

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



TESIS

**“ESCALAS DE SEGMENTACIÓN DE IMÁGENES SENTINEL-2
BASADOS EN DATOS ORIENTADOS A OBJETOS DE LA COBERTURA
DEL SUELO EN EL DISTRITO DE LAS PIEDRAS – MADRE DE DIOS,
PERIODO 2022”**

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

AUTOR:

Bachiller:

RAMOS ALMEIDA, Alejandro Alex

ASESOR:


Dr. Gabriel Alarcón Aguirre

Puerto Maldonado, noviembre de 2023

UNIVERSIDAD NACIONAL AMAZÓNICA DE MADRE DE DIOS

FACULTAD DE INGENIERÍA

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



TESIS

**“ESCALAS DE SEGMENTACIÓN DE IMÁGENES SENTINEL-2
BASADOS EN DATOS ORIENTADOS A OBJETOS DE LA COBERTURA
DEL SUELO EN EL DISTRITO DE LAS PIEDRAS – MADRE DE DIOS,
PERIODO 2022”**

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

AUTOR:

Bachiller:

RAMOS ALMEIDA, Alejandro Alex

ASESOR:

Dr. Gabriel Alarcón Aguirre

Puerto Maldonado, noviembre de 2023

Dedicatoria

La presente tesis está dedicada:

A nuestro Dios, ya que gracias a el he logrado concluir mi carrera.

A mis padres, porque ellos siempre estuvieron a mi lado brindándome su apoyo y sus consejos para hacer de mí una mejor persona.

A mi esposa por sus palabras y confianza, por su amor para realizarme profesionalmente, a mis amigos, compañeros y a todas aquellas personas que de una u otra manera han contribuido para el logro de mis objetivos.

Agradecimientos

Al concluir una etapa maravillosa de mi vida quiero extender un profundo agradecimiento, a quienes hicieron posible este sueño, aquellos que junto a mí caminaron en todo momento y siempre fueron inspiración, apoyo y fortaleza. Esta mención en especial para Dios, mis Padres y mi Esposa.

Terminar este proyecto no hubiera sido posible sin el apoyo profesional de mi Asesor el Dr. Gabriel Alarcón Aguirre, quien con paciencia encausó mi trabajo con sus conocimientos, con el firme propósito de conseguir un producto comunicacional de alto nivel.

Todos en conjunto me hicieron ver, que sin importar cuanto tiempo me tome, todo se puede si de verdad se quiere.

INFORME DE ORIGINALIDAD

18%

INDICE DE SIMILITUD

18%

FUENTES DE INTERNET

8%

PUBLICACIONES

8%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

repositorio.unamad.edu.pe

Fuente de Internet

5%

2

hdl.handle.net

Fuente de Internet

2%

3

acolita.com

Fuente de Internet

1%

4

repositorio.unc.edu.pe

Fuente de Internet

1%

5

Suhail A. Lone, Gh. Jeelani, Abhijit Mukherjee.
"Hydrogeochemical controls on contrasting
co-occurrence of geogenic Arsenic (As) and
Fluoride (F⁻) in complex aquifer system of
Upper Indus Basin, (UIB) western Himalaya",
Environmental Research, 2024

Publicación

1%

6

idoc.pub

Fuente de Internet

1%

7

montblanczone.com

Fuente de Internet

1%

Resumen

El mapeo y monitoreo de la cobertura terrestre es crucial en la Amazonia, y la teledetección se utiliza ampliamente para lograr la tarea. Las imágenes mejoradas de resolución moderada Sentinel-2A (10 m), en lugar de imágenes de satélite comerciales, permiten realizar mapeos con poco o ningún costo. Considerando esto, el objetivo del estudio es determinar la escala de segmentación de imágenes sentinel-2 basados en datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras, Tambopata – Madre de Dios en el periodo 2022

Usando AIBO, se implementó la segmentación mediante el módulo Feature Extraction de ENVI. Se generó una segmentación por nivel de escala (10, 20, 30, 40, 50, 60 y 70) y fusión de 90, considerando datos de forma y compacidad. Los datos S2 proporcionaron una extracción aceptable para las categorías propuestas. Sin embargo, con una precisión general del 79,90% y kappa de 0,756 el nivel de escala 60 y fusión 90 fue la más eficaz a la hora de extraer áreas de clasificación. La homogeneidad espectral por segmentos aumentó la separación entre clases y precisión de la clasificación.

Palabras clave: Objetos, escala, fusión, forma, compacidad, K-Nearest Neighbor.

Abstract

Land cover mapping and monitoring is crucial in the Amazon, and remote sensing is widely used to accomplish the task. Enhanced Sentinel-2A (10 m) moderate resolution imagery, rather than commercial satellite imagery, allows mapping with little or no cost. Considering this, the objective of the study is to determine the scale of segmentation of Sentinel-2 images based on object-oriented data of land cover in the district of Las Piedras, Tambopata - Madre de Dios in the period 2022.

Using AIBO, segmentation was implemented using ENVI's Feature Extraction module. A segmentation was generated by scale level (10, 20, 30, 40, 40, 50, 60 and 70) and fusion of 90, considering shape and compactness data. The S2 data provided an acceptable extraction for the proposed categories. However, with an overall accuracy of 79.90% and kappa of 0.756 the scale level 60 and fusion 90 was the most effective in extracting classification areas. The spectral homogeneity by segments increased the separation between classes and classification accuracy.

Key words: Objects, scale, fusion, shape, compactness, K-Nearest Neighbor.

Índice de contenidos

	Pág.
Dedicatoria.....	i
Agradecimientos	ii
Resumen	iii
Abstract.....	iv
Introducción	1
CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN	8
1.1 Descripción del problema	8
1.2 Formulación del problema	9
1.2.1 Problema general	9
1.2.2 Problemas específicos	9
1.3 Objetivos de la investigación.....	10
1.3.1 Objetivo general	10
1.3.2 Objetivos específicos	10
1.4 Variables de la investigación.....	10
1.4.1 Identificación de variables.....	10
1.5 Operacionalización de variables	11
1.6 Hipótesis	12
1.7 Justificación e importancia	12
1.8 Consideraciones éticas	13
CAPÍTULO II: MARCO TEÓRICO	15
2.1 Antecedentes de estudios.....	15
2.2 Base teórica	19
2.2.1 La Amazonia	19

2.2.2 Cobertura de suelo	19
2.2.3 Sistemas de Información Geográfica (SIG).....	20
2.2.4 Sensoramiento remoto.....	20
2.2.5 Espectro electromagnético.....	21
2.2.6 Teledetección activa y pasiva	24
2.2.7 Plataforma y sensores	25
2.2.8 Escáneres multiespectrales	27
2.2.9 Sistemas de exploración óptica	27
2.2.10 Clasificación de imágenes basado en objetos	27
Segmentación	28
2.2.11 Programa Copérnico	29
Sentinel-2.....	30
Sentinel-2A – Sensor: MSI.....	32
Sentinel-2B – Sensor: MSI.....	33
2.2.11 Software de procesamiento de imágenes	34
SNAP ESA.....	34
ENVI	34
ArcMap	35
2.3 Definición de términos	35
CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN	37
3.1 Tipo de estudio	37
3.2 Diseño del estudio	37
3.3 Delimitación espacial y temporal.....	37
3.3.1 Clima e hidrografía.....	39
3.4 Población y muestra	39
3.5 Método y técnicas	41

3.6 Tratamiento de datos	43
3.6.1 Procesamiento de datos	43
3.6.2 Precisión de datos clasificados	47
3.6.3 Análisis estadístico	48
CAPÍTULO IV: RESULTADOS Y DISCUSIÓN	50
4.1 Parámetros de segmentación de Sentinel-2 orientados a objetos de la cobertura del suelo en el distrito de Las Piedras	50
4.2 Cuantificación de la cobertura del suelo	55
4.3 Evaluación de precisión del método	60
CONCLUSIONES	66
SUGERENCIAS.....	67
REFERENCIAS BIBLIOGRÁFICAS	68
ANEXOS.....	84

Índice de Tablas

	Pág.
Tabla 1. Operacionalización de variables	11
Tabla 2. Características de Sentinel-2	32
Tabla 3. Información de adquisición de imágenes Sentinel-2	44
Tabla 4. Leyenda de cobertura de la tierra adaptada al área de estudio	46
Tabla 5. Valores del coeficiente kappa	48
Tabla 6. Parámetros más importantes utilizados en la segmentación de Sentinel-2.....	54
Tabla 7. Cuantificación de la cobertura del suelo de Sentinel-2 por nivel de escala de segmentación.	59
Tabla 8. Precisión de datos de imágenes Sentinel-2 (escala 10 y fusión 90)	61
Tabla 9. Precisión de datos de imágenes Sentinel-2 (escala 20 y fusión 90)	61
Tabla 10. Precisión de datos de imágenes Sentinel-2 (escala 30 y fusión 90)	62
Tabla 11. Precisión de datos de imágenes Sentinel-2 (escala 40 y fusión 90)	62
Tabla 12. Precisión de datos de imágenes Sentinel-2 (escala 50 y fusión 90)	63
Tabla 13. Precisión de datos de imágenes Sentinel-2 (escala 60 y fusión 90)	63
Tabla 14. Precisión de datos de imágenes Sentinel-2 (escala 70 y fusión 90)	64

Índice de Figuras

	Pág.
<i>Figura 1.</i> Un sensor de detección remota mide la energía reflejada o emitida. Un sensor activo tiene su propia fuente de energía.....	22
<i>Figura 2.</i> Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética.	22
<i>Figura 3.</i> Relación entre longitud de onda, frecuencia y energía.	23
<i>Figura 4.</i> El espectro electromagnético.....	23
<i>Figura 5.</i> Descripción general de los sensores.	25
<i>Figura 6.</i> Ubicación de área de estudio.	38
<i>Figura 7.</i> Distribución de muestras para para medir la precisión de la clasificación.	41
<i>Figura 9.</i> Segmentación de escala 10 y fusión 90.	51
<i>Figura 10.</i> Segmentación de escala 20 y fusión 90.	51
<i>Figura 11.</i> Segmentación de escala 30 y fusión 90.	51
<i>Figura 12.</i> Segmentación de escala 40 y fusión 90.	52
<i>Figura 13.</i> Segmentación de escala 50 y fusión 90.	52
<i>Figura 14.</i> Segmentación de escala 60 y fusión 90.	52
<i>Figura 15.</i> Segmentación de escala 70 y fusión 90.	53
<i>Figura 16.</i> Segmentación de escala 80 y fusión 90.	53
<i>Figura 17.</i> Segmentación de escala 90 y fusión 90.	53
<i>Figura 18.</i> Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 10 y fusión 90.	56
<i>Figura 19.</i> Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 20 y fusión 90.	56
<i>Figura 20.</i> Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 30 y fusión 90.	57

<i>Figura 21.</i> Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 40 y fusión 90.	57
<i>Figura 22.</i> Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 50 y fusión 90.	58
<i>Figura 23.</i> Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 60 y fusión 90.	58
<i>Figura 24.</i> Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 70 y fusión 90.	59

Índice de anexos

	Pág.
Anexo 1. Puntos de muestreo tomados en el área de estudio.....	85
Anexo 2. Panel fotográfico.....	94

Introducción

La pérdida de bosques es un problema ambiental generalizado, especialmente en los trópicos, siendo la deforestación y la degradación los mayores motores de impactos negativos en la diversidad biológica y el bienestar humano, así como la contribución significativa a las emisiones de gases de efecto invernadero (RAISG 2015; Alarcon et al. 2020; INPE 2020a; INPE 2020b; MINAM 2020; RAISG 2020; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022). La Amazonia presenta la extensión de bosque tropical más grande del mundo, sin embargo, han sido impactadas significativamente por la degradación forestal debido a diferentes procesos antropogénicos, como la tala selectiva, los incendios forestales y la fragmentación forestal. Esta situación se refleja en la Amazonia Peruana y en el área de estudio (distrito de Las Piedras) (Giudice et al. 2012; Bax y Francesconi 2018), pero con la particularidad de la presencia de la minería de oro al sur oeste del departamento de Madre de Dios (Asner y Tupayachi 2017; Caballero et al. 2018; Cortés-McPherson 2019; Tarazona y Miyasiro-López 2020).

En este contexto, los productos de teledetección óptica y de radar han sido una fuente clave de información para monitorear los cambios en la cobertura del suelo en las últimas décadas (McNairn et al. 2009; Zhang 2010; Reiche et al. 2015; Nair y Bindhu 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022). Además, estos productos pueden considerarse como la única forma factible de monitorear constantemente los cambios en la cubierta forestal a lo largo del tiempo para grandes regiones geográficas (Rodríguez-Galiano et al. 2012; Reiche et al. 2013; Reiche et al. 2018). Los enfoques más comunes son la clasificación de imágenes no supervisada y supervisada, sin embargo, la clasificación basada en objetos ha ganado más popularidad porque es útil para datos de mediana y alta resolución (Harvey et al. 2002; Jahjah y Ulivieri 2010; Yu et al. 2020; Zhang et al. 2020; Zhao et al. 2020; Fu et al. 2021; Đideliija et al. 2022; Mokhtar et al. 2022). Mientras que la clasificación supervisada y no supervisada se basa en píxeles, la basada en objetos agrupa los píxeles en formas vectoriales representativas con tamaño y geometría (Lian y Chen 2011; Đideliija et al. 2022). El Análisis de imágenes basados en

objetos (AIBO) segmenta una imagen agrupando píxeles, generando objetos con diferentes geometrías porque la extracción orientada a objetos es la condición previa para la segmentación multiescala y la elección óptima de la escala (Jahjah y Ulivieri 2010; Khatriker y Kumar 2018; Labib y Harris 2018; Yu et al. 2020; Mokhtar et al. 2022).

La clasificación basada en píxeles es adecuada para imágenes de detección remota de baja resolución con información espectral rica, pero para imágenes de detección remota de mediana y alta resolución, existen algunas dificultades: (i) la heterogeneidad espectral entre características similares aumenta con la resolución espacial mejorada, por lo que es difícil distinguir las características de la superficie con diferentes propiedades espectrales; por otro lado, la heterogeneidad espectral de las diferentes características se reduce y es difícil distinguir las características de la cubierta, (ii) hay una gran cantidad de datos en imágenes de detección remota de mediana y alta resolución, por lo que los métodos tradicionales no pueden cumplir con los requisitos de extracción rápida (Yu et al. 2020; Zhang et al. 2020; Zhao et al. 2020; Fu et al. 2021; Đideliija et al. 2022; Mokhtar et al. 2022); “cuanto mayor sea la resolución espacial, mayor será la capacidad de identificar objetos” (Lian y Chen 2011, p. 353). Adicionalmente, la identificación de objetos no solo debe considerar el valor específico de la resolución espacial, sino también la forma, tamaño y diferencias relativas en el brillo y la estructura de los objetos circundante (Lian y Chen 2011; Đideliija et al. 2022; Mokhtar et al. 2022). El concepto de escala en el análisis orientado a objetos ya no es el tamaño del píxel, sino el segmento de escala de la imagen y el umbral mínimo de la heterogeneidad de los objetos de la imagen (Harvey et al. 2002; Jahjah y Ulivieri 2010; Lian y Chen 2011; Mokhtar et al. 2022).

Mediante el método orientado a objetos con el software ENVI 5.3 (módulo Feature Extraction), analizará las características de la cobertura del distrito de Las Piedras con una resolución espacial de 10 m y una escala de segmentación óptima en la clasificación de imágenes de sensor Sentinel-2 (Khatriker y Kumar 2018; Yu et al. 2020; Fu et al. 2021; Mokhtar et al. 2022), siendo el criterio "homogeneidad dentro del objeto, heterogeneidad entre

objetos" (Lian y Chen 2011, p. 353), con la finalidad de determinar la mejor escala de segmentación.

Con este estudio, nuestro objetivo fue evaluar la escala de segmentación de imágenes sentinel-2 basados en datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras, Tambopata – Madre de Dios en el periodo 2022, con la finalidad de determinar los parámetros óptimos en el monitoreo de la Amazonia.

CAPÍTULO I: PROBLEMA DE INVESTIGACIÓN

1.1 Descripción del problema

La Amazonia posee los bosques más grandes de los trópicos (Tarazona y Miyasiro-López 2020). Los bosques Amazónicos contribuyen significativamente a los beneficios socioeconómicos, como el suministro de madera, productos diferentes a la madera, territorio de pueblos indígenas, refugio de la fauna silvestre y servicios ambientales, siendo primordial su conservación y manejo sustentable (Perz et al. 2016; Alarcon et al. 2020; Alarcon-Aguirre et al. 2021). En este escenario, los datos de teledetección se han utilizado comúnmente para el monitoreo de la Amazonia. La investigación en la clasificación de imágenes para el análisis de árboles urbanos y el mapeo de la extensión de los manglares se llevó a cabo en trabajos anteriores utilizando imágenes satelitales (Capers et al. 2005; Andersen et al. 2017; Cabral et al. 2018; Alarcon-Aguirre et al. 2021). Muchas imágenes de satélite se han utilizado en el monitoreo de la Amazonia, como Landsat Thematic Mapper (TM), Enhanced Thematic Mapper (ETM +), Landsat-8 Operational Land Imager (OLI), imágenes SPOT y, actualmente Sentinel-2 con una resolución espacial que varía de 2,5 a 60 m (Williams et al. 2006; Roy et al. 2014; Chatziantoniou et al. 2017; Chirif 2018). A pesar de las potencialidades de los sensores de teledetección es bastante desafiante debido a cobertura y sombra de nubes, especialmente cuando el enfoque de clasificación está basado en píxeles (Fernández y Rincón 2020). Por lo tanto, la segmentación multiescala para el análisis de imágenes basado en objetos (AIBO) se ha utilizado para extraer un objeto de las imágenes satelitales para diferenciar los tipos de cobertura terrestre (Jahjah y Ulivieri 2010; Faraj y Mahmood 2018; Labib y Harris 2018; Foody 2020; Yu et al. 2020; Zhang et al. 2020; Zhao et al. 2020; Fu et al. 2021; Đideliija et al. 2022; Mokhtar et al. 2022). Sin embargo,

los estudios centrados en probar los parámetros de segmentación en base a nivel de escala y fusión para extraer las características de acción antrópica sobre los bosques aún son limitados (Jahjah y Ulivieri 2010; Faraj y Mahmood 2018; Labib y Harris 2018; Foody 2020; Yu et al. 2020; Zhang et al. 2020; Zhao et al. 2020; Fu et al. 2021; Đideliija et al. 2022; Mokhtar et al. 2022). En ese sentido, el estudio propone determinar el valor de los parámetros de segmentación apropiados, basado en el nivel de escala y fusión con el módulo Extracción de Características (Feature Extraction) del software ENVI 5,3® según el enfoque AIBO (Harvey et al. 2002).

1.2 Formulación del problema

1.2.1 Problema general

¿Cuál será la escala apropiada de segmentación de imágenes sentinel-2 basados en datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras, Tambopata – Madre de Dios en el periodo 2022?

1.2.2 Problemas específicos

P.E.1 ¿Cuál será el parámetro óptimo de segmentación de imágenes Sentinel-2 bajo un criterio de nivel de escala y fusión mediante datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras?

P.E.2 ¿Cuál y cuanto será la cobertura del suelo mediante datos orientados a objetos del distrito de Las Piedras?

P.E.3 ¿Cuál es la precisión del método de escala de segmentación de imágenes sentinel-2 basados en datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras?

1.3 Objetivos de la investigación

1.3.1 Objetivo general

Determinar la escala de segmentación de imágenes sentinel-2 basados en datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras, Tambopata – Madre de Dios en el periodo 2022.

1.3.2 Objetivos específicos

O.E.1 Determinar los parámetros óptimos de segmentación de imágenes Sentinel-2 bajo un criterio de nivel de escala y fusión mediante datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras.

O.E.2 Cuantificar la cobertura del suelo mediante datos orientados a objetos del distrito de Las Piedras.

O.E.3 Analizar la precisión del método de escala de segmentación de imágenes sentinel-2 basados en datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras.

1.4 Variables de la investigación

1.4.1 Identificación de variables

Variable Dependiente

- ✓ Reflexión de la cobertura del suelo en datos orientados a objetos de imágenes Sentinel-2.

Variable Independiente

- ✓ Dinámica de la cobertura del suelo en base a segmentos orientados a objetos, periodo 2022.

1.5 Operacionalización de variables

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

Tabla 1. *Operacionalización de variables*

Definición conceptual	Definición operacional	Dimensión	Indicadores	Ítems
Variable independiente				
Analizar los parámetros de segmentación de imágenes Sentinel-2 bajo un criterio de nivel de escala y fusión permite obtener valores ópticos de clasificación mediante datos orientados a objetos.	Determinar los parámetros óptimos de segmentación de imágenes Sentinel-2 bajo un criterio de nivel de escala y fusión mediante datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras.	Parámetros óptimos de segmentación de imágenes Sentinel-2 bajo un criterio de nivel de escala y fusión.	Parámetros de segmentación de imágenes Sentinel-2 bajo un criterio de nivel de escala y fusión.	P.E.1 (Fu et al. 2021; Đideliija et al. 2022)
Analizar la cobertura del suelo mediante datos orientados a objetos permite clasificar y cuantificar la superficie en diferentes escalas.	Cuantificar la cobertura del suelo mediante datos orientados a objetos del distrito de Las Piedras en el periodo 2022.	Dinámica de la cobertura del suelo bajo un criterio de nivel de escala y fusión mediante datos orientados a objetos.	Superficie total (ha).	P.E.2 (Ruiz et al. 2011; Khatriker y Kumar 2018; Qi et al. 2021; Mokhtar et al. 2022)
		Nivel de precisión de resultados mediante la matriz de confusión y Kappa.	Matriz de confusión e índice de Kappa.	P.E. 3 (Cohen 1960; Cohen et al. 2003)
Variable dependiente				
Comportamiento de la Reflexión de la cobertura del suelo en datos orientados a objetos de imágenes Seninel-2.	Firmas espectrales de la reflexión de la cobertura del suelo en base a datos orientados a objetos en imágenes Seninel-2.	Rango espectral de datos orientados en objetos.	Unidades de segmentación basados en nivel de escala y fusión.	P.E.1, 2, 3, 4 (Harvey et al. 2002; Blaschke et al. 2014)

1.6 Hipótesis

Hipótesis nula (H_0): El análisis de la cobertura del suelo mediante imágenes Sentinel-2 orientado a objeto con un menor nivel de escala y mayor nivel de fusión, no genera resultados idóneos durante el proceso de clasificación.

Hipótesis alterna (H_1): El análisis de la cobertura del suelo mediante imágenes Sentinel-2 orientado a objeto con un menor nivel de escala y mayor nivel de fusión, genera resultados idóneos durante el proceso de clasificación.

1.7 Justificación e importancia

La dinámica de la cobertura del suelo en la Amazonia se ha plasmado en la desaparición de masas boscosas y fuentes de agua en las últimas décadas (Labib y Harris 2018; Alarcon et al. 2020; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022). La pérdida de bosques es una gran amenaza para las condiciones de vida de la poblaciones rurales, comunidades indígenas y externalidades negativas para las zonas urbanas (Labib y Harris 2018; Alarcon et al. 2020; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022). Monitorear la pérdida de bosques en la Amazonia se ha convertido en un desafío ampliamente investigada debido al impacto masivo que puede tener en el medio ambiente, la ecología, la salud y el bienestar de las poblaciones (Paul 2014; Labib y Harris 2018; Piontekowski et al. 2019; Islam y Amin 2020; Tarazona y Miyasiro-López 2020). En tal situación, las imágenes ópticas han sido de gran ayuda, desarrollándose investigaciones de manera extensiva en métodos basados en píxeles (supervisado, no supervisado e híbrido) (INPE 2020b; INPE 2020a; López et al. 2020; MINAM 2020; RAISG 2020). Sin embargo, análisis de imágenes basado en objetos (AIBO) utilizando niveles de escala aún falta una mayor exploración (Khatriker y Kumar 2018; Labib y Harris 2018; Yu et al. 2020; Fu et al. 2021; Mokhtar et al. 2022).

A través del tiempo, la variación en la resolución espacial entre las imágenes satelitales comerciales y las imágenes satelitales de libre acceso eran

contrastantes. Con el lanzamiento de los programas Sentinel-2 (S2) y Landsat-8 (L8) se han mejorado la resolución espacial de las imágenes de satélite de acceso libre, ello brinda la oportunidad de monitorear y cartografiar con mayor precisión la cobertura del suelo (Roteta et al. 2019; Roy et al. 2019; Niro et al. 2021). Sentinel-2 proporciona una resolución de 10 m para bandas visibles e infrarrojas cercanas (NIR) y más alejadas de 20 m y 60 m (Labib y Harris 2018; Niro et al. 2021).

La selección del método AIBO fue considerado cuidadosamente sobre el método tradicional basado en píxeles. Si bien AIBO es relativamente reciente en la práctica, y el método ya propuso varias ventajas sobre los métodos basados en píxeles; tales como, consideración de autocorrelación espacial, clase de imagen mejorada, consideración contextual, integración de datos auxiliares en el proceso (Labib y Harris 2018). AIBO se está volviendo cada vez más popular entre la comunidad científica y, en combinación con varios métodos de clasificación de alto nivel, como el bosque aleatorio (RF), la clasificación basada en reglas (SVM) (Zhao et al. 2020).

La idea básica de esta investigación fue agregar evidencia en el conocimiento con respecto a la efectividad del método de segmentación basado en nivel de escala y fusión en imágenes Sentinel-2 (Labib y Harris 2018). Para el desarrollo favorable de la investigación, se contará el asesoramiento especializado del personal del Centro de Teledetección para el Estudio y Gestión de los Recursos Naturales (CETEGERN).

1.8 Consideraciones éticas

“La investigación utilizará criterios metodológicos sobre procesamiento de imágenes Sentinel-2 basado en objetos, para ello se empleará los softwares SNAP ESA de plataforma abierta, así como el ENVI 5,3®, ArcGIS Pro 2,9®, ArcGIS 10,8® del CETEGERN”.

A nivel de política institucional, “la investigación cumple con la política marco de la Comisión Nacional de Investigación y Desarrollo Aeroespacial (CONIDA), creada por Decreto Ley N.º 20643”.

La validación mediante trabajos de campo para medir la precisión de la investigación, se cumplirá con todos los protocolos de seguridad del tesista y personal de apoyo de ser necesario.

CAPÍTULO II: MARCO TEÓRICO

2.1 Antecedentes de estudios

Đideliija et al. (2022) estudiaron la influencia del parámetro de escala de segmentación en la precisión de detección de vertederos ilegales en imágenes de satélite. Analizaron la relación entre la segmentación en base al parámetro de escala y la precisión de detección de vertederos ilegales en áreas urbanas que no están cubiertas por vegetación o enterradas en el suelo. La investigación mostró que existe un valor de parámetro de escala óptimo ($SP = 20$) para la imagen de satélite utilizada Pléiades 1B y el área de interés (municipio de Novo Sarajevo). El valor establecido del parámetro de escala proporciona valores Kappa máximos y coeficientes de precisión general para vertederos ilegales detectados en la imagen de satélite.

Mokhtar et al. (2022) delimitaron el área de manglares usando clasificación basada en objetos en imágenes Sentinel-2: Isla Tuba, Langkawi. La clasificación errónea de píxeles es un problema común cuando las imágenes satelitales extraen clases de uso y cobertura de la tierra. Plantearon como objetivo i) identificar el valor de los parámetros de segmentación adecuados para delinear el área de manglares y ii) clasificar los árboles de manglares jóvenes y maduros utilizando el enfoque de clasificación basada en objetos (AIBO). Esta investigación aplicó la máquina de vectores de soporte (SVM) basada en un método basado en objetos que utiliza la imagen Sentinel-2A y se probaron los valores de los parámetros de segmentación de escala, compacidad, forma y matriz de co-ocurrencia de nivel de gris (GLCM). El diámetro del árbol medido a la altura del pecho (DAP) se usó para verificar el árbol de mangle delineado en la imagen Sentinel-2A. La configuración de los parámetros de segmentación de forma (0,2), compacidad (0,2) y escala (50)

muestra errores mínimos con la delimitación del manglar del 9,279 % en comparación con los datos de Global Forest Watch (GFW), mientras que la media GLCM es apropiada para determinar el manglar joven y maduro. El hallazgo de este estudio ayudo al Departamento de Pesca de Malasia y al agroturismo a mantener el ecosistema de manglares y mejorar la industria pesquera.

Qi et al. (2021) monitorearon el contenido de clorofila de las hojas de maní basado en la extracción de características de imágenes multiespectrales basadas en drones. El contenido de clorofila de las hojas de maní Yanghua 1 fue generalmente más alto que el de Yueyou 45, y la densidad de plantas tuvo una mayor influencia en el maní Yanghua 1. Los modelos de regresión lineal unidimensional de NDVI (Índice de vegetación de diferencia normalizada) y GNDVI (Índice de vegetación de diferencia normalizada verde) tuvieron un grado de ajuste y precisión mucho mayor que los otros índices; y el modelo de regresión lineal múltiple tuvo una capacidad predictiva más precisa que el modelo de regresión lineal unidimensional. Después de la prueba, la red neuronal BP (red neuronal de retro propagación) fue el modelo más adecuado para monitorear el contenido de clorofila del maní con mejor ajuste y precisión que el modelo de bosque aleatorio. El dron multiespectral podría confiar en el modelo predictivo de alta precisión para obtener rápidamente información sobre el contenido de clorofila en el campo e inferir el tipo de cultivo y la densidad de plantación más adecuados para la plantación local.

Fernández y Rincón (2020) segmentaron y clasificaron imágenes satelitales para determinar la cobertura del suelo. Aplicaron el análisis de imágenes basados en objetos de la imagen SPOT de la cuenca Santiváñez (Cochabamba-Bolivia), para ello utilizaron el módulo Feature Extraction de ENVI EX mediante 72 segmentaciones, considerando el criterio de nivel de escala y fusión cada 10 unidades. En las segmentaciones se evaluaron la varianza y la autocorrelación I de Moran, obteniéndose los parámetros óptimos para la segmentación fueron; para una escala de 20 y una fusión de 50. Las áreas de entrenamiento de segmentos se hicieron para 6 clases en base a una clasificación con criterios espectrales y texturales. La precisión se

realizó con imágenes y puntos de campo con GPS. La matriz arrojó valores de precisión global de 94,61% y Kappa de 0,92.

Van doninck et al. (2020) estudiaron la datación de los ciclos de floración de los bosques amazónicos dominados por el bambú mediante la segmentación supervisada de series temporales de Landsat en el sudoeste de la Amazonía, cubriendo áreas de la triple frontera (Madre de Dios-Perú, Acre-Brasil, y Pando-Bolivia). Para ello, plantearon un enfoque de segmentación de series de tiempo supervisado que permitieron identificar tanto la presencia de bosques de bambú como los años en los que se produjo la floración y posterior mortalidad del bambú. Aplicaron datos Landsat TM/ETM+ desde 1984 hasta finales de 2018 y validaron la clasificación mediante interpretación visual de imágenes de muy alta resolución. Los resultados muestran que los bosques de bambú se pueden diferenciar de los bosques que no son de bambú usando cualquiera de las bandas infrarrojas, pero la banda 5 produce la mayor precisión de clasificación.

Garnica (2019) evaluó la segmentación de imágenes de satélite en el estudio de bosques húmedos tropicales de la Reserva Nacional Tambopata, Madre de Dios. Para ello, generaron cartografía de bosques de datos Landsat segmentadas y sin segmentar. La escala de trabajo fue de 1:100 000 y concluyeron, que la segmentación de imágenes Landsat permite obtener mapas de bosques con mayor exactitud que los procesos estándar de clasificación digital.

Khatriker y Kumar (2018) extrajeron la huella de un edificio a partir de imágenes de satélite de alta resolución utilizando segmentación. Para la extracción de edificios, especialmente de imágenes de alta resolución. El estudio, planteo dos técnicas de segmentación de imágenes semiautomáticas para la extracción de edificios a partir de imágenes de alta resolución mediante algoritmos: segmentación de resolución múltiple y extracción de características basada en reglas, que se aplican en imágenes de Worldview 2 (2010) del área de Dehradun. La imagen segmentada se clasificó aún más para extraer edificios de las características de la imagen segmentada. El estudio identificó la utilidad de ambos métodos en la extracción de edificios y

encuentra el conjunto óptimo de reglas para extraer edificios de conjuntos de datos de alta resolución. La tasa de verdaderos positivos con la extracción de características basada en reglas es del 88,11 % en comparación con el 85,46 % del algoritmo de segmentación de resolución múltiple. La tasa de falsos negativos (FNR) del algoritmo de segmentación de resolución múltiple (16,5 %) es muy inferior en comparación con la extracción de características basada en reglas (67,5 %).

Labib y Harris (2018) evaluaron el potencial de los datos de Sentinel-2 y Landsat-8 en la extracción de infraestructura verde, utilizando el método de análisis de imágenes basado en objetos. Usando AIBO, implementaron la segmentación de abajo hacia arriba (es decir, multiresolución) y de arriba hacia abajo (es decir, diferencia espectral) usando eCognition para obtener objetos de imagen para imágenes S2 y L8. Después, Se realizó una clasificación basada en reglas para extraer áreas de interés de los objetos. Las relaciones NDVI, NDWI, NIR/R se utilizaron en el desarrollo del conjunto de reglas, después de varios procesos de prueba y error. Tanto S2 como L8 proporcionaron una extracción aceptable de los objetos para áreas urbanas. Sin embargo, con una precisión general del 71,24 %, S2 fue más efectivo al extraer áreas urbanas. Las sombras a lo largo de las carreteras y los edificios de gran altura provocaron cierta inexactitud en la clasificación.

Lian y Chen (2011) investigaron sobre la escala de segmentación de datos de teledetección de múltiples recursos basados en datos orientados a objetos en el Mega Centro de Educación Superior de Guangzhou como área de prueba para la extracción de características superficiales. Los edificios, carreteras, aguas y vegetación se extrajeron de 4 imágenes de diferente resolución utilizando diferentes escalas. Se determinó que la escala de segmentación óptima seleccionada en base a la desviación estándar de las medias y la media de las desviaciones estándar del brillo de los objetos de la imagen es casi consistente con la escala de segmentación óptima seleccionada en base a la clasificación real. La precisión de la clasificación está relacionada con la resolución espacial. La mejor precisión de clasificación se obtuvo con la escala 20-50, además, la precisión de la clasificación disminuye desde SPOT

(2,5m), SPOT (10m) hasta ASTER (15m), lo que mostro que la precisión de la clasificación está relacionada con la resolución espacial. En general, cuanto mayor es la resolución, mejor será la segmentación, pero no la precisión de la clasificación. Pero para aplicaciones específicas, una resolución más alta definitivamente no obtiene una mejor precisión de clasificación.

Jahjah y Ulivieri (2010) realizaron la extracción automática de características arqueológicas a partir de imágenes satelitales VHR en Turkmenistán (Nisa) y en Irak (Babilonia). Utilizaron dos técnicas de extracción de características, eCognition y el SW del módulo ENVI, para comparar los resultados. Los resultados fueron de diferentes salidas, teniendo en cuenta que la escala operativa de los datos censados determina el resultado final de la elaboración y la salida de la calidad de la información, ya que cada uno de ellos fue sensible a formas específicas en cada imagen de entrada. Finalmente, ambos métodos dotaron de nuevos instrumentos para la orientación y la planificación de una aplicación de teledetección, siendo el más sensible el módulo de ENVI.

2.2 Base teórica

2.2.1 La Amazonia

La Amazonia es la selva tropical más grande del mundo. A partir de 2020, se registra 526 millones de hectáreas de bosque primario, lo que representa casi el 84 % de los 629 millones de hectáreas de cobertura arbórea total de la región. La cuenca, cubre alrededor del 40 por ciento del continente sudamericano e incluye partes de ocho países sudamericanos: Brasil, Bolivia, Ecuador, Colombia, Venezuela, Guayana y Surinam, así como la Guayana Francesa (RAISG 2022).

2.2.2 Cobertura de suelo

La cobertura del suelo se refiere a la cobertura superficial del suelo, ya sea vegetación, infraestructura urbana, agua, suelo desnudo u otros. Identificar, delinear y mapear la cobertura terrestre es importante para los estudios de monitoreo global, la gestión de recursos y las actividades de planificación. La

identificación de la cobertura del suelo establece la línea de base a partir de la cual se pueden realizar las actividades de monitoreo (detección de cambios) y proporciona la información de la cobertura del suelo para los mapas temáticos de línea de base (Turner et al. 1995; Naikoo et al. 2022).

2.2.3 Sistemas de Información Geográfica (SIG)

Los Sistemas de Información Geográfica, o GIS, son herramientas informáticas y de software para recopilar y analizar datos relacionados con ubicaciones geográficas y su relación con la actividad humana o natural en la Tierra. Los datos GIS se pueden utilizar para recopilar y analizar datos sobre la superficie de la tierra y para crear mapas en capas, gráficos y modelos 3D de características geográficas, como montañas, ríos, bosques, calles o edificios. Las industrias y los gobiernos usan herramientas GIS para comprender mejor todo, desde la planificación urbana hasta el cambio climático (Wieczorek y Delmerico 2009; Jiang 2020).

Un sistema GIS utiliza computadoras y software para recopilar, administrar y analizar datos en función de la geografía y visualiza los datos en un mapa. El software de mapeo GIS utiliza datos espaciales para crear mapas y modelos 3D a partir de capas de información visual, revelando patrones y relaciones en los datos GIS. Muchas industrias y agencias gubernamentales de análisis de datos que usan GIS para comunicar mejor información compleja y resolver problemas asociados con ubicaciones geográficas.(Wieczorek y Delmerico 2009; Jiang 2020).

2.2.4 Sensoramiento remoto

La teledetección es la ciencia de adquirir información sobre un objeto o fenómeno midiendo la radiación emitida y reflejada. Hay dos tipos principales de instrumentos de teledetección: activos y pasivos (Kerle et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

La teledetección es un tipo de tecnología geoespacial que muestrea la radiación electromagnética (EM) emitida y reflejada de los ecosistemas

terrestres, atmosféricos y acuáticos de la Tierra para detectar y monitorear las características físicas de un área sin hacer contacto físico. Este método de recopilación de datos generalmente involucra tecnologías de sensores basadas en aeronaves y satélites, que se clasifican como sensores pasivos o sensores activos (Kerle et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

Los sensores pasivos responden a estímulos externos, recolectando la radiación reflejada o emitida por un objeto o el espacio circundante. La fuente más común de radiación medida por sensores remotos pasivos es la luz solar reflejada. Los ejemplos populares de sensores remotos pasivos incluyen dispositivos de carga acoplada, fotografía de películas, radiómetros e infrarrojos. Los sensores activos utilizan estímulos internos para recopilar datos, emitiendo energía para escanear objetos y áreas, luego de lo cual un sensor mide la energía reflejada desde el objetivo. RADAR y LiDAR son herramientas típicas de detección remota activa que miden el tiempo de retraso entre la emisión y el retorno para establecer la ubicación, dirección y velocidad de un objeto. Los datos de detección remota recopilados luego se procesan y analizan con hardware y software de detección remota (por ejemplo, análisis de energía e inteligencia comercial de energía), que está disponible en una variedad de aplicaciones patentadas y de código abierto (Kerle et al. 2004; Jensen 2009; Baghdadi y Zribi 2016).

2.2.5 Espectro electromagnético

El espectro electromagnético es un rango de frecuencias, longitudes de onda y energías de fotones que cubre frecuencias desde menos de 1 hercio hasta más de 10^{25} Hz correspondientes a longitudes de onda que son de unos pocos kilómetros a una fracción del tamaño de un núcleo atómico en el espectro de ondas electromagnéticas. Generalmente, en el vacío, las ondas electromagnéticas tienden a viajar a velocidades similares a las de la luz. Sin embargo, lo hacen en una amplia gama de longitudes de onda, frecuencias y energías de fotones. El espectro electromagnético consiste en un tramo de toda la radiación electromagnética que además contiene muchos subrangos que comúnmente se denominan porciones. Estos pueden clasificarse además

como radiación infrarroja, luz visible o radiación ultravioleta (Kerle et al. 2004; Jensen 2009).

Todo el rango (espectro electromagnético) está dado por ondas de radio, microondas, radiación infrarroja, luz visible, radiación ultravioleta, rayos X, rayos gamma y rayos cósmicos en orden creciente de frecuencia y decreciente de longitud de onda (Kerle, et al. 2004).




Figura 1. Un sensor de detección remota mide la energía reflejada o emitida. Un sensor activo tiene su propia fuente de energía.

Fuente: Kerle et al. (2004).




Figura 2. Vectores eléctricos (E) y magnéticos (M) de una onda electromagnética.

Fuente: Kerle et al. (2004)

Las ondas electromagnéticas en estas diferentes bandas tienen diferentes características dependiendo de cómo se producen, cómo interactúan con la materia y sus aplicaciones prácticas. Las ecuaciones de Maxwell predijeron la existencia de un número infinito de frecuencias de ondas electromagnéticas, todas viajando a la velocidad de la luz. Esta es la primera indicación de la existencia de todo el espectro electromagnético (Kerle et al. 2004; Jensen 2009).

No obstante, la principal importancia del espectro electromagnético es que se puede utilizar para clasificar las ondas electromagnéticas y ordenarlas según sus diferentes frecuencias o longitudes de onda (Kerle et al. 2004; Jensen 2009).




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

Fuente: Kerle et al. (2004).




Figura 4. El espectro electromagnético.

Fuente: Kerle et al. (2004).

2.2.6 Teledetección activa y pasiva

Hasta ahora, a lo largo de este capítulo, hemos hecho varias referencias al sol como fuente de energía o radiación. El sol proporciona una fuente de energía muy conveniente para la teledetección. La energía del sol se refleja, como ocurre con las longitudes de onda visibles, o se absorbe y luego se vuelve a emitir, como ocurre con las longitudes de onda del infrarrojo térmico. Los sistemas de detección remota que miden la energía que está naturalmente disponible se denominan sensores pasivos. Los sensores pasivos solo se pueden usar para detectar energía cuando la energía natural está disponible. Para toda la energía reflejada, esto solo puede tener lugar durante el tiempo en que el sol está iluminando la Tierra. No hay energía reflejada disponible del sol durante la noche. La energía que se emite naturalmente (como el infrarrojo térmico) se puede detectar de día o de noche, siempre que la cantidad de energía sea lo suficientemente grande como para registrarla (Kerle et al. 2004; Jensen 2009). Los sensores activos, por otro lado, proporcionan su propia fuente de energía para la iluminación. El sensor emite radiación que se dirige hacia el objetivo a investigar. La radiación reflejada por ese objetivo es detectada y medida por el sensor. Las ventajas de los sensores activos incluyen la capacidad de obtener mediciones en cualquier momento, independientemente de la hora del día o la estación. Los sensores activos se pueden usar para examinar longitudes de onda que el sol no proporciona lo suficiente, como las microondas, o para controlar mejor la forma en que se ilumina un objetivo. Sin embargo, los sistemas activos requieren la generación de una cantidad bastante grande de energía para iluminar adecuadamente los objetivos. Algunos ejemplos de sensores activos son un fluorosensor láser y un radar de apertura sintética (SAR) (Kerle et al. 2004; Jensen 2009).




Figura 5. Descripción general de los sensores.

Fuente: Kerle et al. (2004).

2.2.7 Plataforma y sensores

Usando la definición más amplia de detección remota, existen innumerables tipos de plataformas sobre las cuales implementar un instrumento. La discusión en este curso se limitará a las plataformas y sensores comerciales que se usan más comúnmente en las aplicaciones SIG y de mapeo. Los satélites y las aeronaves recopilan la mayoría de los datos e imágenes del mapa base que se utilizan en SIG; los sensores típicamente desplegados en estas plataformas incluyen cámaras de película y digitales, sistemas de detección de luz y alcance (lidar), sistemas de radar de apertura sintética (SAR), escáneres multiespectrales e hiperspectrales. Muchos de estos instrumentos también se pueden montar en plataformas terrestres, como camionetas, camiones, tractores y tanques. En el futuro, es probable que un porcentaje significativo de SIG y datos cartográficos se originen en fuentes terrestres; sin embargo, debido a limitaciones de tiempo (Kerle et al. 2004; Jensen 2009).

Desde el lanzamiento del primer Landsat en 1972, la cartografía y la detección remota por satélite se han convertido en una industria comercial

internacional. Curiosamente, incluso a medida que se lanzan más satélites, la demanda de datos adquiridos de plataformas aéreas sigue creciendo. El profesional de inteligencia geoespacial bien versado debería poder analizar las ventajas y desventajas de cada tipo de plataforma. Si bien la cantidad de plataformas satelitales es bastante baja en comparación con la cantidad de plataformas aerotransportadas, las capacidades ópticas de los sensores de imágenes satelitales se acercan a las de las cámaras digitales aerotransportadas. Sin embargo, siempre habrá diferencias importantes, estrictamente relacionadas con las características de la plataforma, en la efectividad de los satélites y aeronaves para adquirir datos de teledetección (Kerle et al. 2004; Jensen 2009).

Una ventaja obvia que tienen los satélites sobre los aviones es la accesibilidad global; Existen numerosas restricciones gubernamentales que niegan el acceso al espacio aéreo sobre áreas sensibles o sobre países extranjeros. Las órbitas de los satélites no están sujetas a estas restricciones, aunque es posible que existan acuerdos legales para limitar la distribución de imágenes en áreas particulares (Kerle et al. 2004; Jensen 2009).

El diseño de un sensor destinado a una plataforma satelital comienza muchos años antes del lanzamiento y no se puede cambiar fácilmente para reflejar los avances tecnológicos que pueden evolucionar durante el período intermedio. Si bien todos los sistemas se prueban rigurosamente antes del lanzamiento, siempre existe la posibilidad de que uno o más fallen después de que la nave espacial alcance la órbita. El sensor podría estar funcionando perfectamente, pero un componente del bus de la nave espacial (sistema de determinación de actitud, subsistema de energía, sistema de control de temperatura o sistema de comunicaciones) podría fallar, lo que haría que un sensor muy costoso fuera efectivamente inútil. El riesgo financiero involucrado en la construcción y operación de un sensor y una plataforma de satélite es considerable, lo que presenta un obstáculo importante para la comercialización de la teledetección basada en el espacio (Kerle et al. 2004; Jensen 2009).

2.2.8 Escáneres multiespectrales

Un término de teledetección que se refiere a un radiómetro de barrido que adquiere simultáneamente imágenes en varias bandas de onda al mismo tiempo. Un escáner multiespectral se puede llevar a bordo de un avión o satélite. El escáner multiespectral Landsat registra imágenes en cuatro bandas de radiación electromagnética visible e infrarroja cercana para permitir distinguir objetos con diferentes propiedades de reflectancia. (Sabins Jr 1987; Oppenheimer 1998; Kerle et al. 2004; Jensen 2009).

2.2.9 Sistemas de exploración óptica

Un escáner mecánico óptico es un radiómetro multiespectral mediante el cual se pueden registrar imágenes bidimensionales mediante una combinación del movimiento de la plataforma y un espejo giratorio u oscilante que escanea perpendicularmente a la dirección del vuelo. Los escáneres mecánicos ópticos se componen de un sistema óptico, un sistema espectrográfico, un sistema de escaneo, un sistema detector y un sistema de referencia (Kerle et al. 2004; Jensen 2009).

La misión Sentinel-2A de la Agencia Espacial Europea con el Instrumento Multiespectral (MSI) a bordo se lanzó en 2015, iniciando una nueva era en imágenes de resolución alta a moderada (es decir, de 10 a 60 m) de los recursos de la Tierra. Este manuscrito describe las implementaciones del procesamiento MSI en el Sistema de análisis de datos SeaWiFS (SeaDAS) y proporciona análisis cualitativos y cuantitativos de productos de reflectancia de detección remota (R_{rs}), que son esenciales en la recuperación de concentraciones cercanas a la superficie de componentes del agua en sistemas acuáticos (Fernández-Manso et al. 2016).

2.2.10 Clasificación de imágenes basado en objetos

La imagen de detección remota es una de las herramientas más esenciales para acceder a las características de la superficie de la Tierra. Se pueden estudiar muchas actividades, como el desarrollo de áreas suburbanas o la

cubierta vegetal en el área seleccionada a partir de las imágenes de satélite. El uso de la tecnología de imágenes satelitales se ha aplicado en muchos campos de aplicación para monitorear el uso y la cobertura de la tierra. Además, las imágenes satelitales son capaces de estimar la cobertura agrícola en una región. La separación de las características de una imagen conduce a la complejidad debido a la dificultad de encontrar la técnica adecuada para la segmentación de imágenes. Este artículo propone técnicas para clasificar objetos en la imagen de sensores remotos utilizando varios métodos de procesamiento de imágenes. Estos son los pasos principales que se apoyan entre sí, método de preprocesamiento: Mejora de imagen mediante ecualización de histograma e histograma adaptativo y segmentación de imagen mediante umbralización y canal RGB. El algoritmo puede detectar el área de vegetación, cuerpos de agua, concreto y caminos. Los métodos de segmentación de imágenes pueden detectar la región de interés. El resultado final nos ayuda a clasificar los objetos en la imagen de satélite (Zhao et al. 2020).

Segmentación

Las imágenes con una resolución espacial alta y muy alta muestran niveles más altos de características detalladas, los algoritmos tradicionales de procesamiento de imágenes basados en el análisis de un solo píxel a menudo no son capaces de extraer toda su información. Para solucionar esta limitación, en los últimos años se han propuesto enfoques de análisis de imágenes basados en objetos (AIBO). Uno de los pasos más importantes en el enfoque AIBO es el proceso de segmentación; cuyo objetivo es agrupar los píxeles vecinos según unos criterios de homogeneidad. Diferentes segmentaciones permitirán extraer diferente información de una misma imagen en múltiples escalas. Así, el gran desafío es determinar la segmentación a escala adecuada que permita caracterizar diferentes objetos o fenómenos, en una sola imagen (Xiong et al. 2019).

2.2.11 Programa Copérnico

Copernicus es el programa de observación de la Tierra más ambicioso hasta la fecha. Proporciona información precisa, oportuna y de fácil acceso para mejorar la gestión del medio ambiente, comprender y mitigar los efectos del cambio climático y garantizar la seguridad ciudadana (Torres et al. 2012; Li et al. 2020); Esta iniciativa está encabezada por la Comisión Europea (CE) en colaboración con la Agencia Espacial Europea (ESA). ESA coordina la entrega de datos de más de 30 satélites. La CE, actuando en nombre de la Unión Europea, es responsable de la iniciativa general, estableciendo requisitos y gestionando los servicios (Torres et al. 2012; Li et al. 2020). La ESA ha desarrollado una nueva familia de satélites, denominada Sentinels, específicamente para las necesidades operativas del programa Copernicus. En la actualidad, dos constelaciones completas de dos satélites están en órbita más dos satélites individuales adicionales, Sentinel-5P y Sentinel-6 Michael Freilich. Con el final de la misión del satélite Sentinel-1B, se planea que Sentinel-1C se una a Sentinel-1A en órbita lo antes posible para restaurar la constelación Sentinel-1. Los Sentinels brindan un conjunto único de observaciones, comenzando con las imágenes de radar diurnas y nocturnas para todo clima de la misión Sentinel-1 (Torres et al. 2012; Li et al. 2020), Sentinel-2A, lanzado el 23 de junio de 2015, está diseñado para ofrecer imágenes ópticas de alta resolución para servicios terrestres. El segundo satélite, Sentinel-2B, se unió a su gemelo en órbita el 7 de marzo de 2017 (Torres et al. 2012; Li et al. 2020). Los dos satélites Sentinel-3, lanzados el 16 de febrero de 2016 y el 25 de abril de 2018, proporcionan datos para servicios relevantes para el océano y la tierra. Sentinel-4 y -5 proporcionarán datos para el seguimiento de la composición atmosférica desde órbitas polares y geoestacionarias, respectivamente. Sentinel-6 lleva un altímetro de radar para medir la altura global de la superficie del mar, principalmente para oceanografía operativa y estudios climáticos. Además, se ha desarrollado una misión Sentinel-5 Precursor para reducir las brechas de datos entre Envisat, en particular el instrumento Sciamachy, y el lanzamiento de Sentinel-5. Sentinel-5P, la primera misión de Copernicus en órbita dedicada a monitorear nuestra atmósfera, fue lanzada el 13 de octubre de 2017 desde el

Cosmódromo de Plesetsk en el norte de Rusia (Torres et al. 2012; Li et al. 2020). El Componente Espacial está gestionado por la ESA y sirve a los usuarios con datos satelitales disponibles a través de los Sentinels y las Copernicus Contributing Missions a nivel nacional, europeo e internacional. El segmento terrestre, que facilita el acceso a los datos de Sentinel y Contributing Mission, completa el componente espacial de Copernicus. El Componente Espacial constituye la contribución europea al Sistema de Sistemas de Observación Global de la Tierra (GEOSS) mundial (Torres et al. 2012; Li et al. 2020). Copernicus proporciona un sistema unificado a través del cual se alimentan grandes cantidades de datos a una variedad de servicios de información temáticos diseñados para beneficiar el medio ambiente, la forma en que vivimos, las necesidades humanitarias y respaldar la formulación de políticas efectivas para un futuro más sostenible (Torres et al. 2012; Li et al. 2020). En esencia, Copernicus ayudará a dar forma al futuro de nuestro planeta en beneficio de todos. La ESA está contribuyendo al proporcionar un marco probado para el desarrollo de sistemas operativos en nombre de la comunidad de usuarios, allanando el camino para la inversión en sistemas de generación futura. La ESA está aprovechando sus 30 años de experiencia en el desarrollo y la gestión de programas espaciales para contribuir al éxito de Copernicus (Torres et al. 2012; Li et al. 2020). Copernicus es el nuevo nombre del programa Global Monitoring for Environment and Security, anteriormente conocido como GMES (Torres et al. 2012; Li et al. 2020).

Sentinel-2

Sentinel-2 es una constelación de dos satélites de imágenes ópticas operados por la Agencia Espacial Europea (ESA), el primero lanzado en junio de 2015 y el segundo en marzo de 2017. Forman parte de Copernicus, el programa de observación de la Tierra de la Unión Europea, que es administrado por la Comisión Europea (CE) (Torres et al. 2012; Li et al. 2020).

Los satélites Sentinel-2 se utilizan para monitorear la calidad del agua continental y costera, y la gestión de cultivos y bosques. Ambos satélites son idénticos y tienen un instrumento multiespectral (MSI) a

bordo. Este instrumento consta de un telescopio anastigmático de tres espejos (TMA) para captar y enfocar la luz, un divisor de haz para separar el infrarrojo visible y cercano (VNIR) del infrarrojo de onda corta (SWIR), dos planos focales con 12 detectores en cada uno para los dos tipos de radiación diferentes, un difusor para calibración radiométrica y un mecanismo de calibración y obturador (CSM) para proteger el instrumento de la luz solar en el lanzamiento. (Torres et al. 2012; Li et al. 2020).

El MSI tiene 13 bandas: tres bandas visibles con una resolución espacial de 10 m, una banda visible con una resolución de 60 m, tres bandas NIR (Near-Infrared) con una resolución de 20 m y seis SWIR (Short Wave Infrared) bandas con una resolución de 60 m. Los satélites Sentinel-2 tienen un tiempo de revisión de 5 días entre ellos, cada uno con una franja de 290 km. Los dos satélites siguen la misma órbita heliosíncrona con una inclinación de $98,6^\circ$ pero están desfasados 180° . Orbitan a una altitud de 786 km con un período de 101 minutos (Torres et al. 2012; Li et al. 2020).

Sentinel-2 utiliza el AstroBus-L de EADS (European Aeronautic Defence and Space Company) Astrium. A bordo de este autobús, además del MSI, hay comunicaciones por radiofrecuencia. Proporcionan un enlace descendente de datos MSI de banda X a 560 Mbit/s, y un enlace de datos de telemetría, seguimiento y comando (TT&C) con un enlace ascendente de 64 kbit/s y un enlace descendente de 2 Mbit/s. Debido a su vida útil de diseño de siete años, Sentinel-2A y 2B serán reemplazados por Sentinel-2C y 2D en 2024 y 2025 respectivamente (Torres et al. 2012; Li et al. 2020).

Sentinel-2 es una misión de imágenes operativas multiespectrales dentro del programa GMES (Global Monitoring for Environment and Security), implementado conjuntamente por la CE (Comisión Europea) y la ESA (Agencia Espacial Europea) para la observación global de la tierra (datos sobre vegetación, suelo y agua). cubierta para tierra, vías navegables interiores y áreas costeras, y también proporciona correcciones de datos de distorsión y absorción atmosférica) a alta resolución con alta capacidad de revisita para proporcionar una continuidad mejorada de los datos proporcionados hasta ahora por SPOT-5 y Landsat-7. En abril de 2008, la ESA

adjudicó el contrato principal a Airbus Defence and Space (anteriormente EADS-Astrium GmbH) de Friedrichshafen, Alemania, para proporcionar el primer satélite de observación de la Tierra Sentinel-2A. En el programa de la misión Sentinel-2, Astrium es responsable del diseño y la plataforma del sistema del satélite, así como de la integración y las pruebas del satélite. Astrium Toulouse suministrará el MSI (MultiSpectral Instrument), y Astrium España se encarga de la estructura del satélite preintegrada con su equipo térmico y arnés. El equipo del núcleo industrial también está formado por Jena Optronik (Alemania), Boostec (Francia), Sener y GMV (España). En marzo de 2010, la ESA y EADS-Astrium GmbH firmaron otro contrato para construir el segundo satélite Sentinel-2 (Sentinel-2B), lo que supuso otro paso importante en el programa GMES (Torres et al. 2012; Li et al. 2020).

Tabla 2. *Características de Sentinel-2*

Sentinel-2A – Sensor: MSI				
Nro.	Nombre de banda	Longitud de onda (nm)	Ancho de onda (nm)	Resolución (m)
1	Coastal aerosol	443,9	27	60
2	Blue	496,6	98	10
3	Green	560	45	10
4	Red	664,5	38	10
5	Vegetation Red Edge	703,9	19	20
6	Vegetation Red Edge	740,2	18	20
7	Vegetation Red Edge	782,5	28	20
8	NIR	835,1	145	10
8a	Narrow NIR	864,8	33	20

9	Water vapour	945	26	60
10	SWIR – Cirrus	1373,5	75	60
11	SWIR	1613,7	143	20
12	SWIR	2202,4	242	20
Sentinel-2B – Sensor: MSI				
Nro,	Nombre de banda	Longitud de onda (nm)	Ancho de onda (nm)	Resolución (m)
1	Coastal aerosol	442,3	45	60
2	Blue	492,1	98	10
3	Green	559	46	10
4	Red	665	39	10
5	Vegetation Red Edge	703,8	20	20
6	Vegetation Red Edge	739,1	18	20
7	Vegetation Red Edge	779,7	28	20
8	NIR	833	45	10
8a	Narrow NIR	864	32	20
9	Water vapour	943,2	27	60
10	SWIR – Cirrus	1376,9	76	60
11	SWIR	1610,4	141	20
12	SWIR	2185,7	238	20

Fuente: Serrano et al. (2015).

2.2.11 Software de procesamiento de imágenes

SNAP ESA

La plataforma de aplicaciones de Sentinel (SNAP) es una arquitectura común para todas las cajas de herramientas de Sentinel. El software está desarrollado por Brockmann Consult, Skywatch, Sensor y CS. La arquitectura SNAP es ideal para el procesamiento y análisis de la observación de la Tierra (EO) debido a las siguientes innovaciones tecnológicas: extensibilidad, portabilidad, plataforma modular de cliente enriquecido, abstracción de datos EO genéricos, administración de memoria en mosaico y un marco de procesamiento de gráficos. SNAP y las cajas de herramientas de Sentinel individuales admiten numerosos sensores además de los sensores de Sentinel. ESA/ESRIN proporciona la herramienta de usuario SNAP de forma gratuita a la Comunidad de Observación de la Tierra (Zuhlke et al. 2015).

ENVI

ENVI es el estándar de la industria para software de procesamiento y análisis de imágenes (Arias et al. 2014). Es utilizado por analistas de imágenes, profesionales de GIS y científicos para extraer información oportuna, confiable y precisa de imágenes geoespaciales (Arias et al. 2014). Este software geoespacial está científicamente probado, es fácil de usar y está estrechamente integrado con la plataforma ArcGIS de Esri (Arias et al. 2014). El software de análisis de imágenes ENVI se ha mantenido a la vanguardia de la innovación durante más de tres décadas debido en parte a su compatibilidad con todo tipo de datos, incluidos multiespectrales, hiperespectrales, térmicos, LiDAR y SAR (Arias et al. 2014). ENVI hace que el aprendizaje profundo sea accesible para las personas a través de herramientas intuitivas y flujos de trabajo que no requieren programación (Arias et al. 2014). El análisis de imágenes geoespaciales ENVI también se puede personalizar a través de una API y un entorno de programación visual para cumplir con los requisitos específicos del proyecto (Arias et al. 2014).

Las características son objetos (Feature Extraction) definidos por el usuario que se pueden modelar o representar mediante conjuntos de datos

geográficos. Los ejemplos incluyen carreteras, edificios y masas de agua. Se utiliza la extracción de características para identificar objetos de imágenes pancromáticas o multiespectrales en función de las características espaciales, espectrales y de textura. Luego, clasifique los objetos en tipos de características conocidas, utilizando uno de los siguientes flujos de trabajo: 1. Basado en reglas: defina características mediante reglas de construcción basadas en atributos de objetos como área, elongación, media espectral, textura, etc., 2. Basado en ejemplos: seleccione datos de entrenamiento (muestras de identidad conocida) para asignar objetos de identidad desconocida a características conocidas., y 3. Solo segmento: extraiga segmentos solo sin realizar una clasificación basada en reglas o basada en ejemplos. Esto le permite crear una imagen de segmentación a la que puede agregar sus propios atributos o clasificar como desee (Arias et al. 2014).

ArcMap

ArcMap es una de las dos principales aplicaciones GIS de escritorio incluidas en la suite ArcGIS Desktop. Se utiliza para realizar una amplia gama de tareas GIS comunes, así como tareas especializadas específicas del usuario. Aquí hay una lista de algunos flujos de trabajo comunes que puede realizar: 1. Trabajar con mapas, 2. Imprimir mapas, 3. Compilación y edición de conjuntos de datos GIS, 4. Utilización de geoprocetamiento para automatizar el trabajo y realizar análisis, 5. Organización y administración de geodatabases y documentos de ArcGIS, 6. Publicación de documentos de mapas como servicios de mapa, 7. Documentación geográfica (Shaner y Wrightsell 2000).

2.3 Definición de términos

Teledetección: ciencia y el arte de identificar, observar y medir un objeto sin entrar en contacto directo con ella. Este proceso implica la detección y medición de la radiación de diferentes longitudes de onda reflejada o emitida por objetos o materiales distantes, por lo que pueden identificarse y

categorizarse por clase/tipo, sustancia y distribución espacial (Chuvieco 1996).

Sensores ópticos: la teledetección óptica se ocupa de la parte del espectro electromagnético caracterizada por las longitudes de onda desde el visible (0,4 micrómetros) hasta el infrarrojo cercano (NIR) hasta el infrarrojo térmico (TIR, 15 micrómetros), recogiendo la radiación reflejada y emitida por las superficies observadas (Booyesen et al. 2021)

Programa Copérnico: el programa Copernicus es un proyecto dirigido por la Unión Europea (UE) y la Agencia Espacial Europea (ESA) que construye y gestiona una flota de satélites de observación de la Tierra llamada Sentinel. Hasta la fecha, se han lanzado ocho misiones que proporcionan datos sobre los cambios que se están produciendo en los océanos, la tierra y la atmósfera de nuestro planeta (Torres et al. 2012; Li et al. 2020).

Sentinel-2: imágenes multispectrales, multitemporales y de 13 bandas de 10 m con representaciones visuales e índices. Esta capa de imágenes se obtiene de las colecciones de Sentinel-2 (Ay B) en AWS y se actualiza diariamente con nuevas imágenes (Serrano et al. 2015).

Cobertura del suelo: clasificación de la tierra según la vegetación o material que cubre la mayor parte de su superficie; por ejemplo, bosque de pinos, pastizales, hielo, agua o arena (Lund 2006).

Análisis de imágenes basada en objetos: implica que los píxeles se agrupen primero en objetos según la similitud espectral o una variable externa, como la propiedad, el suelo o la unidad geológica. Se pueden determinar muchas variables, categorizadas como espectrales, de forma y de vecindad (Blaschke et al. 2014).

Segmentación de imágenes por nivel de escala: técnica importante en la visión artificial, que divide una imagen en varios segmentos sobre la base de propiedades específicas, como colores uniformes o texturas similares (Đideliija et al. 2022).

CAPÍTULO III: METODOLOGÍA DE INVESTIGACIÓN

3.1 Tipo de estudio

El estudio determina las escalas de segmentación de la imagen Sentinel-2 de datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras en el periodo 2022, para ello, “se aplicó una investigación de tipo descriptiva y correlacional”, debido que se evaluó el estado actual de la cobertura del suelo, así como las relaciones entre variables para permitir la predicción de eventos a partir del conocimiento actual (Castro 2003; Baray 2006; Cazau 2006; Hernández et al. 2010; Iglesias 2021).

3.2 Diseño del estudio


La determinación escalas de segmentación de la imagen Sentinel-2 de datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras en el periodo 2022 se enmarcó a un diseño Transaccional (transversal), debido a que recopiló datos de una población en un momento específico (Castro 2003; Baray 2006; Cazau 2006; Hernández et al. 2010; Iglesias 2021).

3.3 Delimitación espacial y temporal

Madre de Dios, es parte de la Amazonia peruana y “es conocida como la capital de la biodiversidad del Perú”, “priorizado para su conservación por contar con de los ecosistemas con mayor biodiversidad del mundo”. “Cuenta con una superficie aproximada de 85 183,96 km² (8 518 396 ha) (6,64 % del territorio nacional), y una población de 141 070 habitantes” (INEI 2017).

Se considerará el distrito de Las Piedras como área de estudio para esta investigación (Figura 6). Geográficamente se ubica entre los 11° 20' 12" S a los 12° 36' 55" S de latitud y los 68° 36' 50" O a los 70° 40' 01" O de longitud

y una superficie promedio de 7 605,60 km² (760 560,15 ha); altitud entre 220 m y 260 msnm, y cuenta con una población de 5 826 habitantes (GOREMAD y IIAP 2009; Chávez et al. 2013; Perz et al. 2013; Alarcón et al. 2016; Perz et al. 2016; INEI 2017).



En el área se localizan territorios de pueblos indígenas (Mamani 2021; Soriano Martinez 2022), concesiones forestales no maderables dedicados al aprovechamiento de la castaña, concesiones forestales maderables, y predios agrícolas que generan la pérdida de vegetación por ampliación de la frontera agrícola y la ganadería (Perz et al. 2013; Perz et al. 2016). En esta parte de la región de Madre de Dios, también hay varias grandes concesiones privadas orientadas a la conservación, sin embargo, a partir del año 2010 empieza a aparecer en imágenes de satélite pequeños fragmentos de pérdida de bosques por deforestación y degradación del suelo por minería de oro (Asner y Tupayachi 2017; Caballero et al. 2018; Alarcon-Aguirre et al. 2021).

En cuanto a la evaluación temporal, la determinación de escalas de segmentación de la imagen Sentinel-2 de datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras corresponde al periodo 2022 entre los meses de junio a octubre.

3.3.1 Clima e hidrografía

La temperatura es semicálida (Holdridge 1967), con temperaturas medias anuales que oscilan entre los 25°C y los 27°C, con ligeras fluctuaciones a lo largo del año, pero el período de septiembre a abril presenta la mayor amplitud de temperaturas medias. Mayo y agosto son los meses más fríos con una mínima de 10°C. La precipitación total anual tiene un promedio de 1 800 mm, con menores precipitaciones entre mayo a septiembre, un 20-25% menos que la precipitación total anual (GOREMAD y IIAP 2009). La evaporación varía de 598,4 mm a 652,6 mm y la humedad relativa varía de 63% a 90%. Los principales afluentes son los ríos Las Piedras y Tahuamanu (GOREMAD y IIAP 2009; Perz et al. 2016; Alarcon-Aguirre et al. 2021; Alarcon-Aguirre et al. 2022).

3.4 Población y muestra

El área de estudio comprende el distrito de Las Piedras de la provincia de Tambopata, con una superficie de 7 605,60 km² (760 560,15 ha).

Para determinar escalas de segmentación de la imagen Sentinel-2 de datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras en el periodo 2022 el número de muestras a levantar en campo o el uso de imágenes de alta resolución, utilizó la distribución binomial de probabilidad (Anaya y Chuvieco 2010; Chuvieco y Hantson 2010; Ochoa y Páez 2019). El tamaño de muestra se calculará mediante la siguiente fórmula (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%).

$$n = \frac{(1,96)^2 * 0,5(0,5 * 760\ 560,15)}{(760\ 560,15 - 1) * 0,05^2 + 1,96^2 * (0,5 * 0,5)}$$
$$n = 383,97 = 384$$

Para determinar la precisión de la clasificación por objetos basados en segmentos de la cobertura terrestre de la cartografía, se empleó el método de confiabilidad temática. Para ello, se aplicó el muestreo aleatorio estratificado o, con una distribución donde todos tienen la misma oportunidad de ser muestreados (Ochoa y Páez 2019). Adicionalmente se optó por el criterio de selección por proximidad (cercanía), en ese sentido, áreas con características similares, se optó por el más cercano. Se empleo 384 puntos distribuidos en el mapa según las siguientes categorías: (1) 64 muestras en áreas artificializados, (2) 90 en áreas agrícolas, (3) 90 en bosque y áreas mayormente naturales, (4) 90 en áreas húmedas continentales y (5) 50 en superficies de agua.




Figura 7. Distribución de muestras para para medir la precisión de la clasificación.

3.5 Método y técnicas

Para este estudio, se utilizó imágenes S2, y estas se descargaron de la plataforma del Centro de acceso abierto Copernicus (Copernicus Open Access Hub). Los detalles de la adquisición de imágenes y la información relacionada se enumeran en tabla 3. Las imágenes fueron productos de nivel 2A que presentan corrección atmosférica a nivel de la superficie. Las imágenes tuvieron una cobertura libre de nubes o menor al 10% (Labib y Harris 2018).

Los datos de S2 tienen un total de 12 bandas: aerosol costero (443 nm), azul (490 nm), verde (560 nm), rojo (665 nm), NIR (842 nm), cuatro bandas de borde rojo de vegetación (bandas 5,6 ,7 y 8A), vapor de agua (1375 nm), onda corta infrarroja-1 (1610 nm), onda corta infrarroja-2 (2190 nm), cirro (1376 nm) (Labib y Harris 2018; Kaplan y Avdan 2019). En el estudio se utilizaron las bandas azul, roja, verde y NIR, debido a su amplia aceptación en la extracción de características de la cobertura terrestre (Jensen et al. 1991; Jensen 2009;

Aljenaïd et al. 2022), y explorar cómo funcionan estos datos en la segmentación y clasificaciones. El estudio aplicó para el AIBO la resolución espacial de S2 de 10 m (Bar et al. 2020; Holtgrave et al. 2020).

En este estudio, a las imágenes S2 en nivel 2A se realizó la transformación de la proyección a un sistema UTM (World Geodetic System 84-WGS84). Todas estas bandas (azul, verde, rojo y NIR) se combinaron en una sola imagen utilizando el apilamiento de capas en ENVI (Versión 5,3) para su posterior procesamiento (Bar et al. 2020; Holtgrave et al. 2020).

Para la clasificación de AIBO se segmentó la imagen en el módulo Feature Extraction de ENVI (flujo de trabajo de extracción de características basado en ejemplos), este software y sus algoritmos desarrollados son ampliamente utilizados en diferentes estudios de AIBO (Faraj y Mahmood 2018) con un enfoque de nivel de escala y fusión. Este procedimiento sigue la fusión de regiones secuenciales, comienza en el nivel de un solo píxel y los píxeles vecinos mutuamente similares forman segmentos más pequeños (Ruiz et al. 2011; Faraj y Mahmood 2018; Labib y Harris 2018; Zhang et al. 2020; Zhao et al. 2020). Los segmentos crecen y los píxeles se agrupan hasta alcanzar un “umbral de heterogeneidad” (Ruiz et al. 2011; Faraj y Mahmood 2018; Labib y Harris 2018; Zhang et al. 2020; Zhao et al. 2020). Sin embargo, la selección del nivel de escala y fusión es cuestión de experimentación para lograr una segmentación aceptable con diferencias claras entre los objetos (Labib y Harris 2018; Kaplan y Avdan 2019). En este caso, se experimentó valores de escala de 10 a 90 (Labib y Harris 2018; Kaplan y Avdan 2019) y una fusión de 90, ello de acuerdo a estudios desarrollados con Sentinel-2 (Geospatial-Harris 2008; Tragheim y Smith 2009; Lian y Chen 2011; Novelli et al. 2016; Labib y Harris 2018).

Culminado el proceso de segmentación, los objetos de imagen desarrollados fueron clasificados para encontrar los tipos de cobertura de suelo. Varios métodos de clasificación están integrados en ENVI Feature Extraction: K vecino más cercano (KNN), máquina de vectores de soporte (SVM) y análisis de componentes principales (PCA) (Ruiz et al. 2011; Fu et al. 2021). El estudio utilizó KNN, que clasifica los segmentos en función de su proximidad a las

regiones de formación vecinas y de mayor rigurosidad que los otros métodos, distinguiendo con mayor precisión entre clases similares (Estrada et al. 2019). Adicionalmente, KNN aún no se utilizan ampliamente con datos S2 (por ejemplo; como las clasificaciones comunes como RF, SVM, ML, NN, entre otras) (Estrada et al. 2019). Por lo tanto, hay posibilidades de que los experimentos integren la expresión real en las clasificaciones de los datos S2 (Labib y Harris 2018; Estrada et al. 2019).

El procesamiento aplicó programas de acceso libre y con licencia; “SNAP ESA, ENVI 5,3®, ArcGIS 10,8® y ArcGIS Pro 2,9® proporcionadas por el Centro de Teledetección para el Estudio y Gestión de los Recursos Naturales (CETEGERN) de la Universidad Nacional Amazónica de Madre de Dios” (Alarcón et al. 2016; Alarcon-Aguirre et al. 2022).

La validación de la clasificación por AIBO sigue siendo un tema de debate entre diferentes investigadores, ya que se ha argumentado que existe incertidumbre en la evaluación de la precisión cuando se usa AIBO debido a cómo se manejan las segmentaciones y las evaluaciones de precisión de clasificación (Labib y Harris 2018). A pesar de ello, se planteó evaluar la precisión de la segmentación de manera visual (Novelli et al. 2016) avalado por el conocimiento del área del investigador (Cohen 1960; Cohen et al. 2003). Al respecto, se realizaron interpretaciones de datos tomados de campo mediante una matriz de error (Cohen 1960; Cohen et al. 2003; Kaplan y Avdan 2019). Para ello, se colectó puntos GPS con atributos de clase de la cobertura y se estimó la precisión general y el índice de Kappa (Cohen 1960; Cohen et al. 2003; Foody 2020).

3.6 Tratamiento de datos

3.6.1 Procesamiento de datos

El material cartográfico del distrito de Las Piedras lo proporciono el Centro de Teledetección para el Estudio y Gestión de Recursos Naturales (CETEGERN) de la UNAMAD (Alarcón et al. 2016), mientras que las imágenes S2 para el

periodo 2022 se descargaron de Sentinel Hub (Bouvet et al. 2018; Holtgrave et al. 2020; Puzzi et al. 2020; Niro et al. 2021; Puzzi et al. 2021) (Tabla 2 y 3).

Tabla 3. *Información de adquisición de imágenes Sentinel-2*

Sensor	Fecha de imagen	Nivel de procesamiento	Orbita
Sentinel-2A	2022/08/04 14:47;41,025	2A	Descendente
Sentinel-2A	2022/08/04 14:47;41,024	2A	Descendente
Sentinel-2A	2022/09/06 14:57;41,024	2A	Descendente
Sentinel-2A	2022/09/06 14:57;41,024	2A	Descendente
Sentinel-2B	2022/09/08 14:47;29,024	2A	Descendente
Sentinel-2B	2022/09/18 14:47;29,024	2A	Descendente
Sentinel-2B	2022/06/13 14:57;29,024	2A	Descendente
Sentinel-2B	2022/08/12 14:57;29,024	2A	Descendente

El procesamiento de imágenes S2 descargados se basó en las siguientes fases:

- 1. Pre-Procesamiento.** Se preparo la data óptica S2; se utilizó como productos el nivel 2A, corregidos atmosféricamente a nivel de superficie con el algoritmo Sen2Cor y el modelo de elevación digital PlanetDEM (Varghese et al. 2021).
- 2. Procesamiento.** La segmentación de la imagen S2 multiespectral se realizó con el software ENVI 5,3® (Feature Extraction). Este módulo utilizo el algoritmo basado en los bordes “Edge-based-algorithm” para segmentar las imágenes, que requiere como entrada de configuración el nivel de escala “Scale-level”, parámetro que varía de 0 y 100, de

menos a mayor segmentos, donde una correcta elección garantiza una clasificación más exacta (Fernández y Rincón 2020). Un parámetro opcional es nivel de fusión “Merge-level” que será considerado en el estudio con un valor de 90 (Geospatial-Harris 2008; Tragheim y Smith 2009; Lian y Chen 2011; Novelli et al. 2016; Labib y Harris 2018) y se utilizó para integrar segmentos muy pequeños a segmentos más grandes. La clasificación utilizó el algoritmo K vecino más cercano “K-Nearest Neighbor” (KNN), que consiste en la “distancia euclidiana en un espacio n-dimensional donde n es el número de atributos, y es mucho menos sensible al ruido, mientras K indica el número de vecinos que serán considerados en la clasificación” (Fernández y Rincón 2020, p. 35). Las categorías de clasificación se realizó en base a la metodología desarrollada por CORINE Land Cover (IDEAM 2010), y adaptada por el Ministerio del Ambiente (MINAM 2012), el cual presenta una jerarquía espacial y temática en la leyenda (Tabla 4). Para el estudio se considerará el nivel I.

El algoritmo KNN se implementó mediante la introducción de algunas notaciones, se consideró el conjunto de entrenamiento, donde es el vector de características d-dimensional, y se asocia con las etiquetas de clase observadas. Para simplificar, consideraremos una clasificación binaria. Generalmente suponemos que todos los datos de entrenamiento son muestras id de variables aleatorias con distribución desconocida.

Con muestras previamente etiquetadas como conjunto de entrenamiento, el algoritmo KNN construye una subregión local del espacio de entrada, que se sitúa en el punto de estimación. La región de predicción contiene los puntos de entrenamiento más cercanos, que se escribe de la siguiente manera (Ecuación 2):

$$R(x) = \{ \hat{x} | D(x, \hat{x}) \leq d_k \} \quad (\text{Ecuación 2})$$

donde d(k) es el estadístico de orden kth y es la métrica de distancia. denota el número de muestras en la región, que está

etiquetada. El algoritmo KNN está diseñado estadísticamente para la estimación de la probabilidad posterior del punto de observación

$$p(y|x) = \frac{p(x|y)p(y)}{p(x)} \cong \frac{k[y]}{k} \quad (\text{Ecuación 3})$$

Para una observación dada x , la decisión $g(x)$ se formuló evaluando los valores de $k[y]$ seleccionando la clase que tiene el valor más alto $k[y]$.

$$g(x) = \left[\begin{array}{l} 1, \text{ } k[y = 1] \geq k[y = -1], \\ -1, \text{ } k[y = -1] \geq k[y = 1] \end{array} \right] \quad (\text{Ecuación 4})$$

Por lo tanto, la decisión que maximiza la probabilidad posterior asociada se empleó en el algoritmo KNN. Para un problema de clasificación binaria en el que $y_i \in [+1, 1]$, el algoritmo KNN genera la siguiente regla de decisión (Ecuación 5):

$$g(x) = \text{sgn}(\text{ave}_{x_i \in R(x)} y_i) \quad (\text{Ecuación 5})$$

Tabla 4. *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
	3.1 Bosque	3.1.1 Bosque denso bajo

3. Bosques y áreas mayormente naturales		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. La Post-clasificación consistirá en la vectorización y cuantificación de los resultados obtenidos en la segmentación con ENVI 5,3® y SNAP ESA. Para el procesamiento y análisis se utilizó los softwares ArcGIS 10,8® y ArcGIS Pro 2,9®.

3.6.2 Precisión de datos clasificados

La clasificación por AIBO por segmentación se evaluó de manera visual (Novelli et al. 2016) avalado por el conocimiento del área del investigador (Cohen 1960; Cohen et al. 2003). Al respecto, se realizó interpretaciones de datos tomados de campo con GPS por categoría. La precisión se midió mediante una matriz de confusión; se estimó la precisión general y el índice de Kappa como medida de concordancia de la clasificación de la imágenes de Sentinel-2 con los datos de campo (Tabla 5) (Ecuación 6) (Cohen 1960; Cohen et al. 2003; Foody 2020).

$$Precision\ general = VP + VN / VP + FP + VN + FN \quad (\text{Ecuación 6})$$

donde: “VP es verdadero positivo, VN verdadero negativo, FP falso positivo, y FN falso negativo” (Ecuación 7).

$$Kappa(k) = f_o - f_c / N - f_c \quad (\text{Ecuación 7})$$

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

Tabla 5. *Valores del coeficiente kappa*

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

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

“El protocolo de levantamiento de información de campo se basó al método aplicado por el Centro para el Estudio de Instituciones, Población y Cambios en el Medio Ambiente de la Universidad de la Indiana (CIPEC)” (Moran y Brondizio 1998; Chávez et al. 2013).

3.6.3 Análisis estadístico

El estudio aplicó la geoestadística descriptiva e inferencial, para ello, se usó programas de acceso abierto y con licencia; GeoDa, SigmaPlot, Microsoft Excel, ENVI 5,3®, SNAP ESA, ArcGIS 10,8® y ArcGIS Pro 2,9®.

Para el primer y segundo, sobre determinar los parámetros óptimos de segmentación de imágenes Sentinel-2 bajo un criterio de nivel de escala y fusión mediante datos orientados a objetos y cuantificar la cobertura del suelo en el distrito de Las Piedras para el periodo 2022, se aplicó algoritmos con los softwares SNAP ESA, ENVI 5,3®, ArcGIS 10,8® y ArcGIS Pro 2,9® y Microsoft Excel (Li et al. 2012; Alarcón et al. 2016, p. 321; Yu et al. 2020;

Zhang et al. 2020; Zhao et al. 2020; Fu et al. 2021; Qi et al. 2021; Aljenaid et al. 2022; Đideliija et al. 2022; Mokhtar et al. 2022).

Sobre el tercer objetivo, sobre evaluar la precisión del método de escala de segmentación de imágenes sentinel-2 basados en datos orientados a objetos de la cobertura del suelo en el distrito de Las Piedras para el periodo 2022, se “empleo un test de evaluación denominado matriz de confusión y el coeficiente kappa (κ)” (Cohen 1960; Elijah y Jensen 1996; Chuvieco 2002; Cohen et al. 2003; Chuvieco y Hantson 2010; Alarcón et al. 2016).

CAPÍTULO IV: RESULTADOS Y DISCUSIÓN

4.1 Parámetros de segmentación de Sentinel-2 orientados a objetos de la cobertura del suelo en el distrito de Las Piedras

La clasificación basada en objetos mediante procedimientos de segmentación no solo depende del valor específico de la resolución espacial, sino también de su forma, tamaño y la estructura de los objetos circundantes. La escala en el análisis orientado a objetos ya no es el tamaño del píxel, sino el segmento de escala de la imagen y el umbral mínimo de la heterogeneidad de los objetos de la imagen. Los resultados muestran las características de la cobertura terrestre del distrito de Las Piedras de imágenes del sensor Sentinel-2 de las bandas azul, roja, verde y NIR (10 m de resolución espacial) (Figuras 8-16). Hay una escala de segmentación óptima para aplicaciones particulares, que puede conducir a la mayor precisión de clasificación general mediante límites de segmentación de polígonos claros de las características y visualización múltiple de estas características con uno o más objetos.

Siguiendo el criterio de clasificación de objetos por segmentos, el estudio utilizó criterios espaciales, espectrales y texturales, la fusión, la forma y la compacidad los principales criterios de evaluación de la mejor escala de segmentación.

Usamos el módulo Flujo de trabajo de extracción de características (Feature Extraction Workflow) del software ENVI para segmentar imágenes sentinel-2 en multiescala, y las escalas se dividieron en: 10, 20, 30, 40, 50, 60, 70, 80 y 90. De acuerdo a estudios realizados, el nivel de fusión utilizado fue de 90 (Geospatial-Harris 2008; Tragheim y Smith 2009; Lian y Chen 2011; Novelli et al. 2016; Labib y Harris 2018).




Figura 8. Segmentación de escala 10 y fusión 90.




Figura 9. Segmentación de escala 20 y fusión 90.




Figura 10. Segmentación de escala 30 y fusión 90.




Figura 11. Segmentación de escala 40 y fusión 90.




Figura 12. Segmentación de escala 50 y fusión 90.




Figura 13. Segmentación de escala 60 y fusión 90.




Figura 14. Segmentación de escala 70 y fusión 90.




Figura 15. Segmentación de escala 80 y fusión 90.




Figura 16. Segmentación de escala 90 y fusión 90.

El análisis visual por nivel de escala y una fusión de 90, determina que el tamaño de la escala de 80 y 90 los objetos extraídos y la superficie real presentan características extremadamente desiguales, por lo que, en adelante en el análisis, se elimina la escala de 80 y 90 (Figuras 8-16).

Se puede ver en la tabla 6 que, la forma y la compacidad de los datos con mejores características se encuentran en la escala 40, 50 y 60. El análisis muestra que, en la extracción de varios tipos de características de la superficie, la escala óptima no es necesariamente un valor único, sino generalmente un rango de valores para lograr una segmentación óptima.

Los parámetros de forma y compacidad optimizan los objetos buscando que sus bordes sean más compactos, el estudio reporta mejores comportamientos de forma y compacidad en la escala de 40, 50 y 60 (Tabla 6).

Tabla 6. *Parámetros más importantes utilizados en la segmentación de Sentinel-2*

Escala	Forma	Compacidad
10	0,1910	0,3844
20	0,1968	0,4075
30	0,2026	0,4306
40	0,2084	0,4538
50	0,2142	0,4769
60	0,2200	0,5000
70	0,2210	0,4750

Del análisis y estudios en datos de satélite de objetos por segmentos, se puede deducir que la resolución espacial de las imágenes tiene una cierta relación con los niveles de escalas: por lo general, cuanto mayor sea la resolución espacial, mayor será la escala; mientras que cuanto menor sea la resolución espacial, menor será la escala. También se puede ver que cuanto mayor sea la resolución de la imagen, mejor será el efecto de la segmentación de la imagen; cuanto menor sea la resolución de la imagen, peor será el efecto de la segmentación de la imagen. En términos relativos, la resolución de imagen Sentinel-2 es mediana, por lo que su escala y efecto de segmentación

se comporta mejor en términos medios (40, 50 y 60). Estos comportamientos también se presentaron en estudios sobre clasificación de objetos basado en segmentos de diferentes sensores (Harvey et al. 2002; Lian y Chen 2011; Ruiz et al. 2011; Novelli et al. 2016; Khatriker y Kumar 2018; Labib y Harris 2018; Garnica 2019; Kaplan y Avdan 2019; Foody 2020; Van doninck et al. 2020; Yu et al. 2020; Zhang et al. 2020; Zhao et al. 2020; Đideliija et al. 2022; Mokhtar et al. 2022).

4.2 Cuantificación de la cobertura del suelo

Después de la segmentación, se realizó una clasificación para cada uno de las cinco categorías (Tabla 7). Como era de esperar, la imagen clasificada contenía segmentos mal clasificados, es decir, clasificados como cobertura de suelo inadecuado. Esto requirió un proceso de filtrado para reducir la cantidad de segmentos en las categorías. Después del filtrado, cada grupo de segmentos se observó por separado en el contexto espacial. Se han detectado ciertas anomalías. Por ejemplo, se han detectado áreas agrícolas, dichos segmentos se consideraron errores graves y se eliminaron de los resultados mediante análisis visual, lo que dio como resultado mapas finales (Figuras 17-23). Se demostró que las áreas con mayor dimensión presentan un mejor comportamiento en la caracterización del área de estudio.

Los resultados muestran un área de bosques y áreas mayormente naturales, así como de áreas húmedas continentales sobrestimada en la escala 10, 20, 30 y 70, mientras que, en la escala de 40, 50 y 60 las características y delineación de extracción son mejores (Figuras 17-23). En este caso, la categoría de bosque y áreas mayormente naturales está representada entre el 78%-79% y áreas húmedas continentales entre el 14%-15%.

Para áreas agrícolas esta representa aproximadamente el 5% y muestra una subestimación de áreas en las escalas 10, 20, 30 y 70. Superficies de agua representa en promedio el 2%, con una subestimación de áreas en las escalas 10, 20 y 30. Finalmente áreas artificializadas compone el 0,2% y presenta una subestimación de áreas en las escalas de 10, 20 y 30.




Figura 17. Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 10 y fusión 90.




Figura 18. Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 20 y fusión 90.




Figura 19. Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 30 y fusión 90.




Figura 20. Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 40 y fusión 90.




Figura 21. Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 50 y fusión 90.




Figura 22. Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 60 y fusión 90.




Figura 23. Cuantificación de la cobertura del suelo de Sentinel-2 con escala de segmentación 70 y fusión 90.

La clasificación de objetos por segmentos, muestra datos erróneos entre bosques y áreas mayormente naturales con áreas agrícolas y áreas húmedas continentales. Mientras que áreas agrícolas presenta confusión con áreas artificializados.

Tabla 7. Cuantificación de la cobertura del suelo de Sentinel-2 por nivel de escala de segmentación.

Escala	Categorías (ha)				
	1 Áreas artificializados	2 Áreas agrícolas	3 Bosques y áreas mayormente naturales	4 Áreas húmedas continentales	5 Superficie de agua
10	1 540,01	39 040,94	59 6247,71	111 766,27	11 965,22
20	1 640,76	40 218,38	59 5293,97	111 242,35	12 164,69
30	1 585,25	36 013,82	59 9494,44	111 040,62	12 426,02
40	1 714,52	41 563,75	59 4874,02	110 270,70	12 137,16
50	1 585,25	40 422,79	59 5085,47	111 040,62	12 426,02
60	1 692,44	41 810,18	59 4506,91	110 009,94	12 540,68
70	1 692,44	37 455,30	59 8850,60	110 021,07	12 540,75

Con base en las comparaciones cualitativas y cuantitativas de la segmentación por las categorías, se demuestra que el método de niveles de escala y fusión (90) presenta diferentes características. La clasificación de objetos por segmentación mediante Sentinel-2 (10 m de resolución espacial) caracteriza mejor a unidades grandes como bosques y áreas mayormente naturales, así como áreas húmedas continentales más cercanos a las escalas inherentes de las entidades geográficas (Lian y Chen 2011; Blaschke et al. 2014; Kaplan y Avdan 2019; Đideliija et al. 2022). Estos resultados generados son similares a los casos naturales, lo que sienta una base sólida para análisis posteriores (Lian y Chen 2011; Yu et al. 2020; Zhao et al. 2020; Đideliija et al. 2022; Mokhtar et al. 2022). Este comportamiento también se presenta en unidades de respuesta espectral homogéneas, como lo es las superficies de agua (Lian y Chen 2011; Estrada et al. 2019; Fu et al. 2021).

A pesar de las potencialidades del método, a menudo también se observa una clasificación errónea entre clases; en este caso, como se mencionó anteriormente, bosques y áreas mayormente naturales con áreas húmedas continentales y áreas artificializados con áreas agrícolas causan confusiones debido a que tienen valores de reflectancia dentro del rango de la vegetación y suelo desnudo. Estos hallazgos son consistentes con otros estudios (Ruiz et al. 2011; Novelli et al. 2016; Khatriker y Kumar 2018; Xiong et al. 2019; Yu et al. 2020; Zhang et al. 2020; Zhao et al. 2020; Mokhtar et al. 2022).

4.3 Evaluación de precisión del método

Se utilizaron la matriz de precisión general y la concordancia de kappa para medir la precisión de la cuantificación de la cobertura terrestre de Sentinel-2 de un objeto por segmentos que se presentan en las tablas 8-14.

La matriz de confusión mostro una precisión general de; 69,00%, 70,10%, 71,10%, 74,00%, 77,30%, 79,90% y 75,80% para una escala de 10, 20, 30, 40, 50, 60 y 70 con un nivel de fusión de 90. Mientras que kappa; 0,636, 0,649, 0,663, 0,689, 0,729, 0,756 y 0,719 (Considerable) respectivamente (Cohen 1960; Cohen et al. 2003).

Tabla 8. *Precisión de datos de imágenes Sentinel-2 (escala 10 y fusión 90)*

Categoría		Datos de campo					
		1	2	3	4	5	$f_{\text{Sentinel-2}}$
Sentinel-2 (10*90)	1	54 (11)	10	0	0	0	64
	2	11	72 (20)	4	3	0	90
	3	0	2	70 (22)	18	0	90
	4	0	2	19	69 (30)	0	90
	5	0	0	0	40	10 (1)	50
	f_{DC}	65	86	93	130	10	384
$f_o =$	275			$f_c =$	85		
$k =$	0,636			$k_M =$	0,852		
$\sigma_k =$	0,0295			$\sigma_{k_o} =$	0,0271		
$z =$	23,453			Matriz de confusión=			0,690

Leyenda: 1. Áreas artificializados, 2. Áreas agrícolas, 3. Bosques y áreas mayormente naturales, 4. Áreas húmedas continentales y 5. Superficies de agua.

Tabla 9. *Precisión de datos de imágenes Sentinel-2 (escala 20 y fusión 90)*

Categoría		Datos de campo					
		1	2	3	4	5	$f_{\text{Sentinel-2}}$
Sentinel-2 (20*90)	1	56 (11)	8	0	0	0	64
	2	10	74 (20)	4	2	0	90
	3	0	2	70 (22)	18	0	90
	4	0	2	19	69 (30)	0	90
	5	0	0	0	40	10 (1)	50
	f_{DC}	66	86	93	129	10	384
$f_o =$	279			$f_c =$	84		
$k =$	0,649			$k_M =$	0,848		
$\sigma_k =$	0,0292			$\sigma_{k_o} =$	0,0271		
$z =$	23,961			Matriz de confusión=			0,701

Leyenda: 1. Áreas artificializados, 2. Áreas agrícolas, 3. Bosques y áreas mayormente naturales, 4. Áreas húmedas continentales y 5. Superficies de agua.

Tabla 10. *Precisión de datos de imágenes Sentinel-2 (escala 30 y fusión 90)*

Categoría		Datos de campo					
		1	2	3	4	5	$f_{\text{Sentinel-2}}$
Sentinel-2 (30*90)	1	57 (11)	7	0	0	0	64
	2	9	75 (20)	3	3	0	90
	3	0	1	71 (22)	18	0	90
	4	0	1	19	70 (31)	0	90
	5	0	0	0	40	10 (1)	50
	f_{DC}	66	84	93	131	10	384
$f_o =$	283			$f_c =$	84		
$k =$	0,663			$k_M =$	0,848		
$\sigma_k =$	0,0288			$\sigma_{k_o} =$	0,0271		
$z =$	24,454			Matriz de confusión=			0,711

Leyenda: 1. Áreas artificializados, 2. Áreas agrícolas, 3. Bosques y áreas mayormente naturales, 4. Áreas húmedas continentales y 5. Superficies de agua.

Tabla 11. *Precisión de datos de imágenes Sentinel-2 (escala 40 y fusión 90)*

Categoría		Datos de campo					
		1	2	3	4	5	$f_{\text{Sentinel-2}}$
Sentinel-2 (40*90)	1	59 (11)	5	0	0	0	64
	2	7	78 (20)	2	3	0	90
	3	0	0	73 (21)	17	0	90
	4	0	2	14	74 (32)	0	90
	5	0	0	0	43	7 (1)	50
	f_{DC}	66	85	89	137	7	384
$f_o =$	291			$f_c =$	85		
$k =$	0,689			$k_M =$	0,849		
$\sigma_k =$	0,0281			$\sigma_{k_o} =$	0,0272		
$z =$	25,367			Matriz de confusión=			0,740

Leyenda: 1. Áreas artificializados, 2. Áreas agrícolas, 3. Bosques y áreas mayormente naturales, 4. Áreas húmedas continentales y 5. Superficies de agua.

Tabla 12. *Precisión de datos de imágenes Sentinel-2 (escala 50 y fusión 90)*

Categoría		Datos de campo					
		1	2	3	4	5	$f_{\text{Sentinel-2}}$
Sentinel-2 (50*90)	1	60 (11)	4	0	0	0	64
	2	6	80 (20)	1	3	0	90
	3	0	0	79 (21)	11	0	90
	4	0	1	11	78 (32)	0	90
	5	0	0	0	44	6 (1)	50
	f_{DC}	66	85	91	136	6	384
$f_o =$	303			$f_c =$	85		
$k =$	0,729			$k_M =$	0,849		
$\sigma_k =$	0,0267			$\sigma_{k_o} =$	0,0272		
$z =$	26,819			Matriz de confusión=			0,773

Leyenda: 1. Áreas artificializados, 2. Áreas agrícolas, 3. Bosques y áreas mayormente naturales, 4. Áreas húmedas continentales y 5. Superficies de agua.

Tabla 13. *Precisión de datos de imágenes Sentinel-2 (escala 60 y fusión 90)*

Categoría		Datos de campo					
		1	2	3	4	5	$f_{\text{Sentinel-2}}$
Sentinel-2 (60*90)	1	61 (11)	3	0	0	0	64
	2	4	83 (20)	1	2	0	90
	3	0	0	81 (21)	9	0	90
	4	0	0	8	82 (33)	0	90
	5	0	0	0	46	4 (1)	50
	f_{DC}	65	86	90	139	4	384
$f_o =$	311			$f_c =$	85		
$k =$	0,756			$k_M =$	0,853		
$\sigma_k =$	0,0257			$\sigma_{k_o} =$	0,0272		
$z =$	27,736			Matriz de confusión=			0,799

Leyenda: 1. Áreas artificializados, 2. Áreas agrícolas, 3. Bosques y áreas mayormente naturales, 4. Áreas húmedas continentales y 5. Superficies de agua.

Tabla 14. *Precisión de datos de imágenes Sentinel-2 (escala 70 y fusión 90)*

Categoría		Datos de campo					
		1	2	3	4	5	$f_{\text{Sentinel-2}}$
Sentinel-2 (70*90)	1	54 (11)	10	0	0	0	64
	2	10	76 (20)	1	3	0	90
	3	0	0	80 (21)	10	0	90
	4	0	0	9	81 (32)	0	90
	5	0	0	0	41	9 (1)	50
	f_{DC}	64	86	90	135	9	384
$f_o =$	300			$f_c =$	85		
$k =$	0,719			$k_M =$	0,855		
$\sigma_k =$	0,0271			$\sigma_{k_o} =$	0,0272		
$z =$	26,491			Matriz de confusión=		0,758	

Leyenda: 1. Áreas artificializados, 2. Áreas agrícolas, 3. Bosques y áreas mayormente naturales, 4. Áreas húmedas continentales y 5. Superficies de agua.

El valor de $k =$, entre 0,636 y 0,756, muestra que más de la mitad de las muestras verificadas están de acuerdo (excluyendo el azar) respecto a la clasificación por nivel de escala y fusión (90) de Sentinel-2 con resolución espacial de 10 m (Cohen 1960; Cohen et al. 2003). Con una probabilidad de $(P) < 0,001$, el valor de z para todos los casos es significativo (Tablas 8-14) (Ruiz et al. 2011; Labib y Harris 2018; Kaplan y Avdan 2019; Yu et al. 2020; Zhao et al. 2020; Fu et al. 2021; Đideliija et al. 2022; Mokhtar et al. 2022).

A pesar de las pequeñas diferencias en cuanto al nivel de escala y fusión en la clasificación de objetos por segmentación, el nivel de escala 60 mostro mejores resultados respecto a otros criterios (10, 20, 30, 40, 50 y 70). En ella, se puede apreciar una menor confusión de clases, a excepción de bosques y áreas mayormente naturales con áreas húmedas continentales, que muestra un patrón similar en todos los niveles (Lian y Chen 2011).

En general, Sentinel-2 con las bandas azul, roja, verde y NIR (10 m de resolución espacial) (Figuras 8-16) presenta mejor precisión de clasificación entre los niveles de escala de 40 y 60. Debido a la alta resolución, la homogeneidad espectral por segmentos dentro del mismo tipo de características de la superficie (objeto), lo que aumenta la separación entre clases y precisión de la clasificación (Geospatial-Harris 2008; Jahjah y Ulivieri

2010; Lian y Chen 2011; Ruiz et al. 2011; Faraj y Mahmood 2018; Khatriker y Kumar 2018; Labib y Harris 2018; Kaplan y Avdan 2019; Yu et al. 2020; Zhao et al. 2020; Fu et al. 2021; Đideliija et al. 2022; Mokhtar et al. 2022)

CONCLUSIONES

Mediante el método de segmentación por objetos mediante imágenes Sentinel-2 de la cobertura terrestre en el distrito de Las Piedras, se tiene las siguientes conclusiones:

De acuerdo a los parámetros de forma y compacidad, el estudio reporta mejores comportamientos de forma y compacidad en la escala de 40, 50 y 60.

La cuantificación de las categorías, los resultados muestran un área de bosques y áreas mayormente naturales, así como de áreas húmedas continentales sobrestimada en la escala 10, 20, 30 y 70, mientras que, en la escala de 40, 50 y 60 las características y delineación de extracción son mejores. Para áreas agrícolas muestra una subestimación de áreas en las escalas 10, 20, 30 y 70. Superficies de agua con una subestimación de áreas en las escalas 10, 20 y 30. Mientras que áreas artificializados se subestima en las escalas de 10, 20 y 30.

La segmentación de Sentinel-2 por nivel de escala 60 con las bandas azul, roja, verde y NIR (10 m de resolución espacial) presenta una mejor precisión de clasificación, debido a la homogeneidad espectral por segmentos lo que aumenta la separación entre clases.

SUGERENCIAS

Los datos de teledetección y métodos de procesamiento son variados y aplicables con mayor o menor precisión según las características de la cobertura terrestre, por lo que, las técnicas a nivel de pixel, objetos (segmentos) e híbridos necesitan ser validados. En ese sentido, es necesario mayores investigaciones que determinen la fiabilidad de los productos de datos de satélite (Landsat, Sentinel, PeruSAT-1, entre otros) por el método de segmentos que nos permita obtener mejores resultados en el monitoreo de la cobertura terrestre.

REFERENCIAS BIBLIOGRÁFICAS

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

ALARCON-AGUIRRE, G., MIRANDA FIDHEL, R. F., RAMOS ENCISO, D., CANAHUIRE-ROBLES, R., RODRIGUEZ-ACHATA, L. Y GARATE-QUISPE, J. Burn Severity Assessment Using Sentinel-1 SAR in the Southeast Peruvian Amazon, a Case Study of Madre de Dios. *Fire*, 2022, 5(4). doi:10.3390/fire5040094

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

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

ALJENAID, S., ABIDO, M., REDHA, G. K., ALKHUZAEI, M., MARSAN, Y., KHAMIS, A. Q., NASER, H., ALRUMAIDH, M. Y ALSABBAGH, M. Assessing the spatiotemporal changes, associated carbon stock, and potential emissions of mangroves in Bahrain using GIS and remote sensing data. *Regional Studies in Marine Science*, 2022/05/01/ 2022, 52, 102282. doi:<https://doi.org/10.1016/j.rsma.2022.102282>

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.

ANDERSEN, L. E., GROOM, B., KILLICK, E., LEDEZMA, J. C., PALMER, C. Y WEINHOLD, D. Modelling Land Use, Deforestation, and Policy: A Hybrid Optimisation-Heterogeneous Agent Model with Application to the Bolivian Amazon. *Ecological Economics*, 2017/05/01/ 2017, 135, 76-90. doi:<https://doi.org/10.1016/j.ecolecon.2016.12.033>

ARIAS, H. A., ZAMORA, R. M. Y BOLAÑOS, C. V. Metodología para la corrección atmosférica de imágenes Aster, Rapideye, Spot 2 y Landsat 8 con el módulo Flaash del software ENVI. *Revista Geográfica de América Central*, 2014, 2(53), 39-59. doi:<https://doi.org/10.15359/rgac.2-53.2>

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.

BAR, S., PARIDA, B. R. Y PANDEY, A. C. Landsat-8 and Sentinel-2 based Forest fire burn area mapping using machine learning algorithms on GEE cloud platform over Uttarakhand, Western Himalaya. *Remote Sensing Applications: Society and Environment*, 2020/04/01/ 2020, 18, 100324. doi:<https://doi.org/10.1016/j.rsase.2020.100324>

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>

BLASCHKE, T., HAY, G. J., KELLY, M., LANG, S., HOFMANN, P., ADDINK, E., QUEIROZ FEITOSA, R., VAN DER MEER, F., VAN DER WERFF, H., VAN COILLIE, F. Y TIEDE, D. Geographic Object-Based Image Analysis – Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014/01/01/ 2014, 87, 180-191. doi:<https://doi.org/10.1016/j.isprsjprs.2013.09.014>

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.

BOUVET, A., MERMOZ, S., BALLÈRE, M., KOLECK, T. Y LE TOAN, T. Use of the SAR Shadowing Effect for Deforestation Detection with Sentinel-1 Time Series. *Remote Sensing*, 2018, 10(8). doi:10.3390/rs10081250

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>

CAPERS, R. S., CHAZDON, R. L., BRENES, A. R. Y ALVARADO, B. V. J. J. O. E. Successional dynamics of woody seedling communities in wet tropical secondary forests 2005, 93(6), 1071-1084. doi: <https://doi.org/10.1111/j.1365-2745.2005.01050.x>

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>

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.

CORTÉS-MCPHERSON, D. Expansion of small-scale gold mining in Madre de Dios: 'capital interests' and the emergence of a new elite of entrepreneurs in the Peruvian Amazon. The Extractive Industries and Society, 2019/04/01/ 2019, 6(2), 382-389. doi:<https://doi.org/10.1016/j.exis.2019.01.002>

ĐIDELIJA, M., KULO, N., MULAHSIĆ, A., TUNO, N. Y TOPOLJAK, J. Segmentation scale parameter influence on the accuracy of detecting illegal landfills on satellite imagery. A case study for Novo Sarajevo. Ecological Informatics, 2022/09/01/ 2022, 70, 101755. doi:<https://doi.org/10.1016/j.ecoinf.2022.101755>

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

ESTRADA, P. A. L., JIMENEZ, E. L., NUÑO, J. A. M. Y LOMAS, J. H. P. Water bodies detection using supervised learning algorithms. In *2019 IEEE International Fall Meeting on Communications and Computing (ROC&C)*. 2019, p. 45-50.

FARAJ, J. I. Y MAHMOOD, F. H. Extraction of Vacant Lands for Baghdad City Using Two Classification Methods of Very High Resolution Satellite Images. Iraqi Journal of Science, 2018, 2336-2342. doi:0.24996/ij.s.2018.59.4C.21

FERNÁNDEZ-MANSO, A., FERNÁNDEZ-MANSO, O. Y QUINTANO, C. SENTINEL-2A red-edge spectral indices suitability for discriminating burn severity. *International Journal of Applied Earth Observation and Geoinformation*, 2016/08/01/ 2016, 50, 170-175. doi:<https://doi.org/10.1016/j.jag.2016.03.005>

FERNÁNDEZ, L. T. L. Y RINCÓN, L. N. G. Procesamiento de imágenes satelitales. *L'esprit Ingénieux*, 2020, 11(1), 33-49. doi:<http://revistas.ustatunja.edu.co/index.php/lingenieux/article/view/2332/1972>

FOODY, G. M. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. *Remote Sensing of Environment*, 2020/03/15/ 2020, 239, 111630. doi:<https://doi.org/10.1016/j.rse.2019.111630>

FU, B., LIU, M., HE, H., LAN, F., HE, X., LIU, L., HUANG, L., FAN, D., ZHAO, M. Y JIA, Z. Comparison of optimized object-based RF-DT algorithm and SegNet algorithm for classifying Karst wetland vegetation communities using ultra-high spatial resolution UAV data. *International Journal of Applied Earth Observation and Geoinformation*, 2021/12/15/ 2021, 104, 102553. doi:<https://doi.org/10.1016/j.jag.2021.102553>

GARNICA, C. R. Segmentación de imágenes de satélite en el estudio de bosques húmedos tropicales de la Reserva Nacional Tambopata, Madre de Dios 2019.

GEOSPATIAL-HARRIS ENVI Feature Extraction Module User's Guide. ITT Corporation, 2008.

GIUDICE, R., SOARES-FILHO, B. S., MERRY, F., RODRIGUES, H. O. Y BOWMAN, M. Timber concessions in Madre de Dios: Are they a good deal? *Ecological Economics*, 2012/05/01/ 2012, 77, 158-165. doi:<https://doi.org/10.1016/j.ecolecon.2012.02.024>

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

HARVEY, N. R., THEILER, J., BRUMBY, S. P., PERKINS, S., SZYMANSKI, J. J., BLOCH, J. J., PORTER, R. B., GALASSI, M. Y YOUNG, A. C. Comparison of GENIE and conventional supervised classifiers for multispectral image feature extraction. IEEE Transactions on Geoscience and Remote Sensing, 2002, 40(2), 393-404. doi:10.1109/36.992801

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

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

HOLTGRAVE, A.-K., RÖDER, N., ACKERMANN, A., ERASMI, S. Y KLEINSCHMIT, B. Comparing Sentinel-1 and -2 Data and Indices for Agricultural Land Use Monitoring. Remote Sensing, 2020, 12(18). doi:10.3390/rs12182919

IDEAM, I. D. H. M. Y. E. A.-. 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.

IGLESIAS, M. E. *Metodología de la investigación científica: diseño y elaboración de protocolos y proyectos*. Edition ed.: Noveduc, 2021. ISBN 987538464X.

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.

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

JAHJAH, M. Y ULIVIERI, C. Automatic archaeological feature extraction from satellite VHR images. *Acta Astronautica*, 2010/05/01/ 2010, 66(9), 1302-1310. doi:<https://doi.org/10.1016/j.actaastro.2009.10.028>

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>

KAPLAN, G. Y AVDAN, U. Evaluating the utilization of the red edge and radar bands from sentinel sensors for wetland classification. *CATENA*, 2019/07/01/ 2019, 178, 109-119. doi:<https://doi.org/10.1016/j.catena.2019.03.011>

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

KHATRIKER, S. Y KUMAR, M. Building footprint extraction from high resolution satellite imagery using segmentation. *The International Archives of*

Photogrammetry, Remote Sensing and Spatial Information Sciences, 2018, 42, 123-128. doi:<https://doi.org/10.5194/isprs-archives-XLII-5-123-2018>

LABIB, S. M. Y HARRIS, A. The potentials of Sentinel-2 and LandSat-8 data in green infrastructure extraction, using object based image analysis (OBIA) method. European Journal of Remote Sensing, 2018/01/01 2018, 51(1), 231-240. doi:10.1080/22797254.2017.1419441

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>

LI, C., ZHANG, S., ZHANG, H., PANG, L., LAM, K., HUI, C. Y ZHANG, S. Using the K-Nearest Neighbor Algorithm for the Classification of Lymph Node Metastasis in Gastric Cancer. Computational and Mathematical Methods in Medicine, 2012/10/24 2012, 2012, 876545. doi:10.1155/2012/876545

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>

LIAN, L. Y CHEN, J. Research on Segmentation Scale of Multi-Resources Remote Sensing Data Based on Object-Oriented. Procedia Earth and Planetary Science, 2011/01/01/ 2011, 2, 352-357. doi:<https://doi.org/10.1016/j.proeps.2011.09.055>

LÓPEZ, S., LÓPEZ-SANDOVAL, M. F., GERIQUE, A. Y SALAZAR, J. Landscape change in Southern Ecuador: An indicator-based and multi-temporal evaluation of land use and land cover in a mixed-use protected area. Ecological Indicators, 2020/08/01/ 2020, 115, 106-357. doi:<https://doi.org/10.1016/j.ecolind.2020.106357>

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

MAMANI, E. M. Políticas de protección para los pueblos indígenas en situación de aislamiento: el caso de los mashco piro de Madre de Dios 2021. doi:<http://repositorio.unap.edu.pe/handle/UNAP/15661>

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.

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.

MOKHTAR, E. S., MAJID, M. A. A. A., NORMAN, M., ROSLANI, M. A., NASIRUN, N. Y MOHAMMAD, Z. Mangrove Area Delineation using Object-Based Classification on Sentinel-2 Imagery: Tuba Island, Langkawi. *IOP Conference Series: Earth and Environmental Science*, 2022/04/01 2022, 1019(1), 012019. doi:10.1088/1755-1315/1019/1/012019

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

NAIKOO, M. W., ISLAM, A. R. M. T., MALLICK, J. Y RAHMAN, A. Land use/land cover change and its impact on surface urban heat island and urban thermal comfort in a metropolitan city. *Urban Climate*, 2022, 41, 101052.

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

NIRO, F., GORYL, P., DRANSFELD, S., BOCCIA, V., GASCON, F., ADAMS, J., THEMANN, B., SCIFONI, S. Y DOXANI, G. European Space Agency (ESA) calibration/validation strategy for optical land-imaging satellites and pathway towards interoperability. Remote Sensing, 2021, 13(15), 3003.

NOVELLI, A., AGUILAR, M. A., NEMMAOUI, A., AGUILAR, F. J. Y TARANTINO, E. Performance evaluation of object based greenhouse detection from Sentinel-2 MSI and Landsat 8 OLI data: A case study from Almería (Spain). International Journal of Applied Earth Observation and Geoinformation, 2016/10/01/ 2016, 52, 403-411. doi:<https://doi.org/10.1016/j.jag.2016.07.011>

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.

PAUL, S. S. Analysis of land use and land cover change in Kiskatinaw River watershed: A remote sensing, GIS & modeling approach 2014.

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>

PIONTEKOWSKI, V. J., RIBEIRO, F. P., MATRICARDI, E. A. T., LUSTOSA, I. M., BUSSINGUER, A. P. Y GATTO, A. Modeling deforestation in the State of Rondonia. *Floresta e Ambiente*, 2019, 26. doi:<https://doi.org/10.1590/2179-8087.044118>

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>

QI, H., WU, Z., ZHANG, L., LI, J., ZHOU, J., JUN, Z. Y ZHU, B. Monitoring of peanut leaves chlorophyll content based on drone-based multispectral image feature extraction. *Computers and Electronics in Agriculture*, 2021/08/01/ 2021, 187, 106292. doi:<https://doi.org/10.1016/j.compag.2021.106292>

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.

RAISG. Destrucción del Amazonas: las principales amenazas para la mayor selva tropical del mundo en los 9 países que la comparten (2001-2018). 2022.

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>

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>

ROTETA, E., BASTARRIKA, A., PADILLA, M., STORM, T. Y CHUVIECO, E. Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. Remote Sensing of Environment, 2019/03/01/ 2019, 222, 1-17. doi:<https://doi.org/10.1016/j.rse.2018.12.011>

ROY, D. P., HUANG, H., BOSCHETTI, L., GIGLIO, L., YAN, L., ZHANG, H. H. Y LI, Z. Landsat-8 and Sentinel-2 burned area mapping - A combined sensor

multi-temporal change detection approach. *Remote Sensing of Environment*, 2019/09/15/ 2019, 231, 111254. doi:<https://doi.org/10.1016/j.rse.2019.111254>

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>

RUIZ, L. A., RECIO, J. A., FERNÁNDEZ-SARRÍA, A. Y HERMOSILLA, T. A feature extraction software tool for agricultural object-based image analysis. *Computers and Electronics in Agriculture*, 2011/05/01/ 2011, 76(2), 284-296. doi:<https://doi.org/10.1016/j.compag.2011.02.007>

SABINS JR, F. F. *Remote sensing--principles and interpretation*. Edition ed.: WH Freeman and company, 1987.

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.

SORIANO MARTINEZ, P. C. El proceso constitucional de la comunidad nativa Tres Islas y sus implicancias respecto a los derechos de los pueblos indígenas en el Perú 2022.

TARAZONA, Y. Y MIYASIRO-LÓPEZ, M. Monitoring tropical forest degradation using remote sensing. Challenges and opportunities in the Madre de Dios region, Peru. Remote Sensing Applications: Society and Environment, 2020/08/01/ 2020, 19, 100337. doi:<https://doi.org/10.1016/j.rsase.2020.100337>

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>

TRAGHEIM, D. G. Y SMITH, K. B. Evaluation of ENVI Feature Extraction for geological mapping in arid environments 2009.

TURNER, B. L., SKOLE, D., SANDERSON, S., FISCHER, G., FRESCO, L. Y LEEMANS, R. Land-use and land-cover change: science/research plan. [No source information available], 1995.

VAN DONINCK, J., WESTERHOLM, J., RUOKOLAINEN, K., TUOMISTO, H. Y KALLIOLA, R. Dating flowering cycles of Amazonian bamboo-dominated forests by supervised Landsat time series segmentation. International Journal of Applied Earth Observation and Geoinformation, 2020/12/01/ 2020, 93, 102196. doi:<https://doi.org/10.1016/j.jag.2020.102196>

VARGHESE, D., RADULOVIĆ, M., STOJKOVIĆ, S. Y CRNOJEVIĆ, V. Reviewing the potential of sentinel-2 in assessing the drought. Remote Sensing, 2021, 13(17), 3355. doi:<https://doi.org/10.3390/rs13173355>

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.

XIONG, Z., ZHANG, X., WANG, X. Y YUAN, J. Self-adaptive segmentation of satellite images based on a weighted aggregation approach. *GIScience & Remote Sensing*, 2019/02/17 2019, 56(2), 233-255. doi:10.1080/15481603.2018.1504413

YU, Y., GUAN, H., LI, D., GU, T., TANG, E. Y LI, A. Orientation guided anchoring for geospatial object detection from remote sensing imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020/02/01/ 2020, 160, 67-82. doi:<https://doi.org/10.1016/j.isprsjprs.2019.12.001>

ZHANG, C., YUE, P., TAPETE, D., SHANGGUAN, B., WANG, M. Y WU, Z. A multi-level context-guided classification method with object-based convolutional neural network for land cover classification using very high resolution remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, 2020/06/01/ 2020, 88, 102086. doi:<https://doi.org/10.1016/j.jag.2020.102086>

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

ZHAO, F., WU, X. Y WANG, S. Object-oriented Vegetation Classification Method based on UAV and Satellite Image Fusion. *Procedia Computer Science*, 2020/01/01/ 2020, 174, 609-615. doi:<https://doi.org/10.1016/j.procs.2020.06.132>

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 el área de estudio.

N.º	Categoria	Coordenadas UTM WGS84	
		Este	Norte
1	Áreas artificializados	481397	8608759
2	Áreas artificializados	481457	8609003
3	Áreas artificializados	481536	8608533
4	Áreas artificializados	483128	8609700
5	Áreas artificializados	482120	8609411
6	Áreas artificializados	481054	8609974
7	Áreas artificializados	483086	8609168
8	Áreas artificializados	482297	8608576
9	Áreas artificializados	481635	8608715
10	Áreas artificializados	481853	8609084
11	Áreas artificializados	482272	8609319
12	Áreas artificializados	481099	8640215
13	Áreas artificializados	483747	8642512
14	Áreas artificializados	483379	8642411
15	Áreas artificializados	483295	8642193
16	Áreas artificializados	483379	8642998
17	Áreas artificializados	483479	8643283
18	Áreas artificializados	487122	8660062
19	Áreas artificializados	486982	8660182
20	Áreas artificializados	486677	8659979
21	Áreas artificializados	486855	8659554
22	Áreas artificializados	487058	8658779
23	Áreas artificializados	486709	8659681
24	Áreas artificializados	486620	8659890
25	Áreas artificializados	487274	8660201
26	Áreas artificializados	487337	8660658
27	Áreas artificializados	487458	8660411
28	Áreas artificializados	487471	8660157
29	Áreas artificializados	487136	8662040
30	Áreas artificializados	487134	8661940
31	Áreas artificializados	487163	8661744
32	Áreas artificializados	487174	8661587
33	Áreas artificializados	487169	8661278
34	Áreas artificializados	487028	8662454
35	Áreas artificializados	487056	8662414
36	Áreas artificializados	487063	8662382
37	Áreas artificializados	487083	8662489
38	Áreas artificializados	488570	8664839
39	Áreas artificializados	488571	8664783
40	Áreas artificializados	488513	8664812

41	Áreas artificializados	488466	8664849
42	Áreas artificializados	488438	8664866
43	Áreas artificializados	488474	8664866
44	Áreas artificializados	488657	8664868
45	Áreas artificializados	488692	8664778
46	Áreas artificializados	488642	8664749
47	Áreas artificializados	488634	8664774
48	Áreas artificializados	485659	8668383
49	Áreas artificializados	485542	8669452
50	Áreas artificializados	485563	8669130
51	Áreas artificializados	485368	8670775
52	Áreas artificializados	485336	8671040
53	Áreas artificializados	487146	8680993
54	Áreas artificializados	486971	8680999
55	Áreas artificializados	487008	8680829
56	Áreas artificializados	486992	8680581
57	Áreas artificializados	486918	8680290
58	Áreas artificializados	487241	8680591
59	Áreas artificializados	487183	8680824
60	Áreas artificializados	487151	8680665
61	Áreas artificializados	487341	8680417
62	Áreas artificializados	487484	8680422
63	Áreas artificializados	487183	8680443
64	Áreas artificializados	486939	8680448
65	Áreas agrícolas	485018	8613766
66	Áreas agrícolas	487293	8615433
67	Áreas agrícolas	483774	8611385
68	Áreas agrícolas	485785	8617391
69	Áreas agrícolas	484727	8618079
70	Áreas agrícolas	488748	8616968
71	Áreas agrícolas	481896	8622709
72	Áreas agrícolas	482822	8623371
73	Áreas agrícolas	482107	8624270
74	Áreas agrícolas	483748	8624244
75	Áreas agrícolas	485415	8624164
76	Áreas agrícolas	485441	8625117
77	Áreas agrícolas	485044	8626519
78	Áreas agrícolas	484356	8626281
79	Áreas agrícolas	483086	8626307
80	Áreas agrícolas	481578	8625170
81	Áreas agrícolas	487928	8625805
82	Áreas agrícolas	487664	8625487
83	Áreas agrícolas	487426	8625090
84	Áreas agrícolas	485203	8625937
85	Áreas agrícolas	486526	8627445

86	Áreas agrícolas	484647	8628980
87	Áreas agrícolas	483536	8630461
88	Áreas agrícolas	486314	8631890
89	Áreas agrícolas	485494	8632816
90	Áreas agrícolas	487426	8632393
91	Áreas agrícolas	489145	8633187
92	Áreas agrícolas	483774	8635647
93	Áreas agrícolas	482875	8635991
94	Áreas agrícolas	479303	8636944
95	Áreas agrícolas	476789	8637499
96	Áreas agrícolas	477557	8638875
97	Áreas agrícolas	481102	8638081
98	Áreas agrícolas	481314	8639140
99	Áreas agrícolas	482689	8641468
100	Áreas agrícolas	484568	8642156
101	Áreas agrícolas	484303	8644061
102	Áreas agrícolas	483510	8644643
103	Áreas agrícolas	483695	8645252
104	Áreas agrícolas	484198	8646469
105	Áreas agrícolas	484250	8647315
106	Áreas agrícolas	485256	8648823
107	Áreas agrícolas	486261	8650834
108	Áreas agrícolas	487584	8650623
109	Áreas agrícolas	483430	8650887
110	Áreas agrícolas	475599	8638663
111	Áreas agrícolas	486579	8650517
112	Áreas agrícolas	486288	8655041
113	Áreas agrícolas	487082	8655385
114	Áreas agrícolas	486764	8656311
115	Áreas agrícolas	486685	8657793
116	Áreas agrícolas	490468	8660015
117	Áreas agrícolas	483642	8658375
118	Áreas agrícolas	480837	8655994
119	Áreas agrícolas	481023	8655041
120	Áreas agrícolas	497427	8661047
121	Áreas agrícolas	488722	8661603
122	Áreas agrícolas	487558	8662582
123	Áreas agrícolas	499120	8660333
124	Áreas agrícolas	487426	8665757
125	Áreas agrícolas	487082	8665439
126	Áreas agrícolas	485150	8664884
127	Áreas agrícolas	484065	8664751
128	Áreas agrícolas	485785	8666656
129	Áreas agrícolas	485044	8668165
130	Áreas agrícolas	487505	8667715

131	Áreas agrícolas	491024	8667133
132	Áreas agrícolas	491394	8667874
133	Áreas agrícolas	483166	8671710
134	Áreas agrícolas	482848	8672610
135	Áreas agrícolas	484674	8671816
136	Áreas agrícolas	486473	8672742
137	Áreas agrícolas	485044	8673324
138	Áreas agrícolas	484859	8674488
139	Áreas agrícolas	485203	8676076
140	Áreas agrícolas	482742	8677690
141	Áreas agrícolas	482742	8678854
142	Áreas agrícolas	484383	8679277
143	Áreas agrícolas	485679	8678801
144	Áreas agrícolas	488193	8678801
145	Áreas agrícolas	488325	8680441
146	Áreas agrícolas	489569	8680785
147	Áreas agrícolas	489278	8679383
148	Áreas agrícolas	488907	8677769
149	Áreas agrícolas	488987	8676340
150	Áreas agrícolas	492109	8679806
151	Áreas agrícolas	490759	8681182
152	Áreas agrícolas	491050	8682135
153	Áreas agrícolas	484118	8678960
154	Áreas agrícolas	481975	8677081
155	Bosques y áreas mayormente naturales	478840	8622749
156	Bosques y áreas mayormente naturales	478443	8624733
157	Bosques y áreas mayormente naturales	478575	8627114
158	Bosques y áreas mayormente naturales	477649	8627974
159	Bosques y áreas mayormente naturales	477252	8629363
160	Bosques y áreas mayormente naturales	477120	8630091
161	Bosques y áreas mayormente naturales	476657	8633266
162	Bosques y áreas mayormente naturales	479501	8634523
163	Bosques y áreas mayormente naturales	479898	8630422
164	Bosques y áreas mayormente naturales	481949	8631348
165	Bosques y áreas mayormente naturales	481486	8633663
166	Bosques y áreas mayormente naturales	486447	8621558
167	Bosques y áreas mayormente naturales	493921	8627445
168	Bosques y áreas mayormente naturales	493127	8629363
169	Áreas húmedas continentales	491871	8630885
170	Áreas húmedas continentales	490349	8634457
171	Áreas húmedas continentales	490018	8636243
172	Bosques y áreas mayormente naturales	487637	8639616
173	Bosques y áreas mayormente naturales	486777	8640740
174	Bosques y áreas mayormente naturales	488894	8643651
175	Bosques y áreas mayormente naturales	488762	8646098

176	Bosques y áreas mayormente naturales	483999	8648612
177	Bosques y áreas mayormente naturales	481552	8649538
178	Bosques y áreas mayormente naturales	479700	8648810
179	Bosques y áreas mayormente naturales	479634	8646231
180	Bosques y áreas mayormente naturales	480493	8644180
181	Bosques y áreas mayormente naturales	489754	8649075
182	Bosques y áreas mayormente naturales	492135	8647090
183	Bosques y áreas mayormente naturales	491143	8644841
184	Bosques y áreas mayormente naturales	485322	8657542
185	Bosques y áreas mayormente naturales	482412	8661973
186	Bosques y áreas mayormente naturales	480626	8664355
187	Bosques y áreas mayormente naturales	480560	8668588
188	Bosques y áreas mayormente naturales	491407	8662767
189	Bosques y áreas mayormente naturales	491804	8664553
190	Bosques y áreas mayormente naturales	488960	8667067
191	Bosques y áreas mayormente naturales	489225	8668985
192	Bosques y áreas mayormente naturales	488894	8670705
193	Bosques y áreas mayormente naturales	488299	8672491
194	Bosques y áreas mayormente naturales	487769	8675004
195	Bosques y áreas mayormente naturales	490746	8672887
196	Bosques y áreas mayormente naturales	490812	8676327
197	Bosques y áreas mayormente naturales	493458	8676261
198	Bosques y áreas mayormente naturales	493193	8678774
199	Bosques y áreas mayormente naturales	480626	8680031
200	Bosques y áreas mayormente naturales	481155	8675335
201	Bosques y áreas mayormente naturales	481486	8673020
202	Bosques y áreas mayormente naturales	482345	8668522
203	Bosques y áreas mayormente naturales	479104	8664685
204	Bosques y áreas mayormente naturales	493524	8659592
205	Bosques y áreas mayormente naturales	494979	8663825
206	Bosques y áreas mayormente naturales	494847	8666140
207	Bosques y áreas mayormente naturales	493193	8668191
208	Bosques y áreas mayormente naturales	496831	8668588
209	Bosques y áreas mayormente naturales	502322	8669646
210	Bosques y áreas mayormente naturales	493987	8680626
211	Bosques y áreas mayormente naturales	489995	8680981
212	Bosques y áreas mayormente naturales	487026	8677298
213	Bosques y áreas mayormente naturales	487709	8676980
214	Bosques y áreas mayormente naturales	489852	8677504
215	Bosques y áreas mayormente naturales	481343	8680425
216	Bosques y áreas mayormente naturales	481025	8680616
217	Bosques y áreas mayormente naturales	480470	8680521
218	Bosques y áreas mayormente naturales	480057	8680330
219	Bosques y áreas mayormente naturales	479311	8681029
220	Bosques y áreas mayormente naturales	482851	8680584

221	Bosques y áreas mayormente naturales	483581	8680902
222	Bosques y áreas mayormente naturales	482994	8679028
223	Bosques y áreas mayormente naturales	481311	8679965
224	Bosques y áreas mayormente naturales	481930	8677965
225	Bosques y áreas mayormente naturales	487375	8679235
226	Bosques y áreas mayormente naturales	489979	8679632
227	Bosques y áreas mayormente naturales	489899	8679155
228	Bosques y áreas mayormente naturales	490534	8679187
229	Bosques y áreas mayormente naturales	490455	8678473
230	Bosques y áreas mayormente naturales	489820	8677790
231	Bosques y áreas mayormente naturales	489375	8677282
232	Bosques y áreas mayormente naturales	489693	8676901
233	Bosques y áreas mayormente naturales	487439	8676631
234	Bosques y áreas mayormente naturales	482248	8675774
235	Bosques y áreas mayormente naturales	483518	8676536
236	Bosques y áreas mayormente naturales	485089	8667694
237	Áreas húmedas continentales	489860	8608178
238	Áreas húmedas continentales	489690	8607543
239	Áreas húmedas continentales	490855	8608199
240	Áreas húmedas continentales	486494	8611946
241	Áreas húmedas continentales	486494	8611353
242	Áreas húmedas continentales	485393	8610760
243	Áreas húmedas continentales	483277	8612623
244	Áreas húmedas continentales	483785	8615586
245	Áreas húmedas continentales	483827	8616243
246	Áreas húmedas continentales	484314	8616793
247	Áreas húmedas continentales	484102	8617174
248	Áreas húmedas continentales	482748	8619248
249	Áreas húmedas continentales	483256	8619650
250	Áreas húmedas continentales	483869	8608242
251	Áreas húmedas continentales	490516	8607755
252	Áreas húmedas continentales	491765	8608051
253	Bosques y áreas mayormente naturales	493670	8609046
254	Bosques y áreas mayormente naturales	493670	8608051
255	Bosques y áreas mayormente naturales	492950	8607310
256	Áreas húmedas continentales	492315	8610549
257	Áreas húmedas continentales	490728	8612369
258	Áreas húmedas continentales	489627	8612665
259	Áreas húmedas continentales	487023	8613195
260	Áreas húmedas continentales	488378	8613703
261	Áreas húmedas continentales	490050	8613893
262	Áreas húmedas continentales	483467	8620666
263	Áreas húmedas continentales	479382	8621428
264	Áreas húmedas continentales	478726	8620603
265	Áreas húmedas continentales	477541	8620920

266	Áreas húmedas continentales	475339	8617555
267	Áreas húmedas continentales	475022	8618169
268	Áreas húmedas continentales	488300	8651953
269	Áreas húmedas continentales	489557	8651721
270	Áreas húmedas continentales	490946	8651126
271	Áreas húmedas continentales	492368	8651721
272	Áreas húmedas continentales	494815	8652879
273	Áreas húmedas continentales	489391	8660750
274	Áreas húmedas continentales	491243	8660287
275	Áreas húmedas continentales	493757	8660750
276	Áreas húmedas continentales	494021	8661875
277	Áreas húmedas continentales	493492	8663760
278	Áreas húmedas continentales	496601	8657046
279	Áreas húmedas continentales	499247	8655756
280	Áreas húmedas continentales	478642	8660949
281	Áreas húmedas continentales	477816	8660684
282	Áreas húmedas continentales	484761	8659097
283	Áreas húmedas continentales	497362	8667001
284	Áreas húmedas continentales	498222	8667696
285	Áreas húmedas continentales	499809	8668456
286	Áreas húmedas continentales	502885	8668820
287	Áreas húmedas continentales	484606	8681641
288	Áreas húmedas continentales	484225	8681466
289	Áreas húmedas continentales	483130	8681736
290	Áreas húmedas continentales	482526	8681371
291	Áreas húmedas continentales	481193	8681578
292	Áreas húmedas continentales	480177	8681419
293	Áreas húmedas continentales	485003	8681244
294	Áreas húmedas continentales	485431	8680990
295	Áreas húmedas continentales	488797	8681419
296	Áreas húmedas continentales	490178	8682038
297	Áreas húmedas continentales	490416	8682863
298	Áreas húmedas continentales	491226	8683070
299	Áreas húmedas continentales	490702	8682467
300	Áreas húmedas continentales	490289	8682181
301	Áreas húmedas continentales	490940	8682752
302	Áreas húmedas continentales	491512	8682800
303	Áreas húmedas continentales	485400	8682213
304	Áreas húmedas continentales	485193	8681863
305	Áreas húmedas continentales	486209	8681308
306	Áreas húmedas continentales	485177	8680974
307	Áreas húmedas continentales	488797	8681419
308	Áreas húmedas continentales	489908	8681847
309	Áreas húmedas continentales	483892	8654447
310	Áreas húmedas continentales	483749	8654923

311	Áreas húmedas continentales	483701	8653558
312	Áreas húmedas continentales	482939	8653241
313	Áreas húmedas continentales	486670	8609949
314	Áreas húmedas continentales	486479	8609600
315	Áreas húmedas continentales	486162	8609822
316	Áreas húmedas continentales	485701	8608568
317	Áreas húmedas continentales	486035	8608378
318	Áreas húmedas continentales	485670	8608060
319	Áreas húmedas continentales	485225	8610267
320	Áreas húmedas continentales	482622	8611997
321	Áreas húmedas continentales	483606	8612982
322	Áreas húmedas continentales	483717	8610505
323	Áreas húmedas continentales	482399	8610775
324	Áreas húmedas continentales	483495	8608140
325	Áreas húmedas continentales	484177	8608267
326	Superficies de agua	477536	8619088
327	Superficies de agua	478256	8618982
328	Superficies de agua	478616	8619215
329	Superficies de agua	480022	8619567
330	Superficies de agua	480838	8619681
331	Superficies de agua	481579	8619258
332	Superficies de agua	482278	8618453
333	Superficies de agua	481918	8617374
334	Superficies de agua	481579	8616675
335	Superficies de agua	482024	8613077
336	Superficies de agua	483548	8614749
337	Superficies de agua	484034	8614622
338	Superficies de agua	483717	8614474
339	Superficies de agua	484140	8613966
340	Superficies de agua	482341	8607658
341	Superficies de agua	483759	8607298
342	Superficies de agua	484606	8607044
343	Superficies de agua	485883	8606596
344	Superficies de agua	487405	8606402
345	Superficies de agua	488564	8606579
346	Superficies de agua	489940	8606515
347	Superficies de agua	491189	8606833
348	Superficies de agua	492374	8607827
349	Superficies de agua	492967	8609161
350	Superficies de agua	493178	8610939
351	Superficies de agua	493284	8612018
352	Superficies de agua	499296	8616739
353	Superficies de agua	500354	8616612
354	Superficies de agua	501688	8616464
355	Superficies de agua	502831	8616210

356	Superficies de agua	504757	8614961
357	Superficies de agua	505730	8614114
358	Superficies de agua	514578	8620676
359	Superficies de agua	513922	8619744
360	Superficies de agua	513583	8618474
361	Superficies de agua	520547	8621967
362	Superficies de agua	519827	8623830
363	Superficies de agua	519552	8625015
364	Superficies de agua	519679	8626200
365	Superficies de agua	520589	8627618
366	Superficies de agua	522579	8620379
367	Superficies de agua	521224	8619914
368	Superficies de agua	520399	8621184
369	Superficies de agua	485696	8665982
370	Superficies de agua	485660	8665899
371	Superficies de agua	485418	8672256
372	Superficies de agua	486135	8681663
373	Superficies de agua	486027	8681834
374	Superficies de agua	485697	8682378
375	Superficies de agua	486783	8681248
376	Bosques y áreas mayormente naturales	478840	8681801
377	Bosques y áreas mayormente naturales	480184	8680531
378	Bosques y áreas mayormente naturales	480708	8680330
379	Bosques y áreas mayormente naturales	481835	8680150
380	Bosques y áreas mayormente naturales	481978	8680415
381	Bosques y áreas mayormente naturales	482036	8680087
382	Bosques y áreas mayormente naturales	482607	8679690
383	Bosques y áreas mayormente naturales	489137	8680886
384	Áreas húmedas continentales	474524	8617534

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. Pasturas.



Foto 7. Superficies de agua y áreas húmedas continentales.



Foto 8. Superficies de agua y áreas húmedas continentales.