-Sentinel-1. Para reducir el impacto de las diferentes fechas de adquisición y permitir la creación de un mosaico, se llevó a cabo un preprocesamiento de los datos. Esto incluyó la corrección atmosférica de los datos de Sentinel-1 y Landsat 8 (McNairn, et al. 2009; ESA 2013; Reiche, et al. 2013; Gharbia, et al. 2014; Roy, et al. 2014; Reiche, et al. 2015; Rajah, et al. 2018; Steinhausen, et al. 2018; Dong, et al. 2019; Puzzi, et al. 2021).

Se realizó la calibración radiométrica de las imágenes de Sentinel-1 en ambas polarizaciones VV y VH (McNairn, et al. 2009; ESA 2013; Reiche, et al. 2013; Gharbia, et al. 2014; Roy, et al. 2014; Reiche, et al. 2015; Rajah, et al. 2018; Steinhausen, et al. 2018; Dong, et al. 2019; Puzzi, et al. 2021).

Las imágenes Landsat 8 (mayo a junio) (Tabla 1) fueron transformados de números digitales (DN) a reflectancia de superficie por el método Top Of Atmosphere (TOA) a través de la caja de herramientas de GEE (McNairn, et

al. 2009; ESA 2013; Reiche, et al. 2013; Gharbia, et al. 2014; Roy, et al. 2014; Reiche, et al. 2015; Rajah, et al. 2018; Steinhausen, et al. 2018; Dong, et al. 2019; Puzzi, et al. 2021).

Las imágenes de SAR para el estudio fueron los productos Sentinel-1 nivel-1 Ground Range Detected (GRD). Los productos GRD de nivel 1 se examinaron con múltiples miradas y se proyectó al rango del suelo utilizando un modelo de elipsoide terrestre. Los productos se utilizaron en el modo Interferometric Wide Swath (IW) y una resolución espacial de 5 m por 20 m con un ancho de franja 250 km². Las imágenes de SAR se procesaron utilizando la caja de herramientas ESA SNAP y GEE siguiendo la metodología descrita por Rajah, et al. (2018). El flujo de procesamiento de imágenes SAR consto de cinco pasos: (1) Aplicación del archivo de órbita a la imagen SAR; (2) Calibración radiométrica; (3) Corrección del terreno; (4) Aplicación de filtro de manchas; (5) Conversión SAR DN en valores de retrodispersión gamma (McNairn, et al. 2009; ESA 2013; Reiche, et al. 2013; Gharbia, et al. 2014; Roy, et al. 2014; Reiche, et al. 2015; Rajah, et al. 2018; Steinhausen, et al. 2018; Dong, et al. 2019; Puzzi, et al. 2021).

Las imágenes de SAR en los modos de polarización vertical horizontal (VH) y vertical vertical (VV) se fusionaron con imágenes ópticas para determinar su precisión. La extracción de características (puntos de verdad del terreno) se realizó por separado para imágenes ópticas (mediciones de reflectancia espectral), imágenes de SAR (medición de retrodispersión), y combinación de imágenes ópticas (bandas y Índice de vegetación de diferencia normalizada-NDVI)-SAR. Esta última consistió en las mediciones de retrodispersión que fueron asignadas a la medición de reflectancia espectral y NDVI. Ello se logró apilando imágenes ópticas, NDVI y SAR banda por banda, creando una imagen compuesta (fusionada) que contiene mediciones de reflectancia espectral, NDVI y retrodispersión. La medición espectral fusionada y los datos de retrodispersión se utilizaron para el análisis de clasificación de imágenes (McNairn, et al. 2009; ESA 2013; Reiche, et al. 2013; Gharbia, et al. 2014; Roy, et al. 2014; Reiche, et al. 2015; Rajah, et al. 2018; Steinhausen, et al. 2018; Dong, et al. 2019; Puzzi, et al. 2021).

SNAP ESA, Google Earth Engine y ArcGIS 10.8®, suministrados por CETEGERN, fueron los programas de código abierto y con licencia que se utilizaron para el procesamiento de datos (Alarcón, et al. 2016).

Se recopilaron datos sobre la cobertura y el uso del suelo en la provincia de Tahuamanu con el fin de validar el método mediante la asignación de puntos en el terreno. “Los datos de campo se levantaron mediante el uso de GPS (Garmin Map 60 CSx)” (Alarcón, et al. 2016). La concordancia de la clasificación se validó mediante una matriz general e Índice de Kappa (k) mediante un método mixto; puntos levantados en campo e imágenes de precisión (Drone, PlanetScope, y WorldView) (Alarcón, et al. 2016).

3.5.2 Procesamiento de datos y análisis estadístico

Obtención de información cartográfica:

La cartografía del área de estudio se obtuvo de CETEGERN (Alarcón, et al. 2016), mientras que las imágenes ópticas y de radar; Landsat-8 y SAR Sentinel-1 se descargaron de Google Earth Engine para el periodo 2021 (Tabla 3, 4 y 5).

Para la selección de las imágenes Landsat 8, se considerará las fechas de con nula o menor nubosidad.




Figura 11. Imagen óptica landsat-8 con bandas RGB: 6-5-4 (2021) y Sentinel-1 (2021), polarización VV y VH, y RGB VV-VH-VV/VH de la provincia de Tahuamanu.

Tabla 5. Información de adquisición de imágenes Landsat y Sentinel-1

Sensor	Fecha de imagen	Path Raw/Polarización
Landsat 8	01/05/2021 – 30/06/2021	002-068, 003-067, 003-068, 004-067, y 004-068
Sentinel-1 (SAR)	01-30/06/2021	VV - VH

✓ Tratamiento y análisis de imágenes Landsat y SAR

Tratamiento digital que se basó en la corrección de datos Landsat 8 OLI y Sentinel-1 descargados de Google Earth Engine (GEE) y Alaska Satellite Facility (ASF). Comprende las siguientes fases:

- 1. Pre-Procesamiento.** Se realizó la preparación de los datos Landsat y SAR. Landsat 8; se convirtieron de números digitales (DN) a reflectancia de superficie por el método Top Of Atmosphere (TOA) a través de la caja de herramientas de GEE. SAR Sentinel-1; Multilook, Calibración, Filtro de Speckle, Corrección por Topografía, y Recorte en función al área de estudio (Reiche, et al. 2013; Rajah, et al. 2018; Steinhausen, et al. 2018).
- 2. Procesamiento.** Se clasificó; 1) la reflectancia espectral de Landsat 8, 2) la medición de la retrodispersión de Sentinel-1, y 3) la combinación de la reflectancia espectral y NDVI (Landsat 8) con mediciones de retrodispersión SAR Sentinel-1.

Para el primer caso, las imágenes Landsat 8 se convirtieron de números digitales (DN) a reflectancia de superficie por el método Top Of Atmosphere (TOA) por medio de la plataforma GEE. Para el procesamiento se utilizará las bandas multiespectrales 6, 5, 4 (Williams, et al. 2006; Rajah, et al. 2018).

El segundo caso, las imágenes SAR Sentinel-1 se procesaron utilizando el software ESA SNAP y la plataforma de GEE siguiendo la metodología descrita por Rajah, et al. (2018). El flujo de procesamiento

de imágenes SAR consto de cinco pasos: (1) Aplicación del archivo de órbita a la imagen SAR; (2) Calibración radiométrica; (3) Corrección del terreno; (4) Aplicación de filtro de manchas; (5) Conversión SAR DN en valores de retrodispersión gamma (dB) (Potin 2013; Rajah, et al. 2018).

El último caso, combino la reflectancia espectral del Landsat 8, con las 6, 5, 4 y NDVI con mediciones de retrodispersión dB SAR Sentinel-1. Para ello, se realizó la fusión de las bandas de Landsat, NDVI y retrodispersión dB (Jiang et al. 2006; Williams, et al. 2006; Potin 2013; Roy, et al. 2014; Reiche, et al. 2015; Rajah, et al. 2018).

El NDVI fue calculado según el siguiente algoritmo (Jiang, et al. 2006):

$$NDVI = (NIR - Red)/(NIR + Red) \quad (\text{Ecuación 2})$$

Donde **NIR** es luz infrarroja cercana y **Red** es luz roja visible.

Este índice fluctúa entre -1 a 1, los valores negativos esta caracterizado por nieve, agua y nubes, por el contrario, “los valores cercanos a cero están formados principalmente por rocas y suelo descubierto”. En la misma línea, las regiones sin rocas, como las de arena y/o nieve, presentan valores muy bajos (0,1 o menos). Los valores más altos (de 0,6 a 0,8) indican bosques, mientras que los valores medios (de 0,2 a 0,3) describen matorrales y pastizales (Jiang, et al. 2006).

La caracterización utilizo el método de clasificación Random Forest (RF) en base a la “metodología propuesta por CORINE Land Cover” (IDEAM 2010), y adaptada por el Ministerio del Ambiente (MINAM 2012), RF, aplica un criterio jerárquico najo un criterio espacial, donde en una variedad de árboles de manera aleatoria se elige la que mayor ponderación presenta (Tabla 6) (Rodriguez-Galiano et al. 2012), como se detalla a continuación:

$$b = 1 \text{ a } B \quad (\text{Ecuación 3})$$

- a. Dibuje una muestra bootstrap Z^* de tamaño N a partir de los datos de entrenamiento.

- b. Hacer crecer un árbol de bosque aleatorio T_b a los datos de arranque, repitiendo recursivamente los siguientes pasos para cada nodo terminal del árbol, hasta que se alcance el tamaño mínimo de nodo $n_{\min}$. 1) Seleccione m variables al azar de las p variables, 2) Elije la mejor variable/punto de división entre los m , y 3) Divide el nodo en dos nodos secundarios.

Generación de conjunto de árboles:

$$\{T_b\}_1^B \quad (\text{Ecuación 4})$$

Para hacer una predicción en un nuevo punto x :

$$\text{Regresión} = f_{\text{rf}}^B(x) = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (\text{Ecuación 5})$$

$$\text{Clasificación} = \text{Let} C_b(x) \quad (\text{Ecuación 6})$$

La predicción de clase del b th del árbol RF, luego:

$$C_{\text{rf}}^B(x) = \text{majority vote} \{C_b(x)\}_1^B \quad (\text{Ecuación 7})$$

Si las variables son simplemente *i.d.* (distribuidos de forma idéntica, pero no necesariamente independientes) con correlación positiva por pares ρ , la varianza del promedio es:

$$\rho\sigma^2 + \frac{1-\rho}{B}\sigma^2 \quad (\text{Ecuación 8})$$

A medida que B aumenta, el segundo término desaparece, pero el primero permanece y, por lo tanto, el tamaño de la correlación de pares de árboles en bolsas limita los beneficios de promediar.

Tabla 6. *Leyenda de cobertura de la tierra adaptada al área de estudio*

Nivel I	Nivel II	Nivel III
1. Áreas artificializados	1.1 Áreas urbanizadas	1.1.1 Tejido urbano continuo
		1.1.2 Tejido urbano discontinuo

	1.2 Áreas industriales e infraestructura	1.2.1 Aeropuerto
	1.3 Áreas de extracción de minería e infraestructura y escombreras	1.3.1 Área de extracción de minería e hidrocarburos
2. Áreas agrícolas	2.1 Cultivos transitorios	2.1.1 Otros cultivos transitorios
	2.2 Cultivos permanentes	2.2.1 Cultivos permanentes arbustivos
	2.3 Pastos	2.3.1 Pastos
	2.4 Áreas agrícolas heterogéneas	2.4.1 Mosaico de cultivos pastos y espacios naturales
3. Bosques y áreas mayormente naturales	3.1 Bosque	3.1.1 Bosque denso bajo
		3.1.2 Bosque abierto bajo
		3.1.3 Bosque denso alto
		3.1.4 Bosque abierto alto
		3.1.5 Bosque fragmentado
4. Áreas húmedas continentales	4.1 Áreas húmedas continentales	4.1.1 Áreas pantanosas
5. Superficie de agua	5.1 Aguas continentales	5.1.1 Ríos
		5.1.2 Lagos permanentes
		5.1.3 Lagos Estacionales
		5.1.4 Lagos Estacionales (cochas)

Fuente: MINAM (2012); tomado y adaptado de CORINE Land Cover (IDEAM 2010).

3. Post-Clasificación, procedimiento que consistió en la verificación de los resultados de la clasificación pixel por pixel (Jensen et al. 1991; Xiuwan 2002; Alarcón, et al. 2016), en nuestro caso se aplicó el método de reducción Majority/Minority de ENVI. La fiabilidad de los resultados se midió mediante una matriz general y concordancia de kappa (k). Los productos fueron convertidos a vector para su análisis en softwares SIG (ArcMap y ArcGISpro) (Alarcón, et al. 2016).

✓ Tratamiento de datos

Para medir la precisión de los datos se aplicó un test de evaluación real de campo denominado “matriz de confusión y el coeficiente kappa (κ)” (Elijah y Jensen 1996; Chuvieco 2002; Chuvieco y Hantson 2010; Alarcón, et al. 2016), estadística que mide la concordancia de los resultados con los levantados en campo e imágenes con buena resolución espacial (Cerde y Villarroel 2008; Alarcón, et al. 2016), kappa toma valores de -1 a 1; más cercano a 1, mayor concordancia y precisión, mientras un $\kappa = 0$, indica una concordancia a causa del casualidad (Cerde y Villarroel 2008; Alarcón, et al. 2016). Los niveles de concordancia se precisan en la tabla 7 (Cerde y Villarroel 2008; Alarcón, et al. 2016).

Tabla 7. *Valoración 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: Cerde y Villarroel (2008); Landis y Koch (1977).

El estudio empleo un procedimiento compuesto; 1. Salida de campo para detectar la deforestación, y 2. Las áreas deforestadas serán constatadas con imágenes “de alta resolución CBERS, PlanetScope y WorldView” (Alarcón, et al. 2016). Los datos de campo fueron tomados siguiente el método propuesto por EL “centro para el Estudio de Instituciones, Población y Cambios en el Medio Ambiente de la Universidad de la Indiana (CIPEC)” (Chávez, et al. 2013).




Figura 12. Validación de áreas artificializadas, áreas agrícolas, bosques y áreas mayormente naturales, y áreas húmedas continentales con imágenes WorldView de 0,38 m x 0,38 m de resolución espacial (a y b), imágenes PlanetScope de 3 m x 3 m de resolución espacial (c), y CBERS de 2 m x 2 m de resolución espacial.

Fuente: Planet-Team (2021).

✓ **Análisis estadístico**

La aplicación estadística utilizada consistió en la técnica descriptiva e inferencial, los softwares empleados fueron; “Microsoft Excel, ArcGis 10,8®, SNAP ESA, y el Google Earth Engine”.

Para el primer, segundo y tercer objetivo, sobre “cuantificar la superficie deforestada mediante el uso del sensor óptico Landsat 8 OLI, sensor de radar de apertura sintética (SAR) Sentinel-1, y combinación de datos de sensores ópticos Landsat 8 OLI (respuestas de la reflectancia espectral, NDVI) y SAR Sentinel-1” en el sureste de la Amazonia peruana – Tahuamanu, periodo 2021, se aplicó modelos predictores a partir de las Bandas multiespectrales, NDVI, y datos de retrodispersión VV/VH del sensor Sentinel-1. La caracterización se realizó a través del método de clasificación supervisada

Random Forest (Jiang, et al. 2006; Chen, et al. 2010; ESA 2013; Reiche, et al. 2013; Roy, et al. 2014; Reiche, et al. 2015; Markham, et al. 2018; Mutanga y Kumar 2019; Puzzi, et al. 2021).

Respecto al cuarto objetivo, sobre Determinar el nivel de precisión en la cuantificación de la deforestación mediante el uso del sensor óptico Landsat 8 OLI, SAR Sentinel-1, y la combinación de sensores ópticos y de radar en el sureste de la Amazonia peruana – Tahuamanu, se empleó un test de evaluación denominado matriz de confusión y el coeficiente kappa (κ) (Elijah y Jensen 1996; Chuvieco 2002; Chuvieco y Hantson 2010; Alarcón, et al. 2016).

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1 Clasificación y superficie de la deforestación en la provincia de Tahuamanu

4.1.1 Clasificación de imágenes de satélite Óptica, SAR, y Óptica-SAR

Se adquirieron imágenes Landsat Operational Land Imager (OLI) y Thermal Infrared Sensor (TIRS) con una resolución espacial de 30 m para el 2021 a través del motor de procesamiento Google Earth Engine (GEE). Las escenas 002-068, 003-067, 003-068, 004-067, y 004-068 cubren la provincia de Tahuamanu. Las imágenes seleccionadas presentan nubosidad menor de 20%. Con el fin de proporcionar una cobertura sin nubes suficiente o la menor posible, se consideró el comienzo de la estación seca principal de mayo a junio (Figura 14).

Adicionalmente, de la imagen Landsat-8 OLI se realizó una transformación de índice espectral NDVI, para ello, se realizó el cocientes de bandas del infrarrojo cercano (NIR) y la banda roja (4) (Jiang, et al. 2006; Williams, et al. 2006; Potin 2013; Roy, et al. 2014; Reiche, et al. 2015; Rajah, et al. 2018).

Los datos de SAR para 2021 se obtuvieron del sensor de radar de apertura sintética de banda C Sentinel-1 del programa Copérnico de la Agencia Espacial Europea. Todas las imágenes se adquirieron en modo descendente de Nivel 1.1. Las imágenes Sentinel-1 de 2021 se descargó del portal Alaska satélite Facility (ASF) y Google Earth Engine (GEE). Temporalmente corresponde de 01 al 30 de junio (Figura 13).

La clasificación se realizó mediante el software SNAP ESA y la plataforma GEE, mediante el uso de la herramienta geométrica para determinar áreas de entrenamiento.

La clasificación, considero las siguientes categorías; (1) “áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras”, (2) “áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas”, (3) “bosques y áreas mayormente naturales”, (4) “áreas húmedas continentales”, y (5) “superficies de agua (aguas continentales)” (Figura 10).

La clasificación supervisada de la provincia de Tahuamanu basada en el algoritmo Random Forest (RF), considero las bandas 6, 5, 4 y NDVI para Landsat-8 OLI, y la combinación de bandas polarimétricas VV/VH para los SAR Sentinel-1, seguidamente se realizó la postclasificación en el software ENVI mediante el método Majority/Minority Analysis (kernel size de 3x3) (Figura 13 y 14).




Figura 13. Imagen de Satélite Sentinel-1, firmas espectrales en las bandas R (VV) G (VH) B (VV-VH); (a) Áreas artificializadas, (b) Áreas Agrícolas, (c) Bosques y áreas mayormente naturales, (d) Áreas húmedas continentales, y (e) Superficies de agua.




Figura 14. Imagen de Satélite Landsat-8 OLI, firmas espectrales en las bandas R (6) G (5) B (4); (a) Áreas artificializadas, (b) Áreas Agrícolas, (c) Bosques y áreas mayormente naturales, (d) Áreas húmedas continentales, y (e) Superficies de agua.




Figura 15. Índice de Vegetación de Diferencia Normalizada (NDVI) de Satélite Landsat-8 OLI.

De los datos evaluados, se puede determinar que las imágenes Landsat-8 e NDVI presentan una mejor caracterización de la cobertura y uso de suelo del área de estudio, mientras que el SAR Sentinel-1 mediante las polarizaciones VV y VH presentan un mejor comportamiento en la cuantificación de áreas húmedas.

4.1.2 Deforestación por tipo de sensor; Óptica, SAR, y Óptica-SAR

La evaluación de la deforestación por tipo de sensor; óptico, SAR, y la combinación de Óptico-SAR en la provincia de Tahuamanu al año 2021, presenta variaciones en cuanto a la cuantificación de la pérdida de bosque (deforestación) (Tabla 8, y Figura 16, 17, y 18), la dinámica conversión de bosque a otros usos producto de la deforestación se da por obras de áreas artificializadas (áreas urbanizadas, áreas industriales, infraestructura, y escombreras) y actividades agrícolas (cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas).

La cuantificación reporto 19 435,65 ha mediante procesamiento de imagen óptica Landsat-8, 142,14 ha con SAR Sentinel-1, y 27 125,04 ha con la combinación de Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1 (Tabla 8).

En el análisis, pequeñas áreas ubicadas al oeste de la provincia, ubicadas en el Parque Nacional Alto Purus fueron enmascarados como nubes debido a una fuerte superposición espectral (fracciones Landsat) entre las nubes y el bosque. Adicionalmente, pocas áreas de sombra de nubes muy oscuras fueron detectadas por el algoritmo de enmascaramiento, solo afectando a la categoría de bosques y áreas mayormente naturales (Oppenheimer 1998; Williams, et al. 2006; Ou et al. 2012; Roy, et al. 2014). Las imágenes Landsat seleccionadas en la estación seca presentaron mínimas variaciones estacionales, por lo que, los resultados obtenidos deberían ser consistentes. A diferencia de problemas ambientales en los datos del Landsat, las áreas de escala y sombra del SAR Sentinel-1 siempre tienen la misma ubicación para una determinada especificación de adquisición del SAR (sensor, órbita, modo y ángulo de incidencia asociado). En nuestro

caso, casi todas las áreas de escala y sombra del SAR están cubiertas por información de Landsat y solo una parte insignificante de aproximadamente 0,02% se hace presente en la falta de datos.

Tabla 8. Deforestación en la provincia de Tahuamanu por tipo de sensor, periodo 2021

Sensor	Cobertura y uso de suelo (ha)				
	Bosques y áreas mayormente naturales	Deforestación		Áreas húmedas continentales	Superficies de agua
		Áreas artificializadas	Áreas agrícolas		
Landsat-8	1 994 728,86	5 469,62	13 966,03	258,7	4 878,62
SAR Sentinel-1	2 013 710,254	88,39	53,75	38,92	5 410,52
Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1	1 985 755,04	7 986,73	19 138,31	273,35	6 148,40




Figura 16. Clasificación de cobertura y uso de suelo de imagen óptico Landsat-8 para cuantificar la deforestación de la provincia de Tahuamanu al año 2021.




Figura 17. Clasificación de cobertura y uso de suelo de imagen SAR Sentinel-1 con polarización VV/VH/VV-VH para cuantificar la deforestación de la provincia de Tahuamanu al año 2021.

Los métodos basados en sensores ópticos, presentan resultados fiables, sin embargo, el efecto las condiciones ambientales genera inconvenientes y problemas en la identificación y clasificación de la cobertura y uso de suelo. Por otro lado, las imágenes con alta y mediana resolución aumentan las precisiones generales de los resultados (Häme et al. 2012; van Duijvenbode et al. 2014; Reiche 2015; Alarcon et al. 2021).

El método de combinación o fusión a nivel de característica Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1 (polarización VV/VH/VV-VH) para cuantificar la deforestación en la provincia de Tahuamanu, presentan resultados consistentes, incorporando las características espectrales con una resolución de 30 m de las bandas 6, 5, 4 del Landsat-8, el NDVI para evaluar la actividad fotosintética para cuantificar áreas con vegetación y sin vegetación, del mismo, el aporte de la retrodispersión (copolarización y polarización dual) VV y VH del SAR Sentinel-1 no está sujeta a las interferencias de fenómenos ambientales y presenta una alta sensibilidad en la identificación

y cuantificación de objetos húmedos (Jiang, et al. 2006; Mariaca y Andrés 2007; Chen, et al. 2010; Zhang 2010; Gharbia, et al. 2014; Hong, et al. 2014; Akbar et al. 2016; Joshi, et al. 2016; De Alban, et al. 2018; Erinjery, et al. 2018; Lennox, et al. 2018; Steinhausen, et al. 2018; Dong, et al. 2019; Elias, et al. 2020; Booysen et al. 2021; Puzzi, et al. 2021).




Figura 18. Clasificación de cobertura y uso de suelo mediante la combinación de imágenes Landsat-8 (bandas 6,5,4 + NDVI) y SAR Sentinel-1 (VV/VH/VV-VH) para cuantificar la deforestación de la provincia de Tahuamanu al año 2021.

El clasificador de árbol de decisión RF permite extraer una amplia información de la fusión del SAR y las características ópticas. Al ser un método no paramétrico, no requieren descripciones probabilísticas de las clases deseadas para ser distintos (Reiche, et al. 2013; Reiche 2015; Reiche, et al. 2015; Reiche, et al. 2018; Puzzi, et al. 2021). Los clasificadores de árboles de decisión RF se han aplicado con éxito para la cartografía forestal, detección de cambios, y la deforestación (Mutanga y Kumar 2019). La selección de características y umbrales de características, se realizó un análisis de firma y separabilidad de las características extraídas (2021) utilizando las áreas de

muestra de capacitación disponibles para las “clases de cambio de cobertura y uso de suelo y determinar la deforestación”. La Figura 13, 14, y 15 muestran las firmas de las características de retrodispersión Sentinel-1 VV/VH/VV-VH y Landsat (bandas; 6,5,4+NDVI), para “áreas artificializadas, áreas agrícolas, bosques y áreas mayormente naturales, y áreas húmedas continentales”.




Figura 19. Pérdida de la cubierta forestal y deforestación en la provincia de Tahuamanu al año 2021, mediante el sensor óptico Landsat-8 y SAR Sentinel-1.

La eficacia de la combinación de imágenes ópticas y SAR en la cuantificación de la deforestación en la provincia de Tahuamanu coinciden con

hallazgos reportados por Chatziantoniou, et al. (2017); De Alban, et al. (2018); Erinjery, et al. (2018); Reiche, et al. (2018); Reiche, et al. (2015); Reiche, et al. (2013); Steinhausen, et al. (2018), quienes combinaron imágenes ópticas Landsat y Sentinel-2 con SAR ALOS PALSAR, ALOS, ALOS-2, y Sentinel-1 para generar la cobertura y uso de suelo, humedales y la deforestación en los trópicos mediante el método de clasificación de árboles de decisión RF. Todos ello, mostraron precisiones generales por encima del 88% a un máximo del 95%, y kappa de 0,928 (Reiche, et al. 2013; Reiche 2015; Reiche, et al. 2015; Rajah, et al. 2018; Reiche, et al. 2018).

Finalmente, el uso de datos ópticos y de radar sinérgicos proporciona mayor información confiable sobre el cambio de la cobertura del suelo, específicamente la pérdida de bosque por la expansión agrícola y sus variantes en función a la humedad del suelo en la provincia de Tahuamanu. Estos criterios dan una explicación de los cambios del paisaje, cuando se interpreta junto con una comprensión profunda de los factores próximos y subyacentes complejos que impulsan estos cambios, el cual se puede ser utilizado por los gestores técnicos y políticos del territorio, como lo plantea De Alban, et al. (2018).

4.1.3 Evaluación de precisión de clasificación

Se ha aplicado la matriz de precisión general y la concordancia de kappa para el 2021. La tabla 9 reporta los resultados de la evaluación de precisión de la cuantificación de la deforestación mediante la combinación de datos de sensores ópticos y de radar. La matriz de confusión mostro una precisión general de; 84% para Landsat-8, 82% para SAR Sentinel-1, y 88% para la combinación Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1. Mientras que kappa; 0,80 (Considerable) para Landsat-8, 0,78 (Considerable) para SAR Sentinel-1, y 0,84 (Casi perfecta) para Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1 (Cohen 1960; Cohen et al. 2003).

Tabla 9. *Precisión de resultados del sensor óptico Landsat-8, SAR Sentinel-1, y la combinación de Óptico-SAR*

Nivel de clasificación	Categorías	Referencia Totales	Clasificados Totales	Número Correcto	Productores (omisión) Precisión	Usuarios (comisión) Precisión
Landsat-8	Áreas artificializadas	80	55	50	62,50	90,91
	Áreas agrícolas	80	58	51	63,75	87,93
	Bosques y áreas mayormente naturales	117	109	98	83,76	89,91
	Áreas húmedas continentales	80	70	62	77,50	88,57
Totales		357	292	261	71,88	89,33
SAR Sentinel-1	Áreas artificializadas	80	51	40	50,00	78,43
	Áreas agrícolas	80	53	45	56,25	84,91
	Bosques y áreas mayormente naturales	117	101	85	72,65	84,16
	Áreas húmedas continentales	80	90	85	106,25	94,44
Totales		357	295	255	71,29	85,48
Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1	Áreas artificializadas	80	78	65	81,25	83,33
	Áreas agrícolas	80	79	64	80,00	81,01
	Bosques y áreas mayormente naturales	117	116	97	82,91	83,62
	Áreas húmedas continentales	80	79	70	87,50	88,61
Totales		357	352	346	82,91	84,14

La clasificación errónea se produjo principalmente debido a la sobre dimensión de las áreas húmedas por el SAR Sentinel-1 mediante las copolarizaciones VV y polarización cruzada VH expresadas por un usuario relativamente bajo (error de omisión) y precisión del productor (error de comisión) respecto a al sensor óptico y la combinación de óptico-radar, como se reporta por investigaciones con aplicaciones similares (Jiang, et al. 2006; Chen, et al. 2010; Stefanski, et al. 2014; De Alban, et al. 2018; Erinjery, et al. 2018; Steinhausen, et al. 2018) .

Esta situación determina que el umbral definido en Sentinel-1 no cubre toda la variedad de tipos de cobertura presentes en el área de estudio y por

consiguiente la estratificación espacial no responde a los diferentes tipos de cobertura de la tierra. Los sensores ópticos como el Landsat sin la presencia de eventos o fenómenos climáticos presentan resultados considerables, precisión que aumenta mediante la combinación con índices espectrales como el NDVI y polarizaciones de Sentinel-1 (Jiang, et al. 2006; McNairn, et al. 2009; Chen, et al. 2010; Zhang 2010; Zhu, et al. 2012; Gharbia, et al. 2014; Stefanski, et al. 2014; Reiche, et al. 2015; Nair y Bindhu 2016; Chatziantoniou, et al. 2017; De Alban, et al. 2018; Erinjery, et al. 2018; Reiche, et al. 2018; Steinhausen, et al. 2018).

CONCLUSIONES

La agricultura es el principal motor de la pérdida de bosque en la Amazonia. En Tahuamanu, se espera una mayor expansión y por consiguiente la deforestación de los bosques, lo que puede ocasionar problemas al medio ambiente y efectos en las comunidades locales. En el estudio, se propuso cuantificar y evaluar la precisión de la cuantificación de la deforestación mediante datos ópticos Landsat-8 de bandas 6, 5, 4, SAR Sentinel-1 de banda C y polarizaciones VV y VH, y la combinación de Landsat-8, NDVI, y Sentinel-1 en Tahuamanu durante el 2021. Los hallazgos mostraron que la combinación de datos Landsat-8 (incluido NDVI) y SAR Sentinel-1 de banda C presenta mejor comportamiento que los datos de sensores individuales a través de métricas de precisión sólidas y confiables.

El procesamiento mediante el algoritmo Random Forest para Landsat-8 reportó 19435,65 ha, 142,14 ha para SAR Sentinel-1, y 27125,04 ha para la combinación de Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1.

A nivel de precisión, la matriz de confusión mostró un valor general de 84% para Landsat-8, 82% para SAR Sentinel-1, y 88% para la combinación Landsat-8 (bandas; 6,5,4+NDVI) y SAR Sentinel-1. Mientras que kappa; 0,80 (Considerable), 0,78 (Considerable), y 0,84 (Casi perfecta) respectivamente.

Se rechaza la hipótesis nula sobre que la cuantificación de la deforestación en la Amazonia peruana (Tahuamanu) mediante la combinación del sensor óptico Landsat 8 OLI y SAR Sentinel-1, no reporta una mayor precisión respecto a los resultados del sensor óptico y SAR. Debido a que el uso de múltiples sensores de observación de la Tierra resultó útil para generar información sobre el cambio de la cobertura terrestre que ayuda a comprender los procesos de pérdida de bosques en los bosques Amazónicos.

RECOMENDACIONES

El uso de tecnología a RADAR permite la obtención de información minimizando las inclemencias climáticas, la Amazonia abarca un ámbito geográfico caracterizado por elevadas precipitaciones y alta humedad relativa, por lo que su monitoreo en todo el periodo anual se hace imposible. En ese contexto, la fusión de tecnologías SAR y ópticos permitirían un monitoreo continuo y con resultados más fiables.

El uso de tecnologías de teledetección debe ser transversal en las carreras de ingeniería o afines como ciencia orientada a la planificación del territorio.

REFERENCIAS BIBLIOGRÁFICAS

AKBAR, R., DAS, N., ENTEKHABI, D. Y MOGHADDAM, M. Chapter 10 - Active and Passive Microwave Remote Sensing Synergy for Soil Moisture Estimation. In P.K. SRIVASTAVA, G.P. PETROPOULOS Y Y.H. KERR eds. *Satellite Soil Moisture Retrieval*. Elsevier, 2016, p. 187-207.

ALARCON, 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>

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.

ASNER, G. P., KNAPP, D. E., MARTIN, R. E., TUPAYACHI, R., ANDERSON, C. B., MASCARO, J., SINCA, F., CHADWICK, K. D., HIGGINS, M. Y FARFAN, W. Targeted carbon conservation at national scales with high-resolution monitoring. *Proceedings of the National Academy of Sciences*, 2014, 111(47), E5016-E5022. doi:<https://doi.org/10.1073/pnas.1419550111>

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

BAGHDADI, N. Y ZRIBI, M. Introduction. In N. BAGHDADI Y M. ZRIBI eds. *Optical Remote Sensing of Land Surface*. Elsevier, 2016, p. xxxix-xlii.

BARAY, H. L. Á. *Introducción a la metodología de la investigación*. Edition ed.: Juan Carlos Martínez Coll, 2006. ISBN 8469019996.

BAX, V. Y FRANCESCONI, W. Environmental predictors of forest change: An analysis of natural predisposition to deforestation in the tropical Andes region, Peru. *Applied Geography*, 2018/02/01/ 2018, 91, 99-110. doi:<https://doi.org/10.1016/j.apgeog.2018.01.002>

BOOYSEN, R., GLOAGUEN, R., LORENZ, S., ZIMMERMANN, R. Y NEX, P. A. M. Geological Remote Sensing. In D. ALDERTON Y S.A. ELIAS eds. *Encyclopedia of Geology (Second Edition)*. Oxford: Academic Press, 2021, p. 301-314.

BREIMAN, L. Bagging predictors. *Machine learning*, 1996, 24(2), 123-140. doi:<https://doi.org/10.1007/BF00058655>

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.

CABRAL, A. I. R., SAITO, C., PEREIRA, H. Y LAQUES, A. E. Deforestation pattern dynamics in protected areas of the Brazilian Legal Amazon using remote sensing data. *Applied Geography*, 2018/11/01/ 2018, 100, 101-115. doi:<https://doi.org/10.1016/j.apgeog.2018.10.003>

CARLSON, T. N. Y RIPLEY, D. A. On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment*, 1997/12/01/ 1997, 62(3), 241-252. doi:[https://doi.org/10.1016/S0034-4257\(97\)00104-1](https://doi.org/10.1016/S0034-4257(97)00104-1)

CARVALHO, W. D., MUSTIN, K., HILÁRIO, R. R., VASCONCELOS, I. M., EILERS, V. Y FEARNSIDE, P. M. Deforestation control in the Brazilian Amazon: A conservation struggle being lost as agreements and regulations are subverted and bypassed. *Perspectives in Ecology and Conservation*, 2019/07/01/ 2019, 17(3), 122-130. doi:<https://doi.org/10.1016/j.pecon.2019.06.002>

CASTRO, F. El proceso de investigación y su esquema de elaboración. Editorial Uyapar. Caracas, 2003.

CAZAU, P. Introducción a la investigación en ciencias sociales. Lima. Editorial Universidad Ricardo Palma, 2006.

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>

CHATZIANTONIOU, A., PSOMIADIS, E. Y PETROPOULOS, G. P. Co-Orbital Sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a mediterranean setting based on machine learning. *Remote Sensing*, 2017, 9(12), 1259.

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

CHEN, S., ZHANG, R., SU, H., TIAN, J. Y XIA, J. SAR and multispectral image fusion using generalized IHS transform based on à trous wavelet and EMD decompositions. *IEEE Sensors Journal*, 2010, 10(3), 737-745.

CHIRIF, A. *Deforestación en tiempos de cambio climático*. Edition ed.: IWGIA, Grupo Internacional de Trabajo sobre Asuntos Indígenas, 2018. ISBN 8792786847.

CHUVIECO, E. Empleo de imágenes de satélite para medir la estructura del paisaje: análisis cuantitativo y representación cartográfica. *Serie Geográfica*, 1996, 6, 131-147.

CHUVIECO, E. *Teledetección espacial: la observación de la Tierra desde el espacio* 2002.

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.

DE ALBAN, J. D. T., CONNETTE, G. M., OSWALD, P. Y WEBB, E. L. Combined Landsat and L-Band SAR Data Improves Land Cover Classification and Change Detection in Dynamic Tropical Landscapes. *Remote Sensing*, 2018, 10(2). doi:10.3390/rs10020306

DONG, J., METTERNICHT, G., HOSTERT, P., FENSHOLT, R. Y CHOWDHURY, R. R. Remote sensing and geospatial technologies in support of a normative land system science: Status and prospects. *Current Opinion in Environmental Sustainability*, 2019, 38, 44-52.

DOUROJEANNI, M. Esbozo de una nueva política forestal peruana. *Revista Forestal del Perú*, 2019, 34(1), 4-20.

ELIAS, F., FERREIRA, J., LENNOX, G. D., BERENGUER, E., FERREIRA, S., SCHWARTZ, G., MELO, L. D. O., REIS JUNIOR, D. N., NASCIMENTO, R. O. Y FERREIRA, F. N. Assessing the growth and climate sensitivity of secondary forests in highly deforested Amazonian landscapes. *Ecology*, 2020, 101(3), e02954.

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

ERINJERY, J. J., SINGH, M. Y KENT, R. Mapping and assessment of vegetation types in the tropical rainforests of the Western Ghats using multispectral Sentinel-2 and SAR Sentinel-1 satellite imagery. *Remote Sensing of Environment*, 2018, 216, 345-354.

ESA Sentinel-1 user handbook. European Space Agency 2013.

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.

GHARBIA, R., AZAR, A. T., BAZ, A. E. Y HASSANIEN, A. E. Image fusion techniques in remote sensing. arXiv preprint arXiv:1403.5473, 2014.

GORELICK, N., HANCHER, M., DIXON, M., ILYUSHCHENKO, S., THAU, D. Y MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 2017, 202, 18-27.

GOREMAD Y IIAP. Macro Zonificación Ecológica Económica de Madre de Dios. Madre de Dios - Perú, 2009, p. 208.

HÄME, T., SIRRO, L., CABRERA, E., HAARPAINTNER, J., HEINZEL, J., HÄMÄLÄINEN, J., DE JONG, B., PELLAT, F. P., PEDRAZZANI, D. Y REICHE, J. ReCover: Services for the Monitoring of Tropical Forest to Support REDD+. In *Let's Embrace Space, vol. II*. EU, 2012, p. 106-114.

HANDBOOK, N. Origin & Cause Determination Handbook. 2005.

HANSEN, M. C., POTAPOV, P. V., MOORE, R., HANCHER, M., TURUBANOVA, S. A., TYUKAVINA, A., THAU, D., STEHMAN, S. V., GOETZ, S. J. Y LOVELAND, T. R. High-resolution global maps of 21st-century forest cover change. *Science*, 2013, 342(6160), 850-853.

HERNÁNDEZ, H. Y MONTANER, D. Patrones de respuesta espectral. *Tecnologías Geoespaciales: Experiencias Aplicadas al Estudio y Gestión del Territorio*. Carlos Mena (Ed.) ISBN, 2009, 978-996.

HERNÁNDEZ, M. ¿Cómo están los bosques en el mundo? La Evaluación de Recursos Forestales de la FAO responde este interrogante. *Boletín El Palmicultor*, 2020, 582(Agosto), 2021-2021.

HERNÁNDEZ, R., FERNÁNDEZ, C. Y BAPTISTA, P. *Metodología de la Investigación (Quinta edición ed.)*. (J. Mares Chacón, Ed.) Mexico, México DF. Edtion ed.: McGraw-Hill/Interamericana Editores, SA de CV, 2010.

HIJMANS, R. J. Y VAN ETTEN, J. raster: Geographic data analysis and modeling. R package version, 2014, 2(8).

HONG, G., ZHANG, A., ZHOU, F. Y BRISCO, B. Integration of optical and synthetic aperture radar (SAR) images to differentiate grassland and alfalfa in Prairie area. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 28, 12-19.

HUAMANI, V., ALARCÓN, G., CANAHUIRE, R., HERRERA-MACHACA, M. Y GARATE-QUISPE, J. Natural regeneration of trees and shrubs in degraded areas by gold mining in the Peruvian Amazon. In *Ensino, pesquisa e inovação em botânica*. Ponta Grossa – Paraná – Brasil: Atena Editora, 2021, p. 1-388.

HUANG, X., CAO, Y. Y LI, J. An automatic change detection method for monitoring newly constructed building areas using time-series multi-view high-resolution optical satellite images. *Remote Sensing of Environment*, 2020, 244, 111802.

IDEAM. Leyenda nacional de coberturas de la tierra. Metodología CORINE Land Cover adaptada para Colombia escala 1: 100.000. In.: Instituto de Hidrología Meteorología y Estudios Ambientales (IDEAM), Instituto Geográfico Agustín Codazzi (IGAC), and Corporación Aotónoma Regional del Magdalena (CORMAGDALENA), Bogotá, Colombia, 2010.

INEI. Magnitud y Crecimiento Poblacional. 2017.

INPE. Amazon program—monitoring the Brazilian Amazon by satellite: the PRODES, DETER, DEGRAD and terraclass systems. 2020a.

INPE. Projeto PRODES: Monitoramento da Floresta Amazônica Brasileira por satélite. 2020b.

JENSEN, J. R. *Remote sensing of the environment: An earth resource perspective 2/e*. Edition ed.: Pearson Education India, 2009. ISBN 8131716805.

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>

JIANG, Z. *Geographical Information System in Web Application: Developing Web Application to Serve Spatial Data to Users* 2020. doi:<https://urn.fi/URN:NBN:fi:amk-202001231535>

JIANG, Z., HUETE, A. R., CHEN, J., CHEN, Y., LI, J., YAN, G. Y ZHANG, X. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote Sensing of Environment*, 2006, 101(3), 366-378.

JOSHI, N., BAUMANN, M., EHAMMER, A., FENSHOLT, R., GROGAN, K., HOSTERT, P., JEPSEN, M. R., KUEMMERLE, T., MEYFROIDT, P. Y MITCHARD, E. T. A. A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing*, 2016, 8(1), 70.

KERLE, N., JANSSEN, L. L. F. Y HUURNEMAN, G. C. *Principles of remote sensing*. ITC, Educational textbook series, 2004, 2, 250.

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>

LEITE-FILHO, A. T., COSTA, M. H. Y FU, R. The southern Amazon rainy season: The role of deforestation and its interactions with large-scale mechanisms. *International Journal of Climatology*, 2020, 40(4), 2328-2341. doi:<https://doi.org/10.1002/joc.6335>

LENNOX, G. D., GARDNER, T. A., THOMSON, J. R., FERREIRA, J., BERENGUER, E., LEES, A. C., MAC NALLY, R., ARAGÃO, L. E. O. C., FERRAZ, S. F. B. Y LOUZADA, J. Second rate or a second chance? Assessing biomass and biodiversity recovery in regenerating Amazonian forests. *Global Change Biology*, 2018, 24(12), 5680-5694.

LESIV, M., SCHEPASCHENKO, D., MOLTCHANOVA, E., BUN, R., DÜRAUER, M., PRISHCHEPOV, A. V., SCHIERHORN, F., ESTEL, S., KUEMMERLE, T. Y ALCÁNTARA, C. Spatial distribution of arable and abandoned land across former Soviet Union countries. *Scientific data*, 2018, 5(1), 1-12.

LI, S., KANG, X., FANG, L., HU, J. Y YIN, H. Pixel-level image fusion: A survey of the state of the art. *Information Fusion*, 2017, 33, 100-112.

LI, X., ZHOU, Y., GONG, P., SETO, K. C. Y CLINTON, N. Developing a method to estimate building height from Sentinel-1 data. *Remote Sensing of Environment*, 2020, 240, 111705. doi:<https://doi.org/10.1016/j.rse.2020.111705>

LUND, H. G. *Definitions of forest, deforestation, afforestation, and reforestation*. Edition ed.: Forest Information Services Gainesville, VA, 2006.

MARIACA, B. Y ANDRÉS, W. Circulación atmosférica sobre territorio boliviano durante la fase activa y pasiva del monzón sudamericano. *Revista Boliviana de Física*, 2007, 13(13), 45-53.

MARKHAM, B. L., ARVIDSON, T., BARSİ, J. A., CHOATE, M., KAITA, E., LEVY, R., LUBKE, M. Y MASEK, J. G. Landsat program. *Comprehensive remote sensing*, 2018, 27-90.

MCNAIRN, H., CHAMPAGNE, C., SHANG, J., HOLMSTROM, D. Y REICHERT, G. Integration of optical and Synthetic Aperture Radar (SAR)

imagery for delivering operational annual crop inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2009, 64(5), 434-449.

MELCHIORRI, M., FLORCZYK, A. J., FREIRE, S., SCHIAVINA, M., PESARESI, M. Y KEMPER, T. Unveiling 25 years of planetary urbanization with remote sensing: Perspectives from the global human settlement layer. *Remote Sensing*, 2018, 10(5), 768.

MINAM. Informe Final del Proyecto: Análisis de las Dinámicas de Cambio de Cobertura de la Tierra en la Comunidad Andina. In *Componente Nacional Perú–Primera Etapa. Centro de Datos para la Conservación (CDC-UNALM). Laboratorio de Teledetección (LTAUNALM). Dirección General de Ordenamiento Territorial-Ministerio del Ambiente (DGOT-MINAM). Fundación para el Desarrollo Agrario (FDA). Lima-Perú. 2012.*

MINAM. Bosque y pérdida de bosque del Perú. Perú 2020.

MURAD, C. A. Y PEARSE, J. Landsat study of deforestation in the Amazon region of Colombia: Departments of Caquetá and Putumayo. *Remote Sensing Applications: Society and Environment*, 2018/08/01/ 2018, 11, 161-171. doi:<https://doi.org/10.1016/j.rsase.2018.07.003>

MUTANGA, O. Y KUMAR, L. Google earth engine applications. In.: *Multidisciplinary Digital Publishing Institute*, 2019.

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

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

OPPENHEIMER, C. Sabins, FF 1997. Remote Sensing. Principles and Interpretation, xiii+ 494 pp. New York: WH Freeman & Co. Price£ 32.95 (hard covers). ISBN 0 7167 2442 1. Geological Magazine, 1998, 135(1), 143-158.

OU, L. C., RONNIER LUO, M., SUN, P. L., HU, N. C., CHEN, H. S., GUAN, S. S., WOODCOCK, A., CAIVANO, J. L., HUERTAS, R. Y TREMÉAU, A. A cross-cultural comparison of colour emotion for two-colour combinations. Color Research & Application, 2012, 37(1), 23-43.

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>

PLANET-TEAM. Planet Application Program Interface: In Space for Life on Earth. 2021. Disponible en Internet:<<https://api.planet.com>>

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

PUZZI, A., FLORES-ANDERSON, A., GRIFFIN, R., HERNDON, K. Y MEYER, F. J. Assessing SAR C-band data to effectively distinguish modified land uses

in a heavily disturbed Amazon forest. *International Journal of Applied Earth Observation and Geoinformation*, 2020, 94, 102-214.

PUZZI, A., FLORES-ANDERSON, A., GRIFFIN, R., HERNDON, K. Y MEYER, F. J. Assessing SAR C-band data to effectively distinguish modified land uses in a heavily disturbed Amazon forest. *International Journal of Applied Earth Observation and Geoinformation*, 2021/02/01/ 2021, 94, 102214. doi:<https://doi.org/10.1016/j.jag.2020.102214>

RAISG. Deforestación en la Amazonía (1970-2013). 2015.

RAISG. Destrucción del Amazonas: las principales amenazas para la mayor selva tropical del mundo en los 9 países que la comparten (2001-2018). 2020.

RAJAH, P., ODINDI, J. Y MUTANGA, O. Feature level image fusion of optical imagery and Synthetic Aperture Radar (SAR) for invasive alien plant species detection and mapping. *Remote Sensing Applications: Society and Environment*, 2018/04/01/ 2018, 10, 198-208. doi:<https://doi.org/10.1016/j.rsase.2018.04.007>

REICHE, J. Peer reviewed journals. Combining SAR and optical satellite image time series for tropical forest monitoring, 2015, 156, 146.

REICHE, J., HAMUNYELA, E., VERBESSELT, J., HOEKMAN, D. Y HEROLD, M. Improving near-real time deforestation monitoring in tropical dry forests by combining dense Sentinel-1 time series with Landsat and ALOS-2 PALSAR-2. *Remote Sensing of Environment*, 2018/01/01/ 2018, 204, 147-161. doi:<https://doi.org/10.1016/j.rse.2017.10.034>

REICHE, J., SOUZA, C. M., HOEKMAN, D. H., VERBESSELT, J., PERSAUD, H. Y HEROLD, M. Feature level fusion of multi-temporal ALOS PALSAR and Landsat data for mapping and monitoring of tropical deforestation and forest degradation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(5), 2159-2173.

REICHE, J., VERBESSELT, J., HOEKMAN, D. Y HEROLD, M. Fusing Landsat and SAR time series to detect deforestation in the tropics. Remote Sensing of Environment, 2015, 156, 276-293.
doi:<https://doi.org/10.1016/j.rse.2014.10.001>

REZENDE, G. M. Y VIEIRA, D. L. M. Forest restoration in southern Amazonia: Soil preparation triggers natural regeneration. Forest ecology and management, 2019/02/15/ 2019, 433, 93-104.
doi:<https://doi.org/10.1016/j.foreco.2018.10.049>

RODRIGUEZ-GALIANO, V. F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M. Y RIGOL-SANCHEZ, J. P. An assessment of the effectiveness of a random forest classifier for land-cover classification. ISPRS Journal of Photogrammetry and Remote Sensing, 2012/01/01/ 2012, 67, 93-104.
doi:<https://doi.org/10.1016/j.isprsjprs.2011.11.002>

ROY, D. P., WULDER, M. A., LOVELAND, T. R., C.E, W., ALLEN, R. G., ANDERSON, M. C., HELDER, D., IRONS, J. R., JOHNSON, D. M., KENNEDY, R., SCAMBOS, T. A., SCHAAF, C. B., SCHOTT, J. R., SHENG, Y., VERMOTE, E. F., BELWARD, A. S., BINDSCHADLER, R., COHEN, W. B., GAO, F., HIPPLE, J. D., HOSTERT, P., HUNTINGTON, J., JUSTICE, C. O., KILIC, A., KOVALSKYY, V., LEE, Z. P., LYMBURNER, L., MASEK, J. G., MCCORKEL, J., SHUAI, Y., TREZZA, R., VOGELMANN, J., WYNNE, R. H. Y ZHU, Z. Landsat-8: Science and product vision for terrestrial global change research. Remote Sensing of Environment, 2014/04/05/ 2014, 145, 154-172.
doi:<https://doi.org/10.1016/j.rse.2014.02.001>

SAMEEN, M. I., NAHHAS, F. H., BURAIHI, F. H., PRADHAN, B. Y SHARIFF, A. R. B. M. A refined classification approach by integrating Landsat Operational Land Imager (OLI) and RADARSAT-2 imagery for land-use and land-cover mapping in a tropical area. International journal of remote sensing, 2016, 37(10), 2358-2375.

SERRANO, M. A. M., CATANIA, M., SÁNCHEZ, J., VASCONCELOS, A., KUIJPER, D. Y MARC, X. Sentinel-1A flight dynamics LEOP operational experience. In., 2015.

SHANER, J. Y WRIGHTSELL, J. *Editing in arcMap*. Edition ed.: Esri, 2000. ISBN 1879102978.

SICA, F., PULELLA, A., NANNINI, M., PINHEIRO, M. Y RIZZOLI, P. Repeat-pass SAR interferometry for land cover classification: A methodology using Sentinel-1 Short-Time-Series. *Remote Sensing of Environment*, 2019, 232, 111-277.

STEFANSKI, J., KUEMMERLE, T., CHASKOVSKYY, O., GRIFFITHS, P., HAVRYLUK, V., KNORN, J., KOROL, N., SIEBER, A. Y WASKE, B. Mapping land management regimes in western Ukraine using optical and SAR data. *Remote Sensing*, 2014, 6(6), 5279-5305.

STEINHAUSEN, M. J., WAGNER, P. D., NARASIMHAN, B. Y WASKE, B. Combining Sentinel-1 and Sentinel-2 data for improved land use and land cover mapping of monsoon regions. *International Journal of Applied Earth Observation and Geoinformation*, 2018/12/01/ 2018, 73, 595-604. doi:<https://doi.org/10.1016/j.jag.2018.08.011>

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), 1-7.

TORRES, R., SNOEIJ, P., GEUDTNER, D., BIBBY, D., DAVIDSON, M., ATTEMA, E., POTIN, P., ROMMEN, B., FLOURY, N. Y BROWN, M. GMES Sentinel-1 mission. *Remote Sensing of Environment*, 2012, 120, 9-24. doi:<https://doi.org/10.1016/j.rse.2011.05.028>

VAN DUIJVENBODE, J. D., REICHE, J. Y FORSTREUTER, W. Forest stratification in Fiji using high resolution satellite imagery 2014.

VELÁSQUEZ, M. G., VEGA RUIZ, C. M., GOMRINGER, R. C., PILLACA, M., THOMAS, E., STEWART, P. M., GAMARRA MIRANDA, L. A., DAÑOBEYTIA, F. R., GUERRERO BARRANTES, J. A., GUSHIKEN, M. C., BARDALES, J. V., SILMAN, M., FERNANDEZ, L., ASCORRA, C. Y TORRES, D. D. C. Mercury in soils impacted by alluvial gold mining in the Peruvian Amazon. *Journal of Environmental Management*, 2021/06/15/ 2021, 288, 112364. doi:<https://doi.org/10.1016/j.jenvman.2021.112364>

WIECZOREK, W. F. Y DELMERICO, A. M. Geographic information systems. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2009, 1(2), 167-186.

WILLIAMS, D. L., GOWARD, S. Y ARVIDSON, T. Landsat. *Photogrammetric Engineering & Remote Sensing*, 2006, 72(10), 1171-1178.

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>

ZHANG, J. Multi-source remote sensing data fusion: status and trends. *International Journal of Image and Data Fusion*, 2010, 1(1), 5-24.

ZHU, Z., WOODCOCK, C. E., ROGAN, J. Y KELLNDORFER, J. Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using Landsat and SAR data. *Remote Sensing of Environment*, 2012, 117, 72-82.

ZHU, Z., ZHOU, Y., SETO, K. C., STOKES, E. C., DENG, C., PICKETT, S. T. A. Y TAUBENBÖCK, H. Understanding an urbanizing planet: Strategic directions for remote sensing. *Remote Sensing of Environment*, 2019, 228, 164-182.

ZUHLKE, M., FOMFERRA, N., BROCKMANN, C., PETERS, M., VECI, L., MALIK, J. Y REGNER, P. SNAP (sentinel application platform) and the ESA sentinel 3 toolbox. ESASP, 2015, 734, 21.

ANEXOS

Anexo 1. Puntos de muestreo tomados en la provincia de tahuamanu.

N°	Categoría	Coordinada UTM (WGS84)	
		Este	Norte
1	Bosques y áreas mayormente naturales	481657	8690897
2	Bosques y áreas mayormente naturales	479880	8692840
3	Bosques y áreas mayormente naturales	479038	8694310
4	Bosques y áreas mayormente naturales	481608	8695118
5	Bosques y áreas mayormente naturales	482635	8696826
6	Bosques y áreas mayormente naturales	478567	8700807
7	Bosques y áreas mayormente naturales	480388	8702184
8	Bosques y áreas mayormente naturales	480480	8704318
9	Bosques y áreas mayormente naturales	479545	8704886
10	Bosques y áreas mayormente naturales	481414	8706453
11	Bosques y áreas mayormente naturales	479404	8706973
12	Bosques y áreas mayormente naturales	478468	8707921
13	Bosques y áreas mayormente naturales	475523	8708488
14	Bosques y áreas mayormente naturales	478143	8704743
15	Bosques y áreas mayormente naturales	480998	8698959
16	Bosques y áreas mayormente naturales	479174	8700333
17	Bosques y áreas mayormente naturales	473789	8714035
18	Bosques y áreas mayormente naturales	472759	8715125
19	Bosques y áreas mayormente naturales	471076	8715503
20	Bosques y áreas mayormente naturales	468875	8718679
21	Bosques y áreas mayormente naturales	466911	8718534
22	Bosques y áreas mayormente naturales	466441	8720573
23	Bosques y áreas mayormente naturales	466346	8722375
24	Bosques y áreas mayormente naturales	469621	8720861
25	Bosques y áreas mayormente naturales	469759	8723043
26	Bosques y áreas mayormente naturales	466672	8723988
27	Bosques y áreas mayormente naturales	465501	8725504
28	Bosques y áreas mayormente naturales	469617	8724655
29	Bosques y áreas mayormente naturales	466811	8724605
30	Bosques y áreas mayormente naturales	469854	8721667
31	Bosques y áreas mayormente naturales	470412	8724940
32	Bosques y áreas mayormente naturales	465078	8727116
33	Bosques y áreas mayormente naturales	465123	8728587
34	Bosques y áreas mayormente naturales	462737	8729248
35	Bosques y áreas mayormente naturales	463207	8727589
36	Bosques y áreas mayormente naturales	464004	8725645
37	Bosques y áreas mayormente naturales	464800	8724460
38	Bosques y áreas mayormente naturales	469009	8724844

39	Bosques y áreas mayormente naturales	462263	8734279
40	Bosques y áreas mayormente naturales	460297	8735320
41	Bosques y áreas mayormente naturales	464270	8738076
42	Bosques y áreas mayormente naturales	462645	8728067
43	Bosques y áreas mayormente naturales	464096	8726788
44	Bosques y áreas mayormente naturales	457911	8734985
45	Bosques y áreas mayormente naturales	450937	8737346
46	Bosques y áreas mayormente naturales	439585	8752314
47	Bosques y áreas mayormente naturales	436259	8753588
48	Bosques y áreas mayormente naturales	446095	8750618
49	Bosques y áreas mayormente naturales	446699	8753559
50	Bosques y áreas mayormente naturales	442810	8755307
51	Bosques y áreas mayormente naturales	441013	8764955
52	Bosques y áreas mayormente naturales	436748	8767129
53	Bosques y áreas mayormente naturales	440587	8767658
54	Bosques y áreas mayormente naturales	439368	8768462
55	Bosques y áreas mayormente naturales	436693	8771018
56	Bosques y áreas mayormente naturales	441284	8770647
57	Bosques y áreas mayormente naturales	436408	8772962
58	Bosques y áreas mayormente naturales	438654	8774531
59	Bosques y áreas mayormente naturales	441482	8764529
60	Bosques y áreas mayormente naturales	436139	8766796
61	Bosques y áreas mayormente naturales	439837	8767894
62	Bosques y áreas mayormente naturales	437301	8771493
63	Bosques y áreas mayormente naturales	440535	8770503
64	Bosques y áreas mayormente naturales	437204	8773058
65	Bosques y áreas mayormente naturales	436367	8769974
66	Bosques y áreas mayormente naturales	435989	8771633
67	Bosques y áreas mayormente naturales	436034	8772582
68	Bosques y áreas mayormente naturales	440346	8771499
69	Bosques y áreas mayormente naturales	434251	8774494
70	Bosques y áreas mayormente naturales	432044	8776814
71	Bosques y áreas mayormente naturales	429182	8778752
72	Bosques y áreas mayormente naturales	431753	8781698
73	Bosques y áreas mayormente naturales	428377	8782781
74	Bosques y áreas mayormente naturales	429309	8784965
75	Bosques y áreas mayormente naturales	426401	8786382
76	Bosques y áreas mayormente naturales	433939	8789385
77	Bosques y áreas mayormente naturales	440577	8772941
78	Bosques y áreas mayormente naturales	440339	8774980
79	Bosques y áreas mayormente naturales	434436	8775443
80	Bosques y áreas mayormente naturales	433120	8777575
81	Bosques y áreas mayormente naturales	443323	8756679

82	Bosques y áreas mayormente naturales	440657	8755204
83	Bosques y áreas mayormente naturales	469197	8724038
84	Bosques y áreas mayormente naturales	466345	8723229
85	Bosques y áreas mayormente naturales	469060	8721192
86	Bosques y áreas mayormente naturales	470557	8720103
87	Bosques y áreas mayormente naturales	472336	8717354
88	Bosques y áreas mayormente naturales	473326	8708225
89	Bosques y áreas mayormente naturales	475946	8705382
90	Bosques y áreas mayormente naturales	477629	8704956
91	Bosques y áreas mayormente naturales	478751	8704530
92	Bosques y áreas mayormente naturales	479921	8702255
93	Bosques y áreas mayormente naturales	481840	8696512
94	Bosques y áreas mayormente naturales	477682	8696130
95	Bosques y áreas mayormente naturales	477775	8697553
96	Bosques y áreas mayormente naturales	482447	8697556
97	Bosques y áreas mayormente naturales	482168	8695706
98	Bosques y áreas mayormente naturales	481233	8695848
99	Bosques y áreas mayormente naturales	482264	8691912
100	Bosques y áreas mayormente naturales	480863	8691105
101	Bosques y áreas mayormente naturales	481751	8689066
102	Bosques y áreas mayormente naturales	482544	8691106
103	Bosques y áreas mayormente naturales	484133	8691155
104	Bosques y áreas mayormente naturales	480349	8691247
105	Bosques y áreas mayormente naturales	481936	8693430
106	Bosques y áreas mayormente naturales	479693	8693571
107	Bosques y áreas mayormente naturales	479085	8694898
108	Bosques y áreas mayormente naturales	480630	8690014
109	Bosques y áreas mayormente naturales	480863	8691105
110	Bosques y áreas mayormente naturales	481099	8686315
111	Bosques y áreas mayormente naturales	482546	8688735
112	Bosques y áreas mayormente naturales	486331	8684943
113	Bosques y áreas mayormente naturales	484602	8686175
114	Bosques y áreas mayormente naturales	480668	8702867
115	Bosques y áreas mayormente naturales	480199	8706613
116	Bosques y áreas mayormente naturales	479871	8707514
117	Bosques y áreas mayormente naturales	475805	8705851
118	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	484228	8687598
119	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	485115	8688120
120	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	484088	8686744

121	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	486565	8684231
122	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	482921	8686174
123	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	486565	8683425
124	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	486613	8682192
125	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	487640	8683331
126	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	487172	8684706
127	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	486938	8685939
128	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	485723	8687693
129	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	485442	8689590
130	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	480721	8692623
131	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	480440	8693713
132	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	480487	8694283
133	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	480391	8697223
134	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	479831	8697602
135	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	479409	8698313
136	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	479409	8698313
137	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	479923	8699072
138	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	480950	8700401
139	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	480950	8700401

140	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	479407	8701823
141	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	480436	8701207
142	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	481837	8702204
143	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	479032	8703103
144	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	478331	8703672
145	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	481322	8703721
146	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	481322	8703721
147	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	479311	8705901
148	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	478750	8705806
149	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	478235	8706659
150	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	476972	8708461
151	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	476972	8708461
152	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	475384	8707321
153	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	476083	8709930
154	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	474352	8711124
155	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	473838	8711171
156	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	473837	8712357
157	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	474306	8710460
158	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	472947	8713636

159	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	472526	8714300
160	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	471964	8715722
161	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	471776	8716670
162	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	470560	8717333
163	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	469623	8718660
164	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	469014	8719608
165	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	468359	8720177
166	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	467937	8721220
167	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	468310	8722738
168	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	467558	8726294
169	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	466197	8730656
170	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	466383	8731462
171	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	465866	8733691
172	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	464602	8734211
173	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	463572	8735395
174	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	462729	8736248
175	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	459640	8736671
176	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	458283	8736954
177	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	456597	8738327

178	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	454584	8739083
179	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	453461	8739081
180	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	452712	8739412
181	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	452476	8740503
182	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	447050	8739071
183	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	447231	8742771
184	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	447605	8743340
185	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	446574	8744098
186	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	440654	8756456
187	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	439998	8756739
188	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	441117	8759445
189	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	439242	8760579
190	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	438957	8762950
191	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	439471	8763425
192	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	437363	8763991
193	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	436236	8765411
194	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	437126	8765413
195	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	437922	8765367
196	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	439140	8764942

197	Áreas artificializadas; áreas urbanizadas, áreas industriales e infraestructura, y áreas de extracción de minería e infraestructura y escombreras	439313	8772441
198	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	430346	8784508
199	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	430423	8785416
200	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	431356	8786523
201	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	428349	8788411
202	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	430348	8783955
203	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	429801	8784152
204	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	436578	8788309
205	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	436772	8788862
206	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	436849	8789494
207	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	437086	8787718
208	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	436662	8785073
209	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	438883	8786104
210	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	436088	8779784
211	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	436246	8778560
212	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	437104	8778325
213	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	437064	8779233
214	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	434922	8777650
215	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	437730	8777261
216	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	438006	8775604
217	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	438635	8772882
218	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	439623	8765740
219	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	439899	8763688
220	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	440295	8760611
221	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	442518	8759431
222	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	439603	8755321
223	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	439527	8754492
224	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	440069	8756229

225	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	442496	8750156
226	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	444416	8743292
227	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	443127	8745460
228	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	435805	8745723
229	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	439306	8747742
230	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	438136	8748806
231	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	437043	8750027
232	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	436028	8750933
233	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	445930	8746215
234	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	445893	8745150
235	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	444999	8744398
236	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	444847	8742069
237	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	468509	8717711
238	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	468549	8716409
239	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	468666	8715896
240	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	472207	8716334
241	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	471389	8717280
242	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	471155	8717832
243	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	470454	8718424
244	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	471276	8713096
245	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	470847	8713491
246	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	470497	8713214
247	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	469602	8713647
248	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	469485	8714121
249	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	469485	8714121
250	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	468784	8714475
251	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	468784	8714475
252	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	471086	8708479
253	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	471242	8707453

254	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	471281	8706940
255	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	470386	8707294
256	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	470386	8707294
257	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	471088	8706229
258	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	472255	8705599
259	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	476415	8708680
260	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	487392	8690572
261	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	487586	8691203
262	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	487702	8692506
263	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	487079	8693018
264	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	486496	8693729
265	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	482107	8686543
266	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	482028	8687569
267	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	485138	8687611
268	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	486032	8688756
269	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	485837	8688400
270	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	487314	8689230
271	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	487042	8690374
272	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	487472	8685046
273	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	488249	8686112
274	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	490193	8684613
275	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	489454	8684337
276	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	488560	8683902
277	Áreas agrícolas; cultivos transitorios, cultivos permanentes, pastos, y áreas agrícolas heterogéneas	484010	8689544
278	Áreas húmedas continentales	489034	8682462
279	Áreas húmedas continentales	488726	8682330
280	Áreas húmedas continentales	488386	8682149
281	Áreas húmedas continentales	487868	8681919
282	Áreas húmedas continentales	487447	8681787
283	Áreas húmedas continentales	489293	8682922
284	Áreas húmedas continentales	490167	8683038

285	Áreas húmedas continentales	490734	8682939
286	Áreas húmedas continentales	490944	8683153
287	Áreas húmedas continentales	491090	8683449
288	Áreas húmedas continentales	488158	8685290
289	Áreas húmedas continentales	485016	8685502
290	Áreas húmedas continentales	485551	8684697
291	Áreas húmedas continentales	480592	8689562
292	Áreas húmedas continentales	480138	8690137
293	Áreas húmedas continentales	479992	8690647
294	Áreas húmedas continentales	479684	8691617
295	Áreas húmedas continentales	483652	8692408
296	Áreas húmedas continentales	482939	8692589
297	Áreas húmedas continentales	482566	8692802
298	Áreas húmedas continentales	481610	8693081
299	Áreas húmedas continentales	481092	8693426
300	Áreas húmedas continentales	480749	8698212
301	Áreas húmedas continentales	481202	8698705
302	Áreas húmedas continentales	482109	8699100
303	Áreas húmedas continentales	481590	8699347
304	Áreas húmedas continentales	483160	8703262
305	Áreas húmedas continentales	482771	8703475
306	Áreas húmedas continentales	482236	8703804
307	Áreas húmedas continentales	481798	8704280
308	Áreas húmedas continentales	481490	8704593
309	Áreas húmedas continentales	479526	8708998
310	Áreas húmedas continentales	479169	8709426
311	Áreas húmedas continentales	479931	8709328
312	Áreas húmedas continentales	480158	8710002
313	Áreas húmedas continentales	480790	8710249
314	Áreas húmedas continentales	480854	8710529
315	Áreas húmedas continentales	478312	8707633
316	Áreas húmedas continentales	465990	8725776
317	Áreas húmedas continentales	466526	8724889
318	Áreas húmedas continentales	466025	8723704
319	Áreas húmedas continentales	465848	8722471
320	Áreas húmedas continentales	465865	8721221
321	Áreas húmedas continentales	465688	8720695
322	Áreas húmedas continentales	465705	8720037
323	Áreas húmedas continentales	467015	8722998
324	Áreas húmedas continentales	467046	8723886
325	Áreas húmedas continentales	467224	8724610
326	Áreas húmedas continentales	467320	8725317
327	Áreas húmedas continentales	467379	8731616

328	Áreas húmedas continentales	467331	8731204
329	Áreas húmedas continentales	467104	8730793
330	Áreas húmedas continentales	464914	8731037
331	Áreas húmedas continentales	464897	8731514
332	Áreas húmedas continentales	464314	8731020
333	Áreas húmedas continentales	463762	8731250
334	Áreas húmedas continentales	463243	8731479
335	Áreas húmedas continentales	463114	8731002
336	Áreas húmedas continentales	462546	8731150
337	Áreas húmedas continentales	461945	8731642
338	Áreas húmedas continentales	461863	8732070
339	Áreas húmedas continentales	468174	8731567
340	Áreas húmedas continentales	468466	8731074
341	Áreas húmedas continentales	468207	8730613
342	Áreas húmedas continentales	468791	8730137
343	Áreas húmedas continentales	469440	8730236
344	Áreas húmedas continentales	469066	8730877
345	Áreas húmedas continentales	468871	8731321
346	Áreas húmedas continentales	469033	8731502
347	Áreas húmedas continentales	469601	8731667
348	Áreas húmedas continentales	444657	8748440
349	Áreas húmedas continentales	444203	8748093
350	Áreas húmedas continentales	444184	8749771
351	Áreas húmedas continentales	443664	8750345
352	Áreas húmedas continentales	443192	8750756
353	Áreas húmedas continentales	441394	8749124
354	Áreas húmedas continentales	441966	8746840
355	Áreas húmedas continentales	441935	8746165
356	Áreas húmedas continentales	437876	8755696
357	Áreas húmedas continentales	437973	8755531

Anexo 2. Panel fotográfico.



Foto 1. Bosques y áreas mayormente naturales.



Foto 2. Bosques y áreas mayormente naturales.



Foto 3. Áreas artificializadas.



Foto 4. Áreas artificializadas.



Foto 5. Áreas agrícolas; cultivos permanentes, pastos, y áreas agrícolas heterogéneas.



Foto 6. Áreas agrícolas; cultivos transitorios.



Foto 7. Áreas agrícolas; cultivos permanentes, pastos, y áreas agrícolas heterogéneas.



Foto 8. Áreas agrícolas; pastos.



Foto 9. Áreas húmedas continentales.



Foto 10. Áreas húmedas continentales.



Foto 11. Áreas húmedas continentales.



Foto 12. Áreas húmedas continentales.