

**INFORME N.º 00285-2022-OEFA/DEAM-STEC**

A	:	FRANCISCO GARCÍA ARAGÓN Director de Evaluación Ambiental
DE	:	LÁZARO WALTHER FAJARDO VARGAS Ejecutivo de la Subdirección Técnica Científica MARIELA BERENICE CABALLERO DEL CASTILLO Especialista en Evaluaciones Ambientales
ASUNTO	:	Clasificación de coberturas y cambio de uso en zonas de expansión agrícola de la Unidad Fiscalizable Fundo Zanja Seca administrado por Ocho Sur U SAC, en los distritos Nueva Requena y Curimana, provincias Coronel Portillo y Padre Abad, departamento Ucayali.
EXPEDIENTE DE EVALUACIÓN	:	033-2022-DEAM-EAF
CÓDIGO DE ACCIÓN	:	No Aplica
REFERENCIA	:	Memorando N.º 01272-2022-OEFA/DSAP
FECHA	:	Lima, 30 de setiembre de 2022

Tenemos el agrado de dirigirnos a usted para informarle lo siguiente:

1. INFORMACIÓN GENERAL**Tabla 1.1.** Datos generales de la actividad realizada

a.	Zona evaluada	Zonas de expansión agrícola de la Unidad Fiscalizable Fundo Zanja Seca
b.	Unidades fiscalizables en la zona de estudio o actividades económicas	Unidad Fiscalizable Fundo Zanja Seca
c.	Problemática identificada	Necesidad de identificar coberturas para el periodo 2020-2022 dentro de la unidad fiscalizable e identificar coberturas y cambio de uso en los periodos 2019-2020, 2020-2021 y 2021-2022 en zonas fronterizas a la unidad fiscalizable, así como identificar componentes que no lograron ser identificados en el análisis de imágenes satelitales mediante levantamiento fotogramétrico con RPAS como apoyo en la supervisión ambiental de la unidad fiscalizable Fundo Zanja Seca.
d.	Motivo de la actividad	Memorando N.º 01272-2022-OEFA/DSAP
e.	Tipo de evaluación	Evaluación ambiental focal
f.	Periodo de ejecución	15 al 20 de agosto de 2022

Profesionales que aportaron a este documento:

Tabla 1.2. Listado de profesionales

N.º	Nombres y Apellidos	Profesión	Actividad desarrollada	N.º de Colegiatura
1	Lázaro Walther Fajardo Vargas	Ingeniero químico	Gabinete	CIP 33273
2	Mariela Berenice Caballero del Castillo	Bióloga	Gabinete	CBP 4896
3	Lourdes Liseth Espinoza Quiroz	Ingeniera Geógrafa	Gabinete	CIP 235285
4	Marco Antonio Miranda Valiente	Ingeniero Ambiental	Campo y Gabinete	CIP 180884



N.º	Nombres y Apellidos	Profesión	Actividad desarrollada	N.º de Colegiatura
5	Xiomara Solanch Mandujano Reyes	Ingeniera Ambiental	Campo y Gabinete	CIP 233811

2. ANTECEDENTES

Mediante el Memorando N.º 01272-2022-OEFA/DSAP la Dirección de Supervisión Ambiental en Actividades Productivas (DSAP) solicitó a la Dirección de Evaluación Ambiental (DEAM) la colaboración técnica para realizar un estudio que permita; i) identificar y determinar áreas de cambio de cobertura mediante análisis multitemporal de imágenes satelitales dentro de la unidad fiscalizable Fundo Zanja Seca (2020-2022); ii) identificar y determinar áreas de cambio de cobertura en las zonas fronterizas a la unidad fiscalizable Fundo Zanja Seca mediante el análisis de imágenes satelitales, así como estimar su clasificación y extensión en tres periodos de análisis (2019-2020, 2020-2021 y 2021-2022); y, iii) capturar mediante levantamiento fotogramétrico con sistema de aeronave pilotada de forma remota (en adelante, RPAS¹) componentes que no lograron ser identificados con el análisis de imágenes satelitales dentro de la unidad fiscalizable Fundo Zanja Seca de la empresa Ocho Sur U SAC (en adelante, UFFZS), ubicada en los distritos Nueva Requena y Curimana, provincias Coronel Portillo y Padre Abad, departamento Ucayali.

En el acta de inicio N.º AI-036-2022-ITEGI se definieron los alcances y propuesta para atención del estudio de análisis de imágenes satelitales, análisis multitemporal y levantamiento fotogramétrico con RPAS en la zona de expansión agrícola de la UFFZS (Anexo 1).

Los detalles de la planificación para Identificar y determinar áreas de cambio de coberturas en el periodo 2020-2022 mediante el análisis multitemporal de imágenes satelitales dentro de la UFFZS, identificar áreas de cambio de cobertura en las zonas fronterizas a la UFFZS en tres (3) periodos de análisis (2019-2020, 2020-2021 y 2021-2022) mediante el análisis multitemporal de imágenes satelitales, y capturar mediante levantamiento fotogramétrico con RPAS componentes que no lograron ser identificados con el análisis de imágenes satelitales dentro de la UFFZS, se encuentran detallados en el plan de estudio N.º PE-031-2022-ITEGI (Anexo 2).

El análisis de teledetección inició actividades el 01 de agosto de 2022 de acuerdo a lo establecido por en el plan de estudio y del 15 al 20 de agosto de 2022, el personal designado por la DEAM (Memorando N° 00457-2022-OEFA/DEAM) realizó el acompañamiento a la supervisión ambiental en el cual se ejecutó el levantamiento fotogramétrico con RPAS para la validación e identificación de componentes que no lograron ser identificados con el análisis de imágenes satelitales dentro del área de la UFFZS; dicha actividad fue registrada en el reporte de campo RC-034-2022-ITEGI (Anexo 3).

Posteriormente se procesaron los datos obtenidos en campo y se generaron los reportes de software de procesamiento fotogramétrico N° RSPF-0133-2022-ITEGI y ° RSPF-0134-2022-ITEGI, en el cual se detallan los resultados del Ortomosaico RGB y modelo de elevación digital (Anexo 4).

¹ Del inglés Remotely Piloted Aircraft System (RPAS). Conjunto de elementos configurables integrado por una nave pilotada a distancia, sus estaciones de piloto remoto conexas, los necesarios enlaces de mando y control, y cualquier otro elemento de sistema que pueda requerirse en cualquier punto durante la operación de vuelo. Resolución Directoral N.º 501-2015-MTC/12: Norma Técnica Complementaria: «Requisitos para las operaciones de Sistemas de Aeronaves Pilotadas a Distancia».



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

3. OBJETIVOS

3.1 Objetivo general

Identificar clases de coberturas y determinar la extensión del cambio de coberturas, dentro del área de estudio y en zonas fronterizas de la Unidad Fiscalizable Fundo Zanja Seca, mediante técnicas de teledetección espacial² y levantamiento fotogramétrico con RPAS.

3.2 Objetivos específicos

- Identificar y determinar áreas de cambio de coberturas en el periodo 2020-2022 mediante el análisis multitemporal de imágenes satelitales dentro de la UFFZS.
- Identificar áreas de cambio de cobertura en las zonas fronterizas a la UFFZS en tres (3) periodos de análisis (2019-2020, 2020-2021 y 2021-2022) mediante el análisis multitemporal de imágenes satelitales, así como estimar sus extensiones como apoyo para la evaluación de la continuidad de dicha unidad.
- Generar un Ortomosaico RGB de los componentes que no lograron ser identificados con el análisis de imágenes satelitales dentro de la UFFZS mediante levantamiento fotogramétrico con RPAS.

4. ÁREA DE ESTUDIO

El área de estudio se ubica en los distritos Nueva Requena y Curimana, provincias Coronel Portillo y Padre Abad, departamento Ucayali, en la cual se encuentra la UFFZS (Figura 4.1).

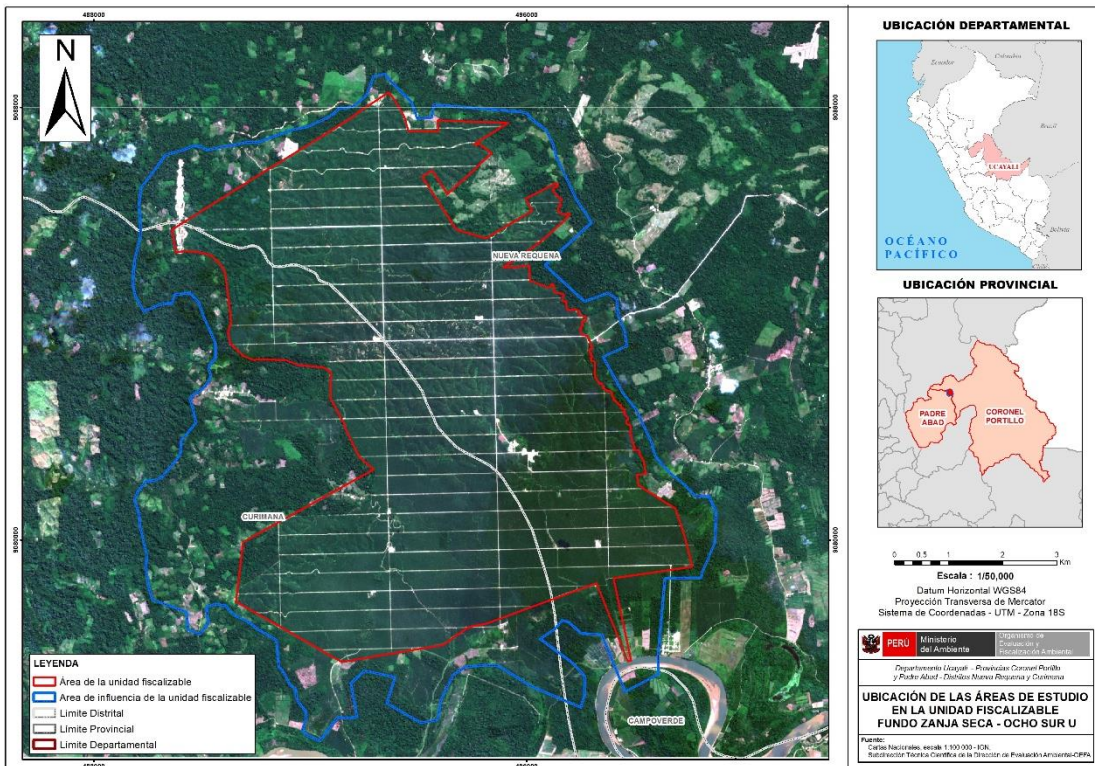


Figura 4.1. Ubicación de las áreas de estudio de la UFFZS.

² Técnica que nos permite obtener información a distancia de los objetos situados sobre la superficie terrestre. (Chuvieco, 2010)



5. METODOLOGÍA

La metodología empleada para identificar clases de coberturas y determinar la extensión del cambio de uso en las áreas de estudio de la UFFZS, tiene como base el manual técnico «Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales», que establece criterios técnicos para la generación de información agraria mediante el uso de la teledetección espacial, y se complementó utilizando herramientas de geoprocésamiento para el tratamiento de la información georreferenciada, como se describe a continuación.

5.1. Guía utilizada para la evaluación ambiental

La guía utilizada para identificar clases de coberturas y determinar la extensión del cambio de uso en el área de estudio de la UFFZS se detalla en la Tabla 5.1.

Tabla 5.1. Referencias empleadas

Guía	Sección	País	Institución/autor	Año
Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales	Toda la guía	Perú	MIDAGRI	2018

5.2. Procesamiento metodológico

El procedimiento metodológico se realizó de manera semi-automatizada para identificar las clases de cobertura y calcular las extensiones de las áreas de cambios por período de análisis, en las áreas de estudio de la UFFZS. El procesamiento se realizó en dos (2) etapas, la primera consistió en la clasificación de coberturas del año 2022 (año base), y la segunda en la detección y clasificación sólo de los segmentos de cambio, manteniendo las demás áreas constantes en los periodos 2019-2020, 2020-2021 y 2021-2022 (Figura 5.1 y Figura 5.2).

Se eligió el método de segmentación de la imagen empleado por MINAGRI (2018), el cual consiste en dividir la imagen en agrupaciones de píxeles vecinos (formados en base a valores espectrales, espaciales y/o de texturas similares), a estas agrupaciones se les denomina segmentos. El algoritmo empleado permitió regular el tamaño de los segmentos, su forma y el grado de compactación.

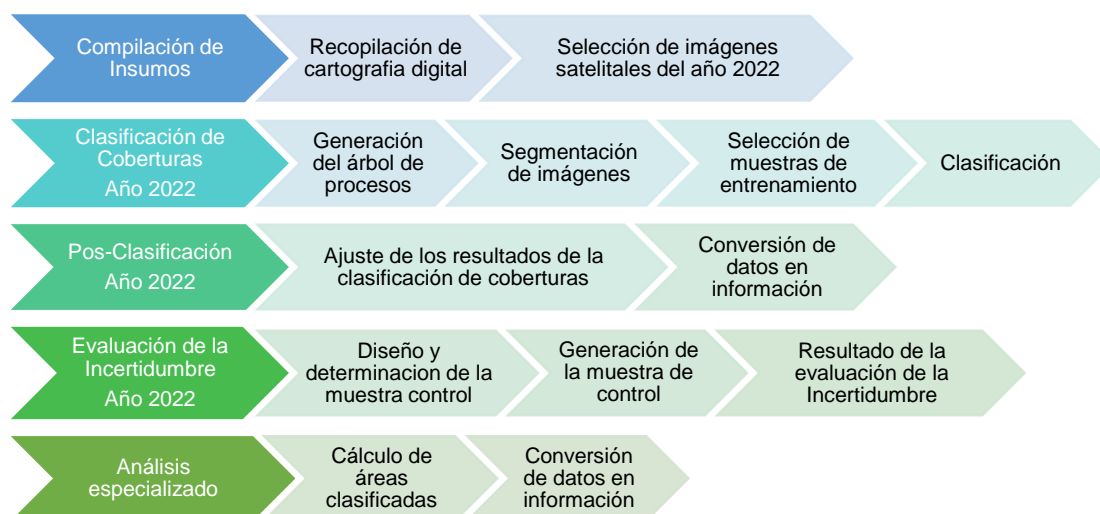


Figura 5.1. Esquema de la metodología semi-automatizada para la clasificación de coberturas para el año 2022.

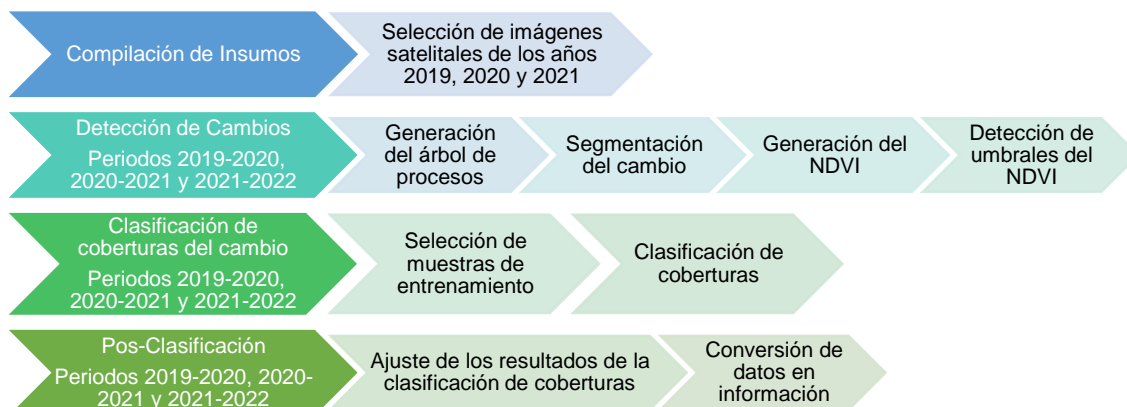


Figura 5.2. Esquema de la metodología semi-automatizada para la detección y clasificación de cambios de cobertura para los periodos 2019-2020, 2020-2021 y 2021-2022.

5.3. Clasificación de coberturas del año 2022

5.3.1. Compilación de insumos

a. Recopilación de cartografía digital

La cartografía digital utilizada como insumo para el presente estudio se detalla en la Tabla 5.2.

Tabla 5.2. Cartografía digital utilizada como insumo para la clasificación

Institución	Cartografía Digital
Ocho Sur P SAC	Límites de la UFFZS
OEFA - DSAP	Límites de áreas de estudios

b. Selección de imágenes satelitales

Para la selección de imágenes satelitales disponibles para el área de estudio se empleó la plataforma de *Google Earth Engine*³ y se consultó la colección de imágenes satelitales de la misión Sentinel 2A, las cuales se encuentran disponibles de forma gratuita y poseen una buena resolución espacial y espectral conveniente para los objetivos del estudio, como se muestra en la Tabla 5.3.

Tabla 5.3. Característica de las imágenes satelitales Sentinel 2A

Sentinel-2 Bandas	Longitud de onda (µm)	Resolución (m)
Banda 1 - <i>Coastal aerosol</i>	0,443	60
Banda 2 - <i>Blue</i>	0,490	10
Banda 3 - <i>Green</i>	0,560	10
Banda 4 - <i>Red</i>	0,665	10
Banda 5 - <i>Vegetation Red Edge</i>	0,705	20
Banda 6 - <i>Vegetation Red Edge</i>	0,740	20
Banda 7 - <i>Vegetation Red Edge</i>	0,783	20
Banda 8 - <i>NIR</i>	0,842	10
Banda 8A - <i>Narrow NIR</i>	0,865	20
Banda 9 - <i>Water vapour</i>	0,945	60
Banda 10 - <i>SWIR – Cirrus</i>	1,375	60

³ Google Earth Engine es una plataforma que aloja imágenes de satélite y las almacena en un archivo de datos público que incluye imágenes históricas de la Tierra que se remontan a más de cuarenta años. (Google, 2019)



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

Table with 3 columns: Sentinel-2 Bandas, Longitud de onda (µm), Resolución (m). Rows include Banda 11 - SWIR and Banda 12 - SWIR.

Las escenas fueron seleccionadas teniendo en consideración tres (3) criterios: El primer criterio es la fecha en la que fue tomada la imagen satelital, siendo de prioridad la más reciente; el segundo criterio es que la imagen satelital sea de nivel 2A (imagen ortorectificada y corregida atmosféricamente); por último, el tercer criterio es que la imagen satelital tenga el menor porcentaje de cobertura de nubes sobre el área de interés, en la medida que se pueda disponer de la mayor cantidad de datos en el área de estudio.

Para la descarga de las imágenes satelitales seleccionadas dentro del entorno de la plataforma de Google Earth Engine, se empleó el siguiente código:

```
//Definición de "geometry"
var table = ee.FeatureCollection("users/OEFA_DSAP_OCHOSURU"),
    geometry =
    /* color: #d63000 */
    /* shown: false */
    /* displayProperties: [
    {
    "type": "rectangle"
    }
    ] */
    ee.Geometry.Polygon(
    [[[-75.12799828958762, -8.23213868036145],
    [-75.12799828958762, -8.359197847106486],
    [-74.98551934671653, -8.359197847106486],
    [-74.98551934671653, -8.23213868036145]]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection('COPERNICUS/S2_SR')
    .filterBounds(geometry)
    .filterDate('2022-08-23','2022-08-25')
    .filterMetadata('CLOUDY_PIXEL_PERCENTAGE','Less_Than',30);
var SentinelFiltro = ee.Image(IMGSentinel.median());
var SentinelClip = SentinelFiltro.clip(geometry);
//Imprimimos la lista de imágenes disponibles en la pestaña de Console
print(SentinelFiltro);
//Añadimos la imagen a la vista haciendo una composición de colores y asignando un nombre de etiqueta en la vista
Map.addLayer(SentinelClip, {
    max: 5000.0,
    min: 0.0,
    gamma: 1.2,
    bands: ['B4','B3','B2'],
    'Capa Sentinel');
// exportar
Export.image.toDrive({
    image: SentinelClip.select("B2","B3", "B4", "B8"),
    description: '2022_OchosurU_BOA',
    scale: 10,
    region: geometry});
```



5.3.2. Clasificación de coberturas del año 2022

a. Generación del árbol de procesos

Para la generación del árbol de procesos se empleó el software *eCognition Developer 10.1 Trial*⁴ (Figura 5.3), donde se creó la siguiente secuencia de procesos:

- Segmentación; configurando el algoritmo de *Multiresolution Segmentation* en el cual se asignó los parámetros de tamaño, escala, forma y peso.
- Importación de muestras; configurando el *Assing Class Thematic Layer* cuya función fue asignar clases al proyecto y *Classified Objects Samples* para vincular las muestras con los segmentos. Las muestras se crearon previamente mediante el software ArcGIS⁵.
- Clasificación con los algoritmos de *Classifier* utilizando el método de *Random Forest*.



Figura 5.3. Regla de procesos para la clasificación de coberturas en el software *eCognition Developer 10.1 Trial*.

Como apoyo para la clasificación se seleccionaron las métricas utilizadas en las segmentaciones (NDVI, NDWI, SAVI y ratios).

⁴ Programa especializado para la clasificación de objetos.
⁵ Programa especializado en geoprocasamientos



Índice de vegetación diferenciada normalizada (NDVI)

Conocido como NDVI por sus siglas en inglés (*Normalized difference vegetation index*). Es un indicador de la salud de la vegetación. Esto quiere decir que la degradación o disminución de vigorosidad en el ecosistema ocasionados por factores externos refleja un valor bajo en el NDVI.

Se calcula a partir de mediciones de reflectancia de la siguiente manera:

$$NDVI = (NIR-RED) / (NIR+RED)$$

Dónde:

NDVI = Índice Normalizado de Vegetación

NIR = Reflectancia en la banda del infrarrojo cercano

RED = Reflectancia en la banda roja del visible

Índice diferencial de agua normalizado (NDWI)

Conocido como NDWI por sus siglas en inglés (*Normalized differential water index*). Es un indicador el cual podemos identificar masas de agua y zonas de elevada saturación de humedad por medio del análisis de imágenes satélite. De esta forma podemos emplear el índice como unidad de medida para determinar el estrés hídrico en vegetación, saturación de humedad en suelo.

Se calcula a partir de mediciones de reflectancia de la siguiente manera:

$$NDWI = (GREEN-RED) / (GREEN+ NIR)$$

Dónde:

NDWI = Índice Diferencial de Agua Normalizado

NIR = Reflectancia en la banda del infrarrojo cercano

RED = Reflectancia en la banda roja del visible

GREEN = Reflectancia en la banda verde del visible

Índice de vegetación ajustado al suelo (SAVI)

Conocido como SAVI por sus siglas en inglés (*Soil Adjusted Vegetation Index*). Es el índice de vegetación que se ajusta al suelo, en comparación al NDVI, ajusta la reflectancia del suelo.

Se calcula a partir de mediciones de reflectancia de la siguiente manera:

$$SAVI = ((NIR-RED) / (NIR+RED+L))*(1+L)$$

Dónde:

SAVI = Índice de Vegetación Ajustado del Suelo

NIR = Reflectancia en la banda del infrarrojo cercano

RED = Reflectancia en la banda roja del visible

L= Factor encargado de amortiguar la presencia del suelo



Ratios

Son expresiones algebraicas que son de apoyo en la interpretación de la clasificación.

Asimismo, se consideró la selección de las bandas B4-RED y B8-NIR como parte de los insumos para la clasificación, ya que con estas bandas se pueden diferenciar las especies vegetales, delimitar cuerpos de agua, y suelos.

b. Segmentación de imágenes

Para la selección de objetos, fue necesario agrupar información relevante eliminando el efecto de píxeles aislados. El software *eCognition Developer 10.1 Trial* calcula las características de cada segmento, tales como:

- Desviación estándar y mediana.
- Textura (muchos tipos).
- Extensión (por ejemplo: área, longitud, ancho, etc.).
- Forma (por ejemplo: redondo, asimétrico, compacto, etc.).
- Relaciones con los segmentos vecinos (diferencia media con los vecinos).

El proceso de segmentación se configuró utilizando el algoritmo *Multiresolution Segmentation* bajo los siguientes criterios:

- Pesos de las bandas de la imagen; el cual ajusta la cantidad de influencia que tiene cada banda de la imagen en la segmentación. Para ello se utilizaron las bandas B4-RED y B8-NIR, colocándole los valores de 2, y a las demás bandas el valor 1.
- Parámetro de Escala; el cual determina el tamaño del segmento basándose en una medida de varianza (espectral y de forma). Estos segmentos crecen hasta alcanzar el umbral de varianza del parámetro de escala.
- Parámetro de Forma; el cual modifica el tipo de varianza determinada en la escala, el umbral varía de 0 a 0,9 donde:
 - 0 = La varianza es estrictamente espectral
 - 0,9 = La varianza hace referencia principalmente a la forma
- Parámetro de Compactibilidad; el cual modifica el parámetro de Forma (varianza de forma), variando el umbral de 0 a 1. A medida que se aumenta el umbral de forma la compactibilidad también aumenta.

Para realizar la segmentación se configuraron los siguientes parámetros: *Escale Parameter* = 40, *Shape* = 0,1 y *Compactness* = 1 (Figura 5.4).



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

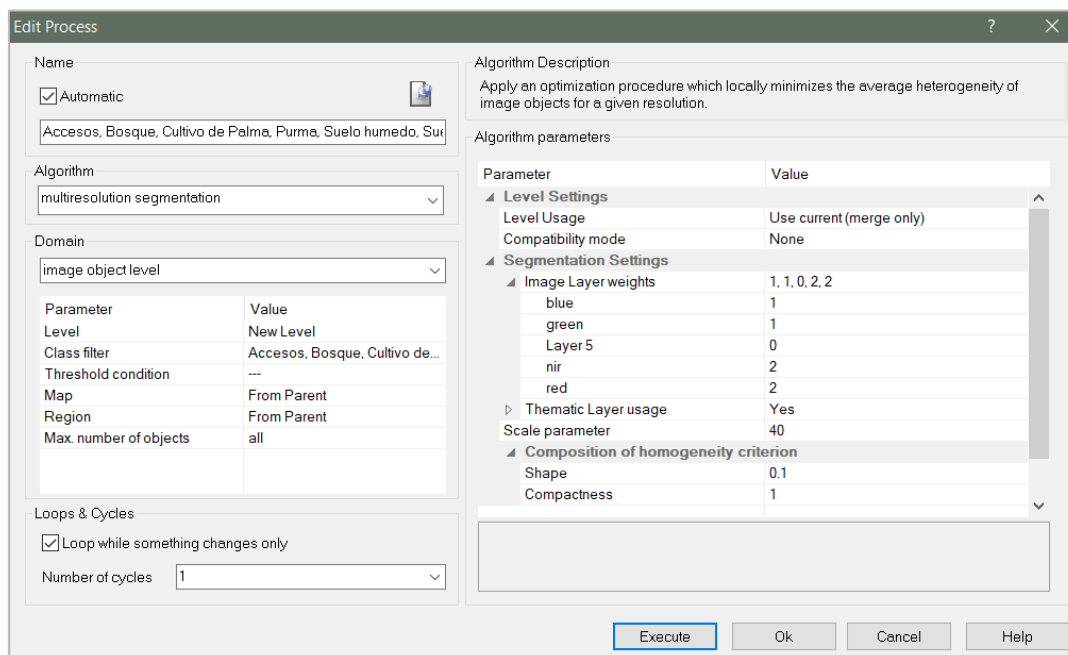
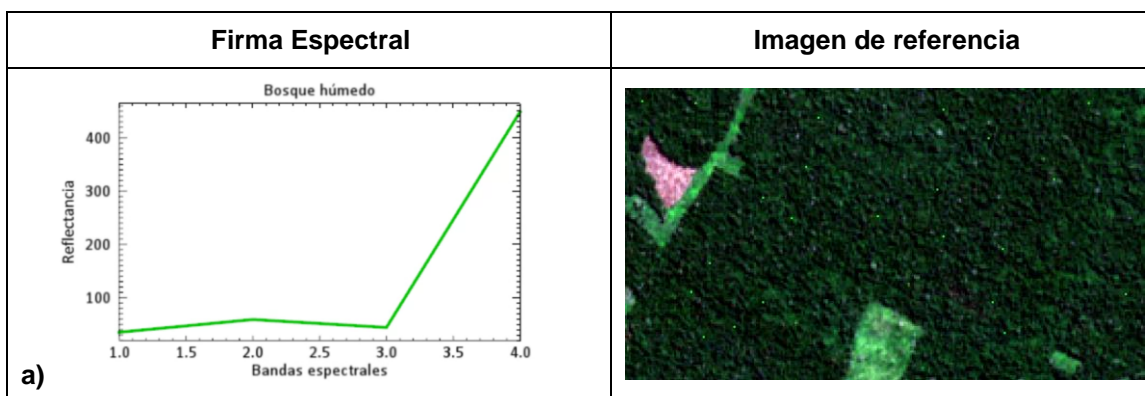


Figura 5.4. Resultado de la configuración de parámetros para la segmentación en eCognition Developer 10.1 Trial.

c. Selección de muestras de entrenamiento

La segmentación generó una preclasificación de clases de cobertura, la cual se afinó en base a información secundaria y con apoyo de la fotointerpretación de las imágenes satelitales. En base a ello se definieron siete (7) clases de cobertura: (1) Bosque húmedo, (2) cultivo de palma, (3) suelo húmedo, (4) suelo seco, (5) purma, (6) accesos y (7) cuerpos de agua. Cabe precisar que otros cultivos y las infraestructuras fueron clasificados mediante interpretación visual, por ende, no cuenta con firma espectral ni muestras de entrenamiento.

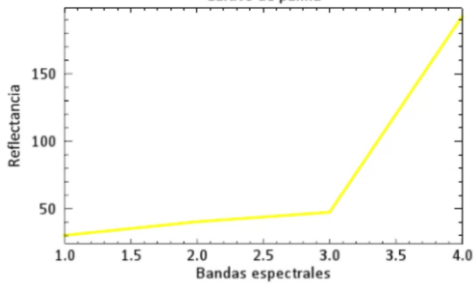

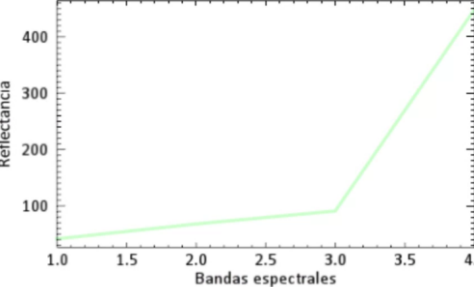

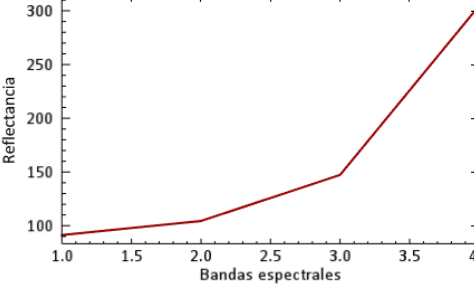

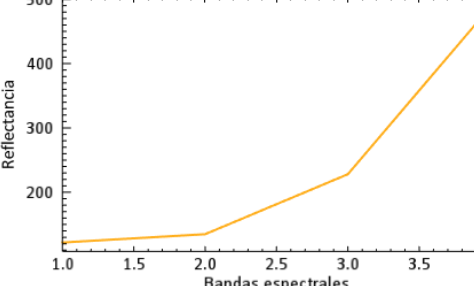

Para la generación de las muestras de entrenamiento, con el software ArcGIS, se generó una capa de puntos (archivo *Shapefile*) agrupados según las siete (7) clases definidas y descritas en sus respectivos atributos. Posteriormente con el software Envi 5.3⁶ se verificó que las muestras seleccionadas cuentan con la firma espectral característica de cada clase de cobertura, como se detalla en la Figura 5.5. Luego se procedió con la importación del archivo *Shapefile* de las muestras de entrenamiento al inicio de la configuración de las reglas de proceso.



⁶ Programa especializado para el tratamiento digital de imágenes satelitales.



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

Firma Espectral	Imagen de referencia																
<p data-bbox="245 667 272 696">b)</p>  <table border="1"><caption>Data for Cultivo de palma</caption><thead><tr><th>Bandas espectrales</th><th>Reflectancia</th></tr></thead><tbody><tr><td>1.0</td><td>20</td></tr><tr><td>1.5</td><td>30</td></tr><tr><td>2.0</td><td>40</td></tr><tr><td>2.5</td><td>45</td></tr><tr><td>3.0</td><td>50</td></tr><tr><td>3.5</td><td>100</td></tr><tr><td>4.0</td><td>180</td></tr></tbody></table>	Bandas espectrales	Reflectancia	1.0	20	1.5	30	2.0	40	2.5	45	3.0	50	3.5	100	4.0	180	
Bandas espectrales	Reflectancia																
1.0	20																
1.5	30																
2.0	40																
2.5	45																
3.0	50																
3.5	100																
4.0	180																
<p data-bbox="245 1057 272 1086">c)</p>  <table border="1"><caption>Data for Purma</caption><thead><tr><th>Bandas espectrales</th><th>Reflectancia</th></tr></thead><tbody><tr><td>1.0</td><td>30</td></tr><tr><td>1.5</td><td>50</td></tr><tr><td>2.0</td><td>70</td></tr><tr><td>2.5</td><td>80</td></tr><tr><td>3.0</td><td>90</td></tr><tr><td>3.5</td><td>250</td></tr><tr><td>4.0</td><td>420</td></tr></tbody></table>	Bandas espectrales	Reflectancia	1.0	30	1.5	50	2.0	70	2.5	80	3.0	90	3.5	250	4.0	420	
Bandas espectrales	Reflectancia																
1.0	30																
1.5	50																
2.0	70																
2.5	80																
3.0	90																
3.5	250																
4.0	420																
<p data-bbox="245 1473 272 1503">d)</p>  <table border="1"><caption>Data for Suelo húmedo</caption><thead><tr><th>Bandas espectrales</th><th>Reflectancia</th></tr></thead><tbody><tr><td>1.0</td><td>90</td></tr><tr><td>1.5</td><td>100</td></tr><tr><td>2.0</td><td>110</td></tr><tr><td>2.5</td><td>130</td></tr><tr><td>3.0</td><td>150</td></tr><tr><td>3.5</td><td>220</td></tr><tr><td>4.0</td><td>300</td></tr></tbody></table>	Bandas espectrales	Reflectancia	1.0	90	1.5	100	2.0	110	2.5	130	3.0	150	3.5	220	4.0	300	
Bandas espectrales	Reflectancia																
1.0	90																
1.5	100																
2.0	110																
2.5	130																
3.0	150																
3.5	220																
4.0	300																
<p data-bbox="245 1886 272 1915">e)</p>  <table border="1"><caption>Data for Suelo seco</caption><thead><tr><th>Bandas espectrales</th><th>Reflectancia</th></tr></thead><tbody><tr><td>1.0</td><td>100</td></tr><tr><td>1.5</td><td>120</td></tr><tr><td>2.0</td><td>140</td></tr><tr><td>2.5</td><td>180</td></tr><tr><td>3.0</td><td>230</td></tr><tr><td>3.5</td><td>350</td></tr><tr><td>4.0</td><td>480</td></tr></tbody></table>	Bandas espectrales	Reflectancia	1.0	100	1.5	120	2.0	140	2.5	180	3.0	230	3.5	350	4.0	480	
Bandas espectrales	Reflectancia																
1.0	100																
1.5	120																
2.0	140																
2.5	180																
3.0	230																
3.5	350																
4.0	480																

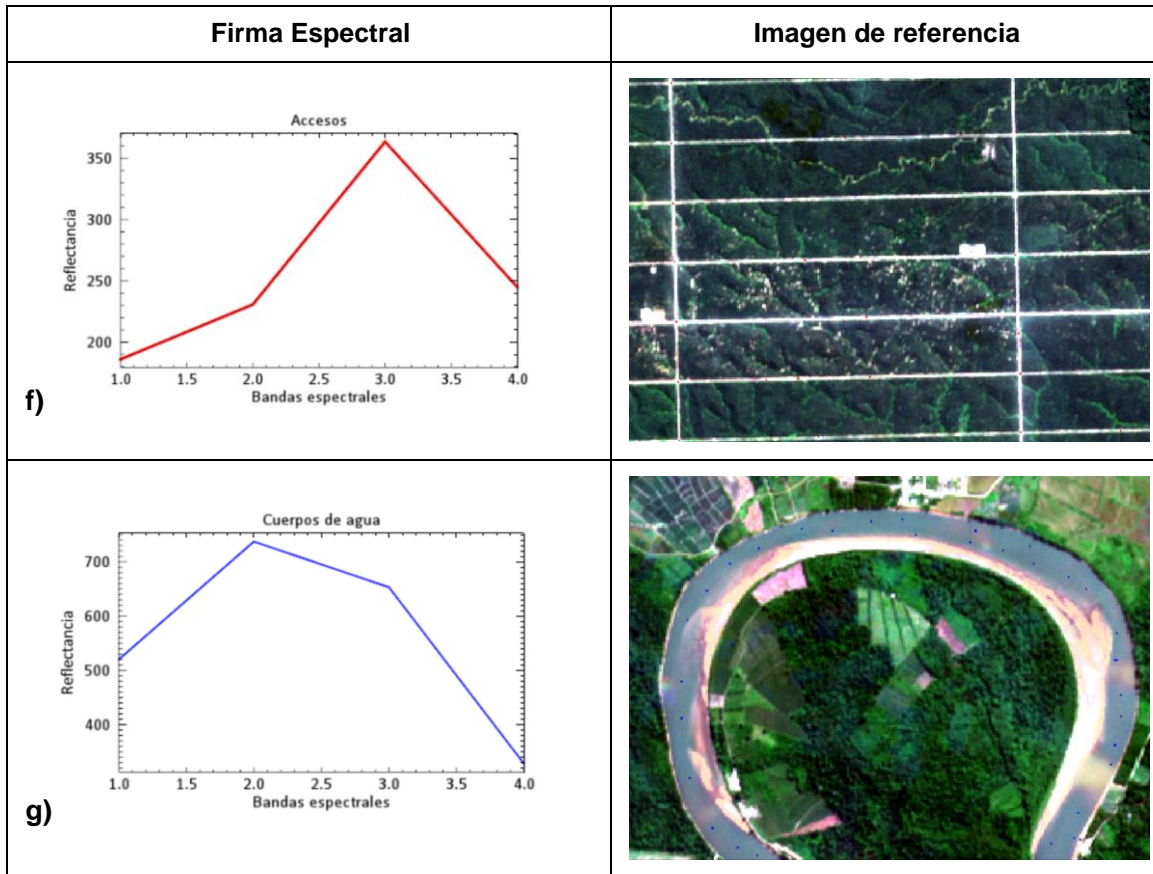


Figura 5.5. Firmas espectrales de las clases identificadas: a) Bosque húmedo, b) Cultivo de palma, c) Purma, d) Suelo húmedo, e) Suelo seco, f) Accesos y g) Cuerpos de agua

d. Clasificación de coberturas

En el *Árbol de Procesos*⁷ se configuraron los parámetros del algoritmo de clasificación que permitieron interactuar con las muestras de entrenamiento. Se introdujeron los índices y ratios, así como las medianas de las bandas B4-RED y B8-NIR con la finalidad de aportar en la discriminación de las coberturas y obtener mejores resultados en la clasificación.

i. Creación de clases:

En el software *eCognition Developer 10.1 Trial* se creó un proceso y se configuró el algoritmo *Assign Class by Thematic Layer*, el cual permite relacionar los atributos de las muestras de entrenamiento y crear las clases (jerarquía de las clases), ver Figura 5.6.

⁷ Es la ventana creada por *eCognition Developer 10.1 Trial* donde se escriben conjuntos de reglas en base a funciones. Los conjuntos de reglas son una combinación de procesos individuales, que se muestran en el árbol de procesos y se crean mediante el cuadro de diálogo.



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

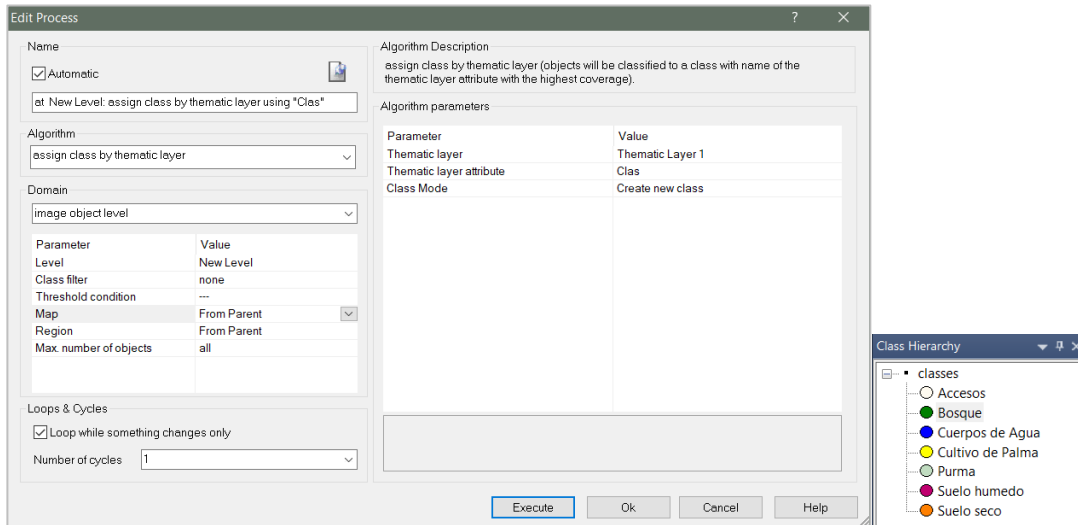


Figura 5.6. Relación de atributos y creación de clases

ii. Asignación de clases a los segmentos:

Posteriormente en el software *eCognition Developer 10.1 Trial* se configuró el algoritmo *Classified Image Objects to Samples*, el cual convierte las muestras de entrenamiento de puntos a segmentos, relacionando los atributos y asignándole las clases, generando finalmente las muestras a nivel de segmento.

iii. Clasificación mediante la aplicación del algoritmo *Random Forest*

Para la clasificación de imágenes se utilizó el algoritmo *Random Forest* el cual es un clasificador que produce múltiples árboles de decisiones. Estos árboles se crean en base a la selección aleatoria de un subconjunto de muestras y variables de entrenamiento mediante un enfoque de *bagging*. Esto quiere decir que la misma muestra puede ser seleccionada en los subconjuntos varias veces, mientras que otras pueden no ser seleccionada en lo absoluto. Se emplea alrededor de dos tercios de las muestras para entrenar a los árboles y el tercio restante se emplean en una técnica de validación cruzada para estimar que tan bien funciona el modelo de *random forest*. La clasificación final se da en base al promedio de las probabilidades de la asignación de clases calculadas por todos los árboles producidos. Cada árbol de decisión vota por una etiqueta de clase. La etiqueta con el máximo de votos será la que se seleccione finalmente (Belgiu & Drăgu, 2016; Breiman, 2001).

En el software *eCognition Developer 10.1 Trial* se configuró el algoritmo *Classifier* usando como clasificador el *Random Trees*. Se seleccionaron las muestras de entrenamiento, así como los valores de las medianas de las bandas de la imagen (RED y NIR) y de los índices generados (NDVI, NDWI, SAVI y ratios) que influyen en la clasificación, tal como muestra la Figura 5.7.

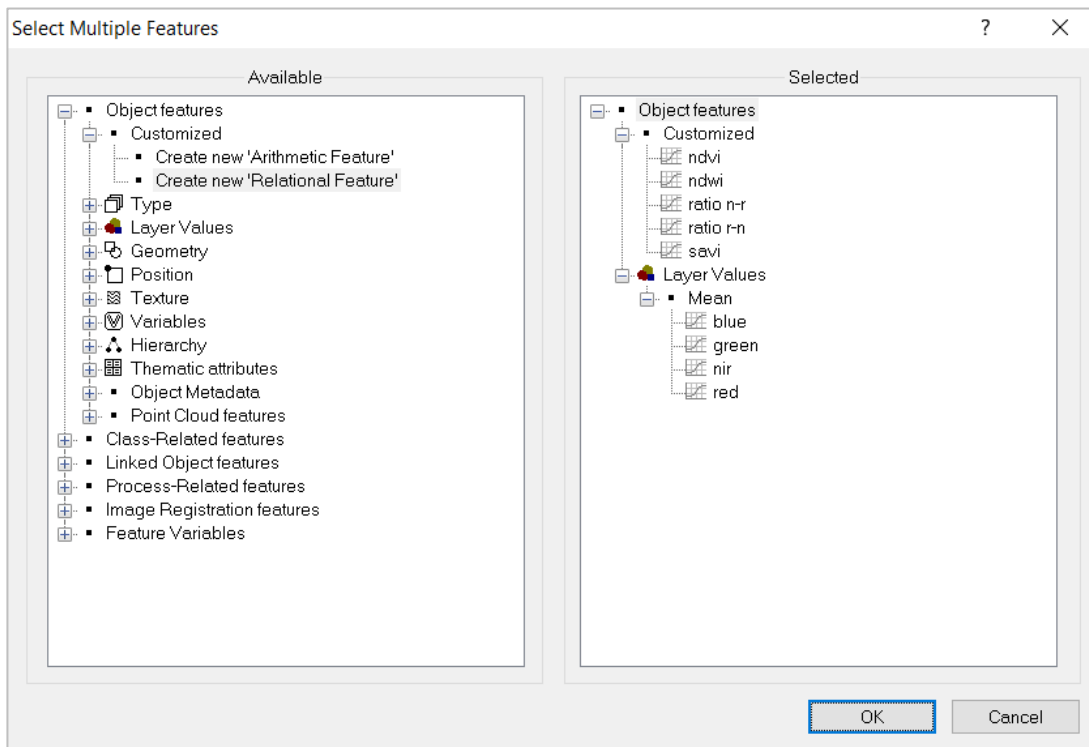


Figura 5.7. Ventana de *Select Múltiple Feature*, permite agregar parámetros e índices a la clasificación

Se escogió como clasificador el algoritmo *Random Forest* indicando que el número de iteraciones sea 500, tal como muestra la Figura 5.8.

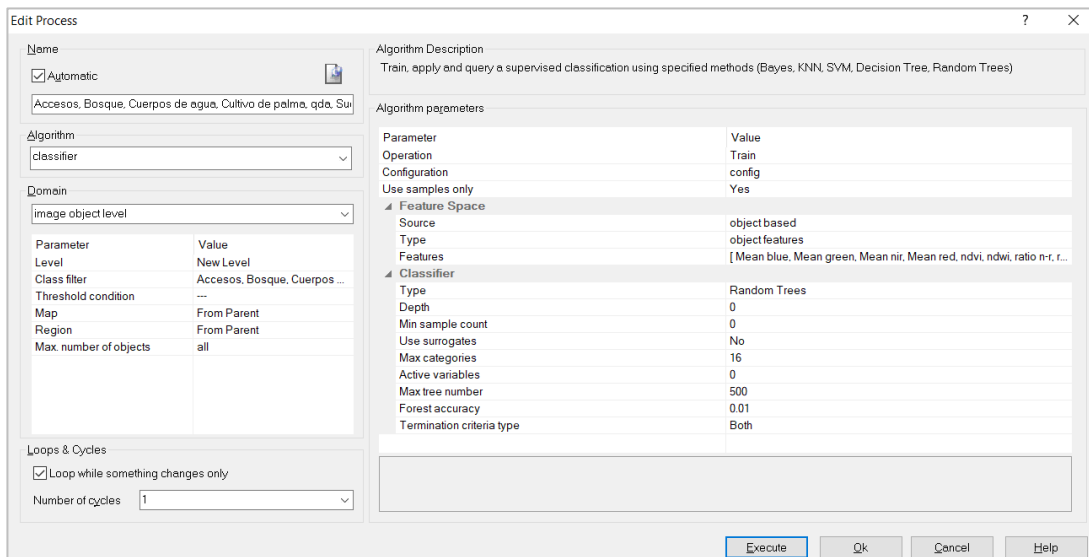


Figura 5.8. Configuración del clasificador del algoritmo *Random Forest*

Posteriormente se configuró un nuevo algoritmo *Classifier* indicando que la operación deberá aplicarse, tal como muestra la Figura 5.9.

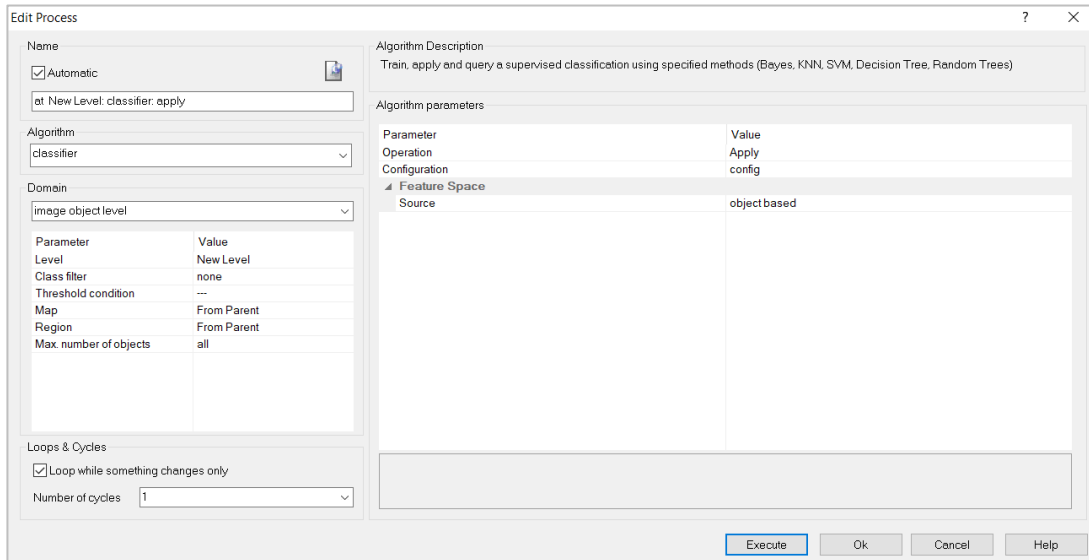


Figura 5.9. Configuración de la aplicación del algoritmo Classifier

5.3.3. Pos-Clasificación del año 2022

a. Ajuste de los resultados de la clasificación de coberturas

Sobre los resultados de la clasificación de coberturas se realizó un ajuste manual en las zonas que presentaron imperfecciones propias del procesamiento por clasificaciones erróneas. Este pos-procesamiento se realizó mediante la técnica de la fotointerpretación. Para ello se utilizó el *software eCognition Developer 10.1 Trial* y se realizaron los siguientes pasos:

- Selección de la clasificación y la clase a ajustar.
- Selección automática de polígonos de píxeles menores a 5 con la herramienta *Manual Editing Tool*.
- Traslado de polígonos seleccionados a la nueva clase con la herramienta *classify image objects*.

b. Conversión de datos en información

Para la conversión de datos en información se emplearon herramientas de geoprocésamiento del *software ArcGIS*, se realizaron los siguientes pasos:

- Vectorización del ráster de clases de cobertura mediante la aplicación de la herramienta *raster to polygon*.
- Cálculo de áreas (en hectáreas) mediante la aplicación de la herramienta *calculate geometry*.

5.3.4. Evaluación de incertidumbre de la clasificación de coberturas del año 2022

Se determinó el porcentaje de confianza del mapa mediante la exactitud global de las categorías de cobertura para el área de estudio de la UFFZS, para lo cual se realizó una validación espacial estadística utilizando como insumo imágenes de mejor resolución (imágenes de RPAS) y se complementó con Imágenes de Google Earth Pro, así como fichas de validación de campo. Se consideró para la incertidumbre las clases con mayor extensión.



a. Diseño y determinación de la muestra control

Para el diseño de la muestra de control se procedió utilizar la Matriz Aleatoria Estratificado (en adelante, MAE) pues es flexible en la distribución de las muestras en las clases de cobertura (Olofsson, Foody, Stehman, & Woodcock, 2013).

Para determinar el tamaño de muestra utilizando la MAE se consideró los siguientes parámetros:

- La variable de interés a muestrear
- Los estratos utilizados
- La unidad mínima de muestreo (UMM)
- La información a priori de los parámetros para la estimación de las varianzas y
- Los supuestos de confiabilidad y precisión.

Como parte del proceso en determinar el tamaño de muestra se requiere poner información a priori de las precisiones de Usuario (U_i) a nivel de subcategoría (Olofsson et al., 2014). Se requiere que el intérprete defina con criterio de experto en función a la eficiencia de los clasificadores. Es necesario fijar la confiabilidad del muestreo al 95% ($\alpha=0,95$) y a la precisión total de omisión ($S(O)$) permitiendo un error de estimación del 0,01%.

Una vez definida el uso de la MAE como diseño muestral se procedió a estimar el tamaño de muestra (Tabla 5.4) siguiendo conceptualmente a este diseño y orientándose en la propuesta de Olofsson (2013), para ello se procedió de la siguiente manera:

1. Se definirá conceptualmente la estructura de la matriz de confusión del mapa traslapado entre tiempo 1 y el 2, la cual incluya las áreas (o número total de píxeles) de los estratos y sus pesos ($W_i = \frac{\text{areasclase}}{\text{totaldelarea}}$)
2. Después, se asignará un valor de precisión de omisión (U_i) por estrato (este valor es determinado por el experto de acuerdo al trabajo de clasificación).
3. Posteriormente, se calculará para cada estrato la desviación estándar de la precisión de usuario (S_i) con:

$$S_i = \sqrt{U_i(1 - U_i)}$$

4. Una vez calculada S_i , se fijará el nivel de confiabilidad de la estimación de la precisión total con un 95% y un error del 1% $S(O) = 0,1$.
5. Finalmente, se calculará el tamaño total de la muestra bajo un MAE (Cochran, 1977):

$$n = \frac{(\sum W_i S_i)^2}{S(O)^2 + (1/N) \sum W_i S_i^2}$$

Donde:

W_i = Peso de cada clase con respecto al total del área de estudio

S_i = Desviación estándar de la precisión de usuario del estrato i (definida previamente)

U_i = Precisión de usuario del estrato i (tomada como dato a priori)

N = Área total o número total de píxeles.

$S(O)$ = Precisión total de omisión

Tabla 5.4. Estimación del tamaño de muestra

Clase	Área (ha)	W_i	U_i	S_i	$W_i S_i$
Bosque húmedo	2.209,68	0,248	0,04	0,196	0,049
Cultivo de Palma	4.855,97	0,545	0,00	0,055	0,030



«Decenio de la igualdad de oportunidades para mujeres y hombres»

«Año del fortalecimiento de la soberanía nacional»

«Año del bicentenario del Congreso de la República del Perú»

Clase	Área (ha)	W_i	U_i	S_i	$W_i S_i$
Purma	1.011,45	0,114	0,58	0,494	0,056
Suelo húmedo	253,99	0,029	0,60	0,490	0,014
Suelo seco	138,33	0,016	0,70	0,458	0,007
Accesos	365,46	0,041	0,90	0,300	0,012
Cuerpos de agua	38,51	0,004	0,90	0,300	0,001
Infraestructura	15,82	0,002	0,90	0,300	0,001
Otros cultivos	13,78	0,002	0,90	0,300	0,000
Total	8902,99				0,170

De acuerdo con la distribución de muestra al interior de los estratos influye en las estimaciones de la precisión global del mapa de coberturas. Bajo una matriz aleatoria estratificada, el cual la asignación óptica favorece a la estimación de la precisión total y de las áreas de referencia (Stehman, 2013). Por lo que la cantidad de puntos totales corresponden a la suma de $(W_i S_i)/S_i$ elevado al cuadrado resultó una muestra de doscientos ochenta y ocho (288).

b. Generación de la muestra de control

Luego de que se tuvo definida el tamaño de muestra total de doscientos ochenta y ocho (288), se procedió a la distribución entre las clases del mapa de coberturas 2022 del área de estudio de la UFFZS (Figura 5.10). Para este caso se aplicó una distribución proporcional a las áreas, teniendo en cuenta que algunas clases quedaran sin puntos de validación. Por ende, las clases de coberturas Cuerpos de Agua, Infraestructura y otros cultivos, no serán parte de la estimación de la incertidumbre. (Tabla 5.5)

Tabla 5.5. Distribución de la muestra

Clase	W_i	U_i	S_i	Distribución proporcional	Distribución uniforme	Distribución final
Bosque húmedo	0,248	0,04	0,196	71,5	32,0	72
Cultivo de palma	0,545	0,00	0,055	157,2	32,0	157
Purma	0,114	0,58	0,494	32,7	32,0	33
Suelo húmedo	0,029	0,60	0,490	8,2	32,0	8
Suelo seco	0,016	0,70	0,458	4,5	32,0	6
Accesos	0,041	0,90	0,300	11,8	32,0	12
Cuerpos de agua	0,004	0,90	0,300	1,2	32,0	-
Infraestructura	0,002	0,90	0,300	0,5	32,0	-
Otros cultivos	0,002	0,90	0,300	0,4	32,0	-
Total				288	288	288



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

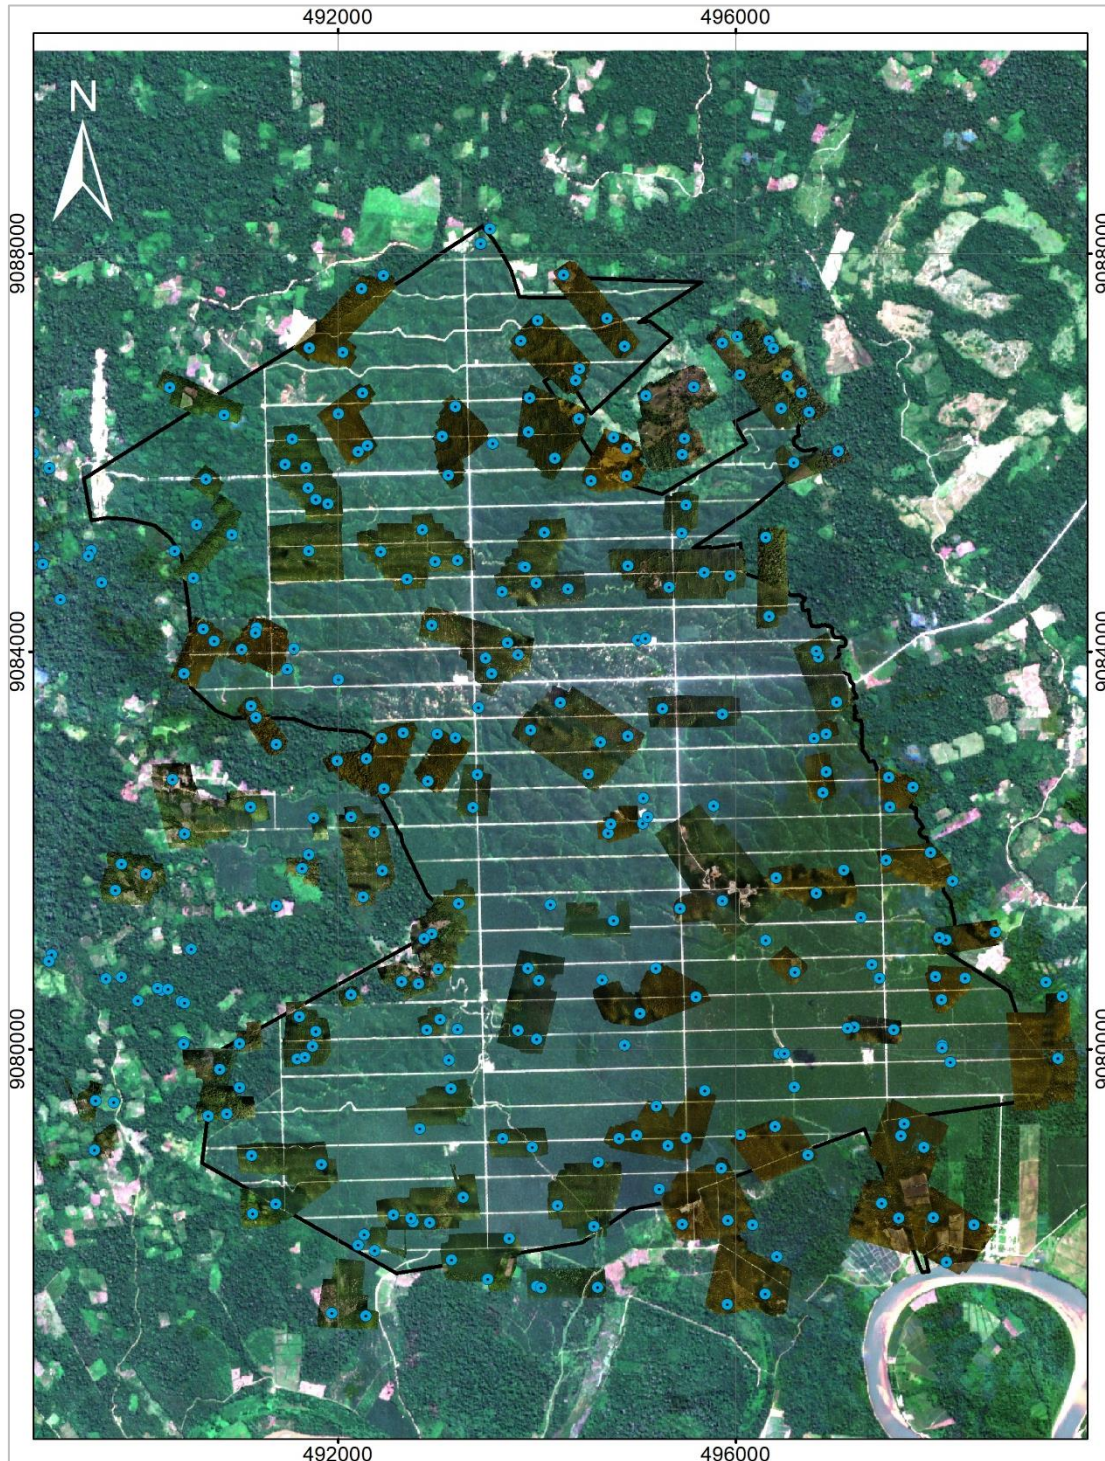


Figura 5.10. Distribución de los pixeles de validación

c. Validación de campo con imágenes RPAS

Una vez obtenido el tamaño y distribución de la muestra, se procedió a levantar información de puntos en campo, el cual consistió en la captura de imágenes de alta resolución con RPAS, lo cual consistió en:

- Generar ortomosaicos RGB de alta resolución de grupos de puntos de validación, los cuales fueron sobrevolados mediante levantamiento fotogramétrico con RPAS.



- Generar fichas de validación de campo con información general (punto de validación, responsable, departamento, provincia, distrito, fecha y hora) y descripción de la ubicación del punto (coordenadas, datum, descripción de la cobertura predominante en dicho punto y códigos de fotografías).

Lo descrito se encuentra con mayor detalle en el Reporte de Campo N.º RC-0034-2022-ITEGI (Anexo 3), en el reporte de procesamiento de software fotogramétrico N.º RSPF-0133-2022-ITEGI (Anexo 4) y la Ficha de puntos de validación del Mapa de Cobertura y Uso 2022 de la Unidad Fiscalizable Fundo Zanja Seca (Anexo 5).

d. Evaluación de incertidumbre

Para el cálculo del error de la clasificación obtenida, se utilizó la matriz de confusión, de acuerdo con Comber et al (2012) y Ariza et al (2018), la matriz de confusión se aplica como un estándar para informar sobre la exactitud y la calidad temática de cualquier producto derivado de la teledetección espacial. En esta matriz se contabiliza el grado de semejanza entre: un conjunto de datos bajo control y un conjunto de datos de referencia.

Este último corresponde a los datos de muestreo que se han seleccionado previamente, los cuales representan la realidad del terreno. El grado de certeza se verá reflejado en las celdas de la diagonal la cual contiene las cantidades correspondientes a los ítems bien clasificados, es decir donde hay una coincidencia; mientras que las cantidades fuera de esta diagonal representan los errores o la no coincidencia.

A partir de la matriz de confusión se deducen índices relativos a la exactitud de la clasificación, a través del *software Envi 5.3* se analizó el comportamiento y exactitud de dicha clasificación. Los resultados de la matriz se exponen en la Tabla 5.6.

Tabla 5.6. Matriz de confusión

CLASES	Bosque Húmedo	Cultivos de Palma	Purma	Suelo Seco	Suelo Húmedo	Accesos	Infraestructura	Total
Bosque Húmedo	72	1	0	0	0	0	0	73
Cultivos de Palma	0	161	0	0	0	1	0	162
Purma	0	2	25	0	0	0	2	29
Suelo Seco	0	0	0	3	0	0	0	3
Suelo Húmedo	0	0	0	0	7	0	0	7
Accesos	0	0	0	0	0	14	0	14
Total	72	164	25	3	7	15	2	288

Hay dos versiones de resultados equivalentes en la matriz; la primera, cuyas entradas se expresan en píxeles y la segunda en que se expresan como porcentajes. Los elementos en negro de la diagonal indican los píxeles que fueron correctamente clasificados. Todos los elementos fuera de la diagonal indican errores de omisión o de comisión. Los errores de omisión corresponden a los elementos no diagonales de las columnas.

A partir de la matriz de confusión se calculó la exactitud global, dividiendo el número total de píxeles correctamente clasificados por el número total de píxeles de referencia y expresándolo como porcentaje. En el presente estudio se obtuvo:

$$\text{Exactitud global} = (282/288) * 100 = 97,91\%$$



Cabe precisar que este índice es global y no nos indica cómo la exactitud se reparte entre las diversas categorías individuales.

Luego de calcular la matriz de confusión se usó el coeficiente de kappa (K) para definir la exactitud, según Congalton (1991), este coeficiente sirve también para medir la exactitud de un mapa, pero de forma más precisa que la matriz de confusión puesto que mide la diferencia entre la exactitud lograda en la clasificación con un clasificador automático y la chance de lograr una clasificación correcta con un clasificador aleatorio. Asimismo, incluye dentro del cálculo todos los valores de la matriz y no solamente sus extremos.

El coeficiente kappa se define como:

$$K = (\text{exactitud observada} - \text{chance de acierto}) / (1 - \text{chance de acierto})$$

Mediante la siguiente fórmula computarizada:

$$K = \frac{N \sum_{i=1}^r (x_{ii}) - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 \sum_{i=1}^r (x_{i+} * x_{+i})}$$

Donde:

r = Número de filas en la matriz

x_{ii} = Número de observaciones en el elemento de la fila i y la columna i (es decir sobre la diagonal mayor)

x_{i+} = Total de observaciones en la fila i (es el total marginal a la derecha de la matriz)

x_{+i} = Total de observaciones en la columna i (es el total marginal al pie de la matriz)

N = Número total de observaciones incluidas en la matriz

El valor de K varía usualmente entre 0 y 1, como se muestra en la Tabla 5.7.

Tabla 5.7. Valoración del coeficiente de Kappa

Coeficiente de Kappa (k)	Fuerza de concordancia
0,00	Pobre
0,01 – 0,20	Leve
0,21 – 0,40	Aceptable
0,41 – 0,60	Moderada
0,61 – 0,80	Considerable
0,81 – 1,00	Casi perfecta

Fuente: Protocolo de Evaluación de la Exactitud temática del Mapa de deforestación (MINAM)

Para el presente estudio, el coeficiente kappa resultó 0,97 que se encuentra en el rango de fuerza de concordancia «Casi perfecta».

5.4. Detección y clasificación de cambios de coberturas para los periodos 2019-2020, 2020-2021 y 2021-2022

5.4.1. Compilación de insumos

a. Selección de imágenes satelitales

En esta sección se describe la selección de imágenes satelitales para los años 2019, 2020 y 2021, ya que la imagen satelital seleccionada para el año 2019 se encuentra descrita en la sección b del subtítulo 5.3.1.



Para los años 2019, 2020 y 2021, se trabajó con escenas de imágenes satelitales de las misiones Sentinel 2A, las cuales están disponibles de forma gratuita.

Las escenas fueron seleccionadas teniendo en consideración tres (3) criterios: El primer criterio es la fecha en la que fue tomada la imagen satelital; el segundo criterio es que la imagen satelital sea de nivel 2A (imagen ortorectificada y corregida atmosféricamente); por último, el tercer criterio es que la imagen satelital tenga el menor porcentaje de cobertura de nubes sobre el área de interés, en la medida que se pueda disponer de la mayor cantidad de datos en el área de estudio.

Para la descarga de las imágenes satelitales para el año 2019, 2020 y 2021, seleccionadas dentro del entorno de la plataforma de *Google Earth Engine*, se empleó el siguiente código:

```
//Definición de "geometry"
var table = ee.FeatureCollection("users/OEFA_DSAP_OCHOSURU"),
    geometry =
    /* color: #d63000 */
    /* shown: false */
    /* displayProperties: [
    {
    "type": "rectangle"
    }
    ] */
    ee.Geometry.Polygon(
    [[[-75.12799828958762, -8.23213868036145],
    [-75.12799828958762, -8.359197847106486],
    [-74.98551934671653, -8.359197847106486],
    [-74.98551934671653, -8.23213868036145]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2_SR')
    .filterBounds (geometry)
    .filterDate ('2019-09-17','2019-09-19')
    .filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);
var SentinelFiltro = ee.Image(IMGSentinel.median());
var SentinelClip = SentinelFiltro.clip (geometry);
//Imprimimos la lista de imágenes disponibles en la pestaña de Console
print (SentinelFiltro);
//Añadimos la imagen a la vista haciendo una composición de colores y asignando un nombre de etiqueta en la vista
Map.addLayer (SentinelClip, {
    max: 5000.0,
    min: 0.0,
    gamma: 1.2,
    bands: ['B4','B3','B2']],
    'Capa Sentinel');
// exportar
Export.image.toDrive({
    image: SentinelClip.select("B2","B3", "B4", "B8"),
    description: '2019_OchosurU_BOA',
    scale: 10,
    region: geometry});
```

```
//Definición de "geometry"
var table = ee.FeatureCollection("users/OEFA_DSAP_OCHOSURU"),
```



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

```

geometry =
/* color: #d63000 */
/* shown: false */
/* displayProperties: [
  {
    "type": "rectangle"
  }
] */
ee.Geometry.Polygon(
[[[-75.12799828958762, -8.23213868036145],
  [-75.12799828958762, -8.359197847106486],
  [-74.98551934671653, -8.359197847106486],
  [-74.98551934671653, -8.23213868036145]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2_SR')
.filterBounds (geometry)
.filterDate ('2020-08-27','2020-08-29')
.filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);
var SentinelFiltro = ee.Image(IMGSentinel.median());
var SentinelClip = SentinelFiltro.clip (geometry);
//Imprimimos la lista de imágenes disponibles en la pestaña de Console
print (SentinelFiltro);
//Añadimos la imagen a la vista haciendo una composición de colores y asignando un nombre de etiqueta en la vista
Map.addLayer (SentinelClip, {
  max: 5000.0,
  min: 0.0,
  gamma: 1.2,
  bands: ['B4','B3','B2'],
  'Capa Sentinel');
// exportar
Export.image.toDrive({
  image: SentinelClip.select("B2","B3", "B4", "B8"),
  description: '2020_OchosurU_BOA',
  scale: 10,
  region: geometry});

```

```

//Definición de "geometry"
var table = ee.FeatureCollection("users/OEFA_DSAP_OCHOSURU"),
geometry =
/* color: #d63000 */
/* shown: false */
/* displayProperties: [
  {
    "type": "rectangle"
  }
] */
ee.Geometry.Polygon(
[[[-75.12799828958762, -8.23213868036145],
  [-75.12799828958762, -8.359197847106486],
  [-74.98551934671653, -8.359197847106486],
  [-74.98551934671653, -8.23213868036145]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2_SR')
.filterBounds (geometry)

```



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

```
.filterDate ('2021-08-07','2021-08-09)
.filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);
var SentinelFiltro = ee.Image(IMGSentinel.median());
var SentinelClip = SentinelFiltro.clip (geometry);
//Imprimimos la lista de imágenes disponibles en la pestaña de Console
print (SentinelFiltro);
//Añadimos la imagen a la vista haciendo una composición de colores y asignando un nombre de etiqueta en la vista
Map.addLayer (SentinelClip, {
max: 5000.0,
min: 0.0,
gamma: 1.2,
bands: ['B4','B3','B2']],
'Capa Sentinel');
// exportar
Export.image.toDrive({
image: SentinelClip.select("B2","B3", "B4", "B8"),
description: '2021_OchosurU_BOA',
scale: 10,
region: geometry});
```

Finalmente, en la Tabla 5.8 se enlista un resumen de las imágenes satelitales usadas para el presente estudio.

Tabla 5.8. Resumen de imágenes satelitales usadas

Table with 5 columns: Año, Sensor, Fecha de captura, Tipo de descarga, Nivel de tratamiento. Rows for years 2019, 2020, and 2021.

5.4.1 Detección de cambios

a. Generación del árbol de procesos

Para la generación del árbol de procesos se empleó el software eCognition Developer 10.1 Trial (Figura 5.11), siendo necesario generar una secuencia de procesos que contenga lo siguiente:

- Segmentación; configurando el algoritmo de Multiresolution Segmentation en el cual se asignan los parámetros de tamaño, escala, forma y peso.
• Detección de Cambios, configurando el algoritmo de assing class y definiendo los valores de los parámetros del NDVI para detectar los cambios ocurridos.
• Importación de muestras; configurando el Assing Class Thematic Layer cuya función es asignar clases al proyecto y Classified Objects Samples para vincular las muestras con los segmentos.
• Clasificación usando los algoritmos de; assing class thematic layer cuya función es asignar clases al proyecto, classified objects samples que permite relacionar las clases de las muestras con los segmentos de detección de cambios y, el algoritmo classifier usando el método de Random Forest.



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

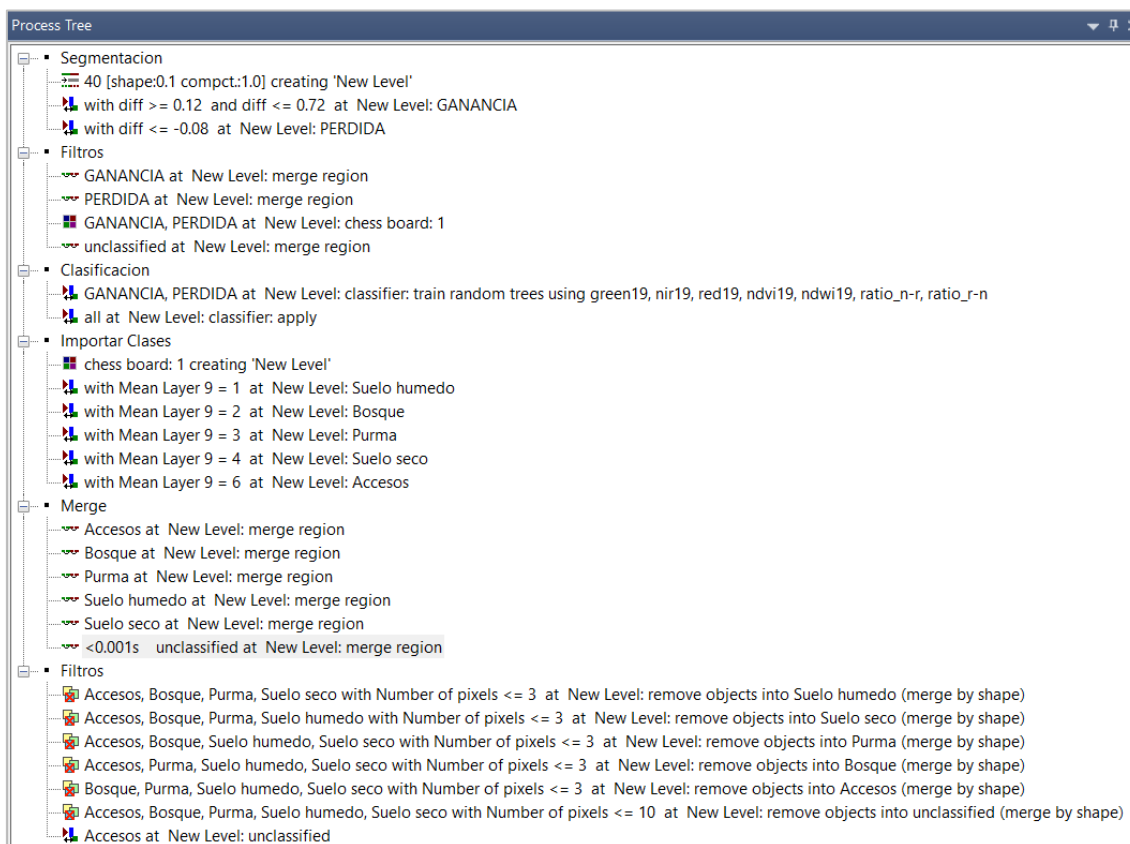


Figura 5.11. Regla de procesos para la detección y clasificación de coberturas en *eCognition Developer 10.1 Trial*.

b. Segmentación del cambio

Para la detección de las áreas de cambio del Año 1 (base) al Año 2 (cambio) mediante una selección de objetos, fue necesario realizar una sola segmentación (algoritmo *Multiresolution Segmentation*) y que esta sea capaz de detectar todos los cambios ocurridos en este periodo. Para ello se realizaron pruebas donde se concluyó que las bandas RED y NIR (insumos para el NDVI) de cada año ayudan a una discriminación más exacta frente a las otras bandas de la imagen.

El proceso de segmentación se configuró utilizando los siguientes criterios:

- Los pesos correspondientes a la banda *RED* y *NIR* de ambos años tengan valores a dos (2), y a las demás bandas dejar con valor uno (1), dada la importancia de las bandas para segmentar dos imágenes de diferente año.
- Parámetro de Escala; el cual determina el tamaño del segmento basándose en una medida de varianza (espectral y de forma). Estos segmentos crecen hasta alcanzar el umbral de varianza del parámetro de escala.
- Parámetro de Forma; el cual modifica el tipo de varianza determinada en la escala, el cual el umbral varía de 0 a 0,9 donde:
 - 0 = La varianza es estrictamente espectral
 - 0,9 = La varianza hace referencia principalmente a la forma
- Parámetro de Compactibilidad; el cual modifica el parámetro de Forma (varianza de forma), variando el umbral de 0 a 1. A medida que se aumenta el umbral de forma la compactibilidad también aumenta.



Para realizar la segmentación se configuraron los siguientes parámetros: *Escale Parameter* = 50, *Shape* = 0,1 y *Compactness* = 1 (Figura 5.12).

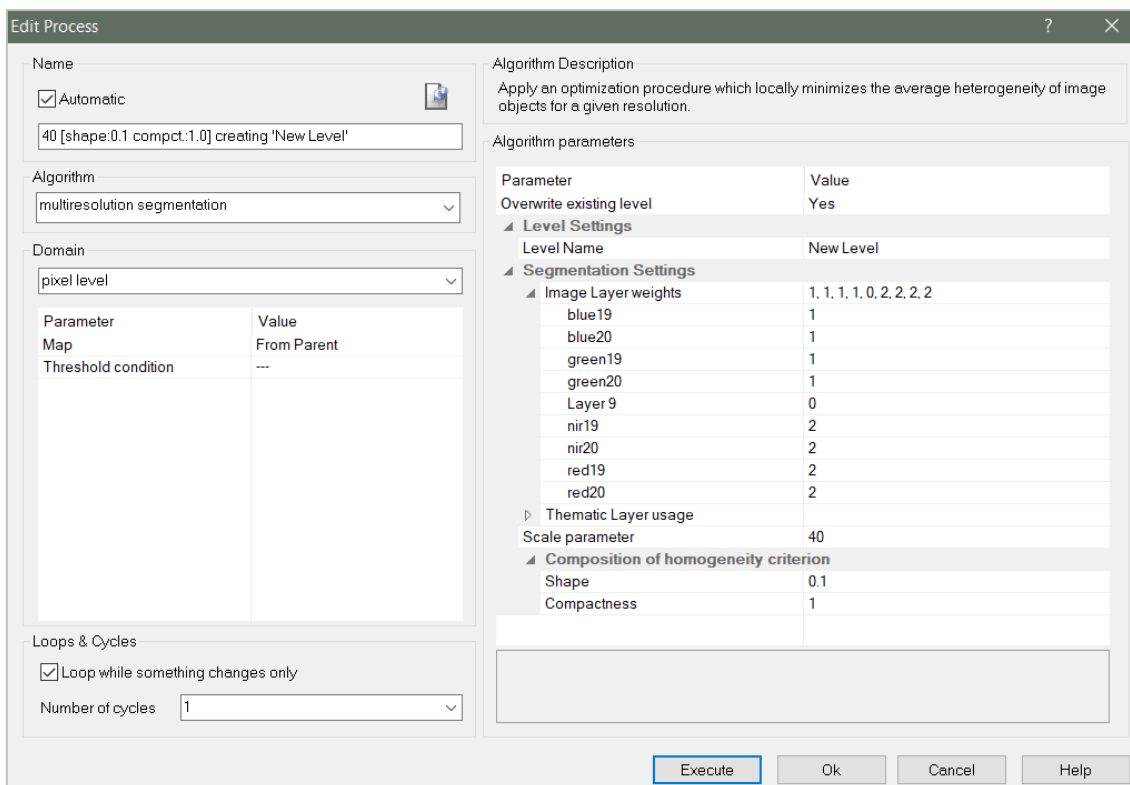


Figura 5.12. Resultado de la configuración de parámetros para la segmentación en *eCognition Developer 10.1 Trial*.

c. Generación del Índice de Vegetación Normalizada (NDVI)

Para el proceso de detección de cambios es de suma importancia contar con los NDVI de cada año, y con este resultado se hizo un proceso matemático simple, que es una diferencia de ambos NDVI (Año 1 - Año 2), lo que nos generó los cambios producidos en una determinada superficie de la tierra.

Esta diferencia de NDVI, permitió reconocer donde hubo pérdida de cobertura boscosa, así como también cambios suscitados entre clase y clase.

En el software *eCognition Developer 10.1 Trial*, se comprobó “visualmente” los cambios suscitados en una determinada superficie realizando la siguiente combinación de bandas: R: Infrarroja cercana del Año 1, G: Infrarroja cercana del Año 2, B: Infrarroja cercana del Año 1.

Al hacer esta combinación, se observó dos tonalidades fuertemente marcadas: el color magenta, representa los cambios y/o pérdidas dentro una superficie cualquiera, por otro lado, el color verdoso indica que se está produciendo algún tipo de revegetación de una zona que ha sido intervenido en el Año 1, a lo que uno puede interpretar como una ganancia de la cobertura vegetal.

d. Detección de Umbrales del NDVI

La detección de cambios se realizó en base a Umbrales del NDVI, para ello se utilizó el algoritmo *assign class* configurando los umbrales que cubren todos los sectores de pérdida



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

y/o ganancia de la imagen. Todos los objetos que no están dentro de este rango son discriminados para el análisis de detección de cambio.

Se definió que el umbral más adecuado para la ganancia son todos aquellos valores mayores a 0,12 y menores a 0,72, y aquellos valores que representan la pérdida son menores a -0,08.

5.4.2 Clasificación de coberturas de cambio

a. Selección de muestras de entrenamiento

La segmentación y detección del cambio generaron muestras de entrenamiento (puntos) con sus respectivos atributos (nombre de clases) con apoyo de la fotointerpretación de las imágenes satelitales. Se definieron clases de cobertura por cada periodo de años analizados considerando el mismo criterio de selección de muestras mencionado en la sección b del subtítulo 5.3.2.

b. Clasificación de coberturas

Esta clasificación se realizó para el año de cambio, para lo cual en el Árbol de Procesos se configuraron los parámetros del algoritmo de clasificación que permitieron interactuar con las muestras de entrenamiento. Se introdujeron los índices y ratios, así como las medianas de las bandas RED y NIR con la finalidad de aportar en la discriminación de las coberturas y obtener mejores resultados en la clasificación.

i. Creación de clases:

En el software *eCognition Developer 10.1 Trial* se generó un proceso y se configuró el algoritmo *Assign Class by Thematic Layer*, el cual permitió relacionar los atributos de las muestras de entrenamiento y crear las clases (jerarquía de las clases), como se muestra en la Figura 5.13.

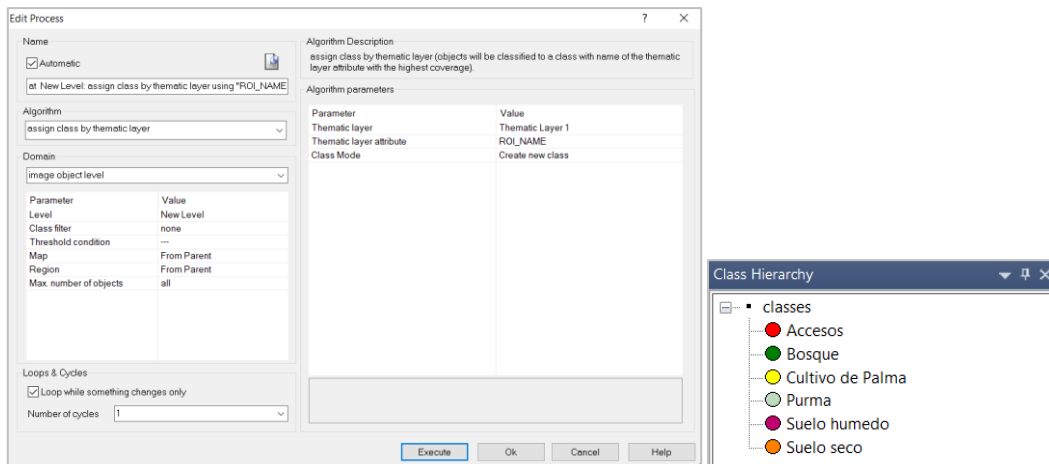


Figura 5.13. Relación de atributos y creación de clases

ii. Asignación de clases a los segmentos:

Posteriormente en el software *eCognition Developer 10.1 Trial* se configuró el algoritmo *Classified Image Objects to Samples*, el cual convirtió las muestras de entrenamiento de puntos a segmentos, relacionando los atributos y asignándole las clases, generando finalmente las muestras a nivel de segmento.



iii. Clasificación usando el algoritmo *Random Forest*

Para la clasificación de imágenes se utilizó el algoritmo *Random Forest* el cual es un clasificador que produce múltiples árboles de decisiones. Estos árboles se crean en base a la selección aleatoria de un subconjunto de muestras y variables de entrenamiento mediante un enfoque de *bagging*. Esto quiere decir que la misma muestra puede ser seleccionada en los subconjuntos varias veces, mientras que otras pueden no ser seleccionada en lo absoluto. Se emplea alrededor de dos tercios de las muestras para entrenar a los árboles y el tercio restante se emplean en una técnica de validación cruzada para estimar que tan bien funciona el modelo de *random forest*. La clasificación final se da en base al promedio de las probabilidades de la asignación de clases calculadas por todos los árboles producidos. Cada árbol de decisión vota por una etiqueta de clase. La etiqueta con el máximo de votos será la que uno seleccione finalmente (Belgiu & Drăgu, 2016; Breiman, 2001).

En el software *eCognition Developer 10.1 Trial* se configuró el algoritmo *Classifier* usando como clasificador el *Random Trees*. Se seleccionaron las muestras de entrenamiento, así como los valores de las medianas de las bandas de la imagen (*RED* y *NIR*) y de los índices generados (*SAVI*, *NDVI*, *NDWI* y ratios) que influyen en la clasificación, tal como muestra la Figura 5.14.

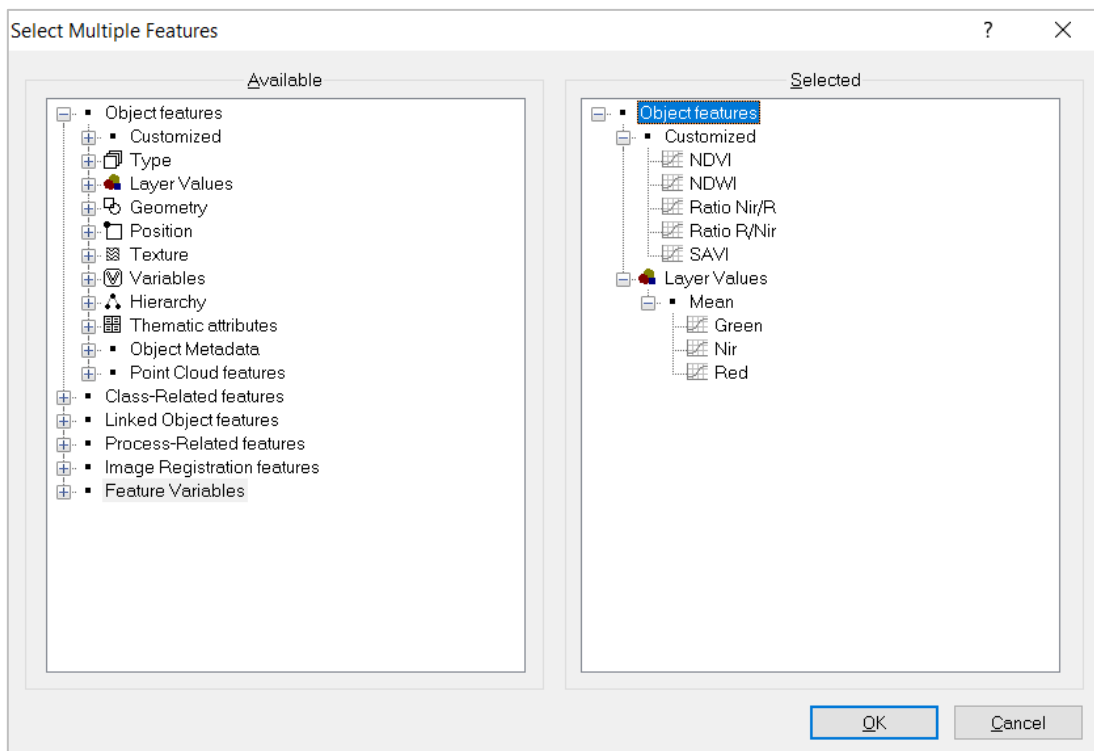


Figura 5.14. Ventana de Select Múltiple Feature, que permite agregar parámetros e índices a la clasificación

Se escogió como clasificador el algoritmo *Random Forest* indicando que el número de iteraciones sea 500. Asimismo, en la opción *Class filter* se seleccionaron las clases entrenadas tal como muestra la Figura 5.15.

«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

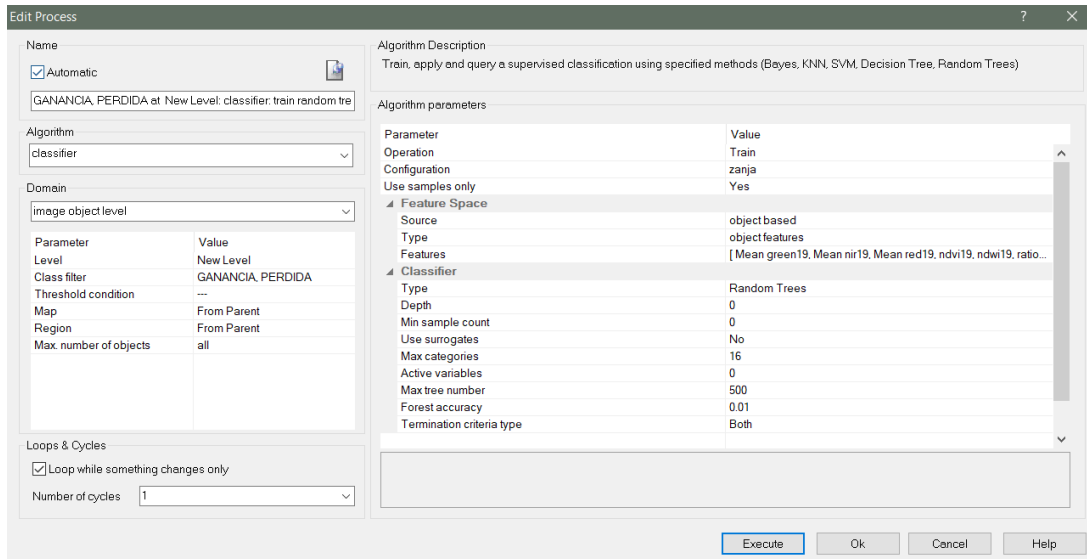


Figura 5.15. Configuración del clasificador del algoritmo *Random Forest*

Posteriormente se configuró un nuevo algoritmo *Classifier* indicando en la opción *Class filter* las áreas de detección de cambio para su clasificación, tal como muestra la Figura 5.16.

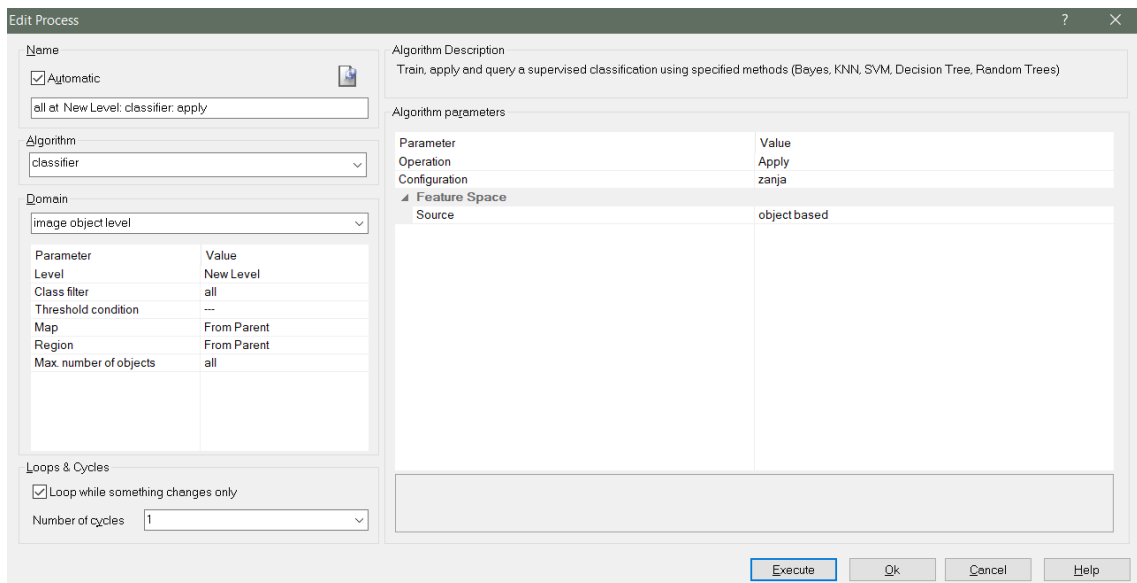


Figura 5.16. Configuración de la aplicación del algoritmo *Classifier*

5.4.3 Pos-Clasificación

a. Ajuste de los resultados de la clasificación de coberturas

Sobre los resultados de la clasificación de coberturas en las áreas de cambio se realizó un ajuste manual en las zonas que presentaron imperfecciones propias del procesamiento por clasificaciones erróneas. Este pos-procesamiento se apoyó en la técnica de la fotointerpretación. Para ello se usó el *software eCognition Developer 10.1 Trial* y se realizaron los siguientes pasos:

- Selección de la clasificación y la clase a ajustar.
- Selección automática de polígonos de píxeles menores a 5 con la herramienta *Manual Editing Tool*.



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

- Traslado de polígonos seleccionados a la nueva clase con la herramienta *classify image objects*.

b. Conversión de datos en información

Para la conversión de datos en información se emplearon herramientas de geoprocésamiento del *software ArcGIS*, para lo que se realizaron los siguientes pasos:

- Vectorización del raster de clases de cobertura mediante la herramienta *raster to polygon*.
- Cálculo de áreas (en hectáreas) mediante la herramienta *calculate geometry*.

6. RESULTADOS

A continuación, se presentan los resultados de la identificación de clases de coberturas y determinación de la extensión de los cambios de uso en las áreas de estudio de la UFFZS.

a. Identificar y determinar áreas de cambio de coberturas en el periodo 2020-2022 mediante el análisis multitemporal de imágenes satelitales dentro de la UFFZS.

Para el año 2020 se identificaron ocho (8) clases de coberturas; bosque húmedo con una extensión de 425,68 ha, cultivo de palma una extensión de 4342,01 ha, purma con una extensión de 305,71 ha, suelo húmedo con una extensión 27,47 ha, suelo seco con una extensión 16,78 ha, accesos con una extensión de 321,16 ha, cuerpos de agua con una extensión de 18,19 ha e Infraestructura con una extensión de 14,20 ha. (Figura 6.1 y Figura 6.2)




Figura 6.1. Extensión de cobertura para el año 2020.



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

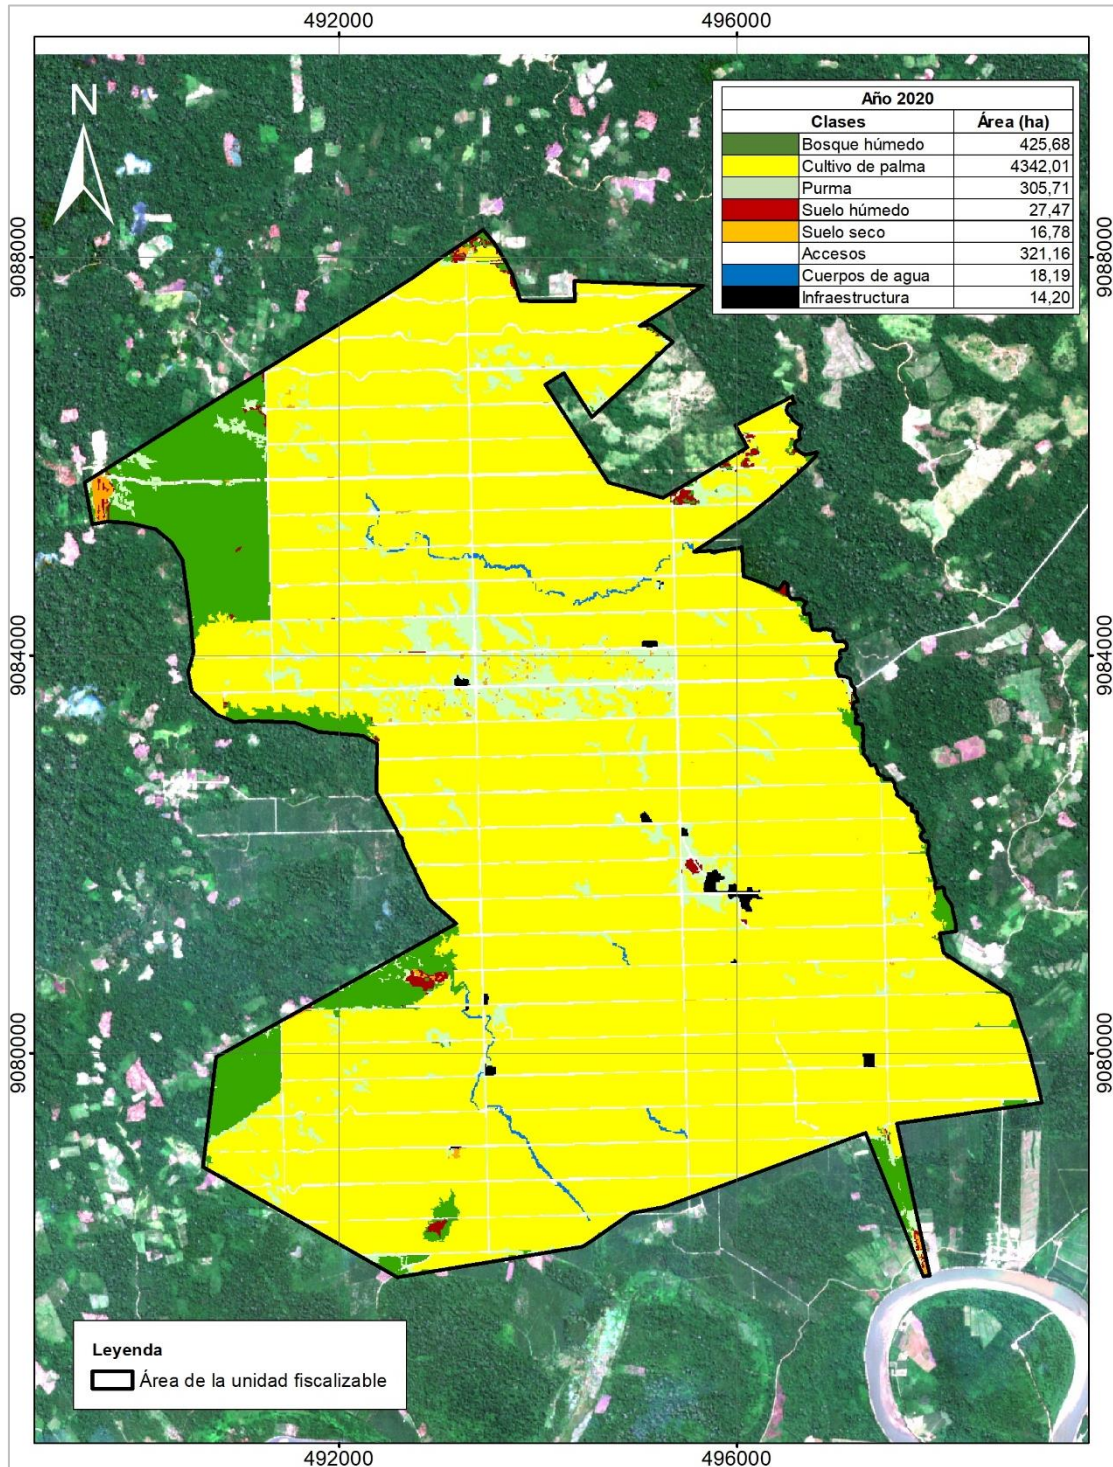


Figura 6.2. Clases de cobertura del año 2020 dentro del área de la UFFZS

Para el año 2022 se identificaron ocho (8) clases de coberturas; bosque húmedo con una extensión de 394,6 ha, cultivo de palma una extensión de 4338,04 ha, purma con una extensión de 321,33 ha, suelo húmedo con una extensión 23,60 ha, suelo seco con una extensión 21,97 ha, accesos con una extensión de 336,35 ha, cuerpos de agua con una extensión de 19,97 ha e Infraestructura con una extensión de 15,34 ha. (Figura 6.3 y Figura 6.4)



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

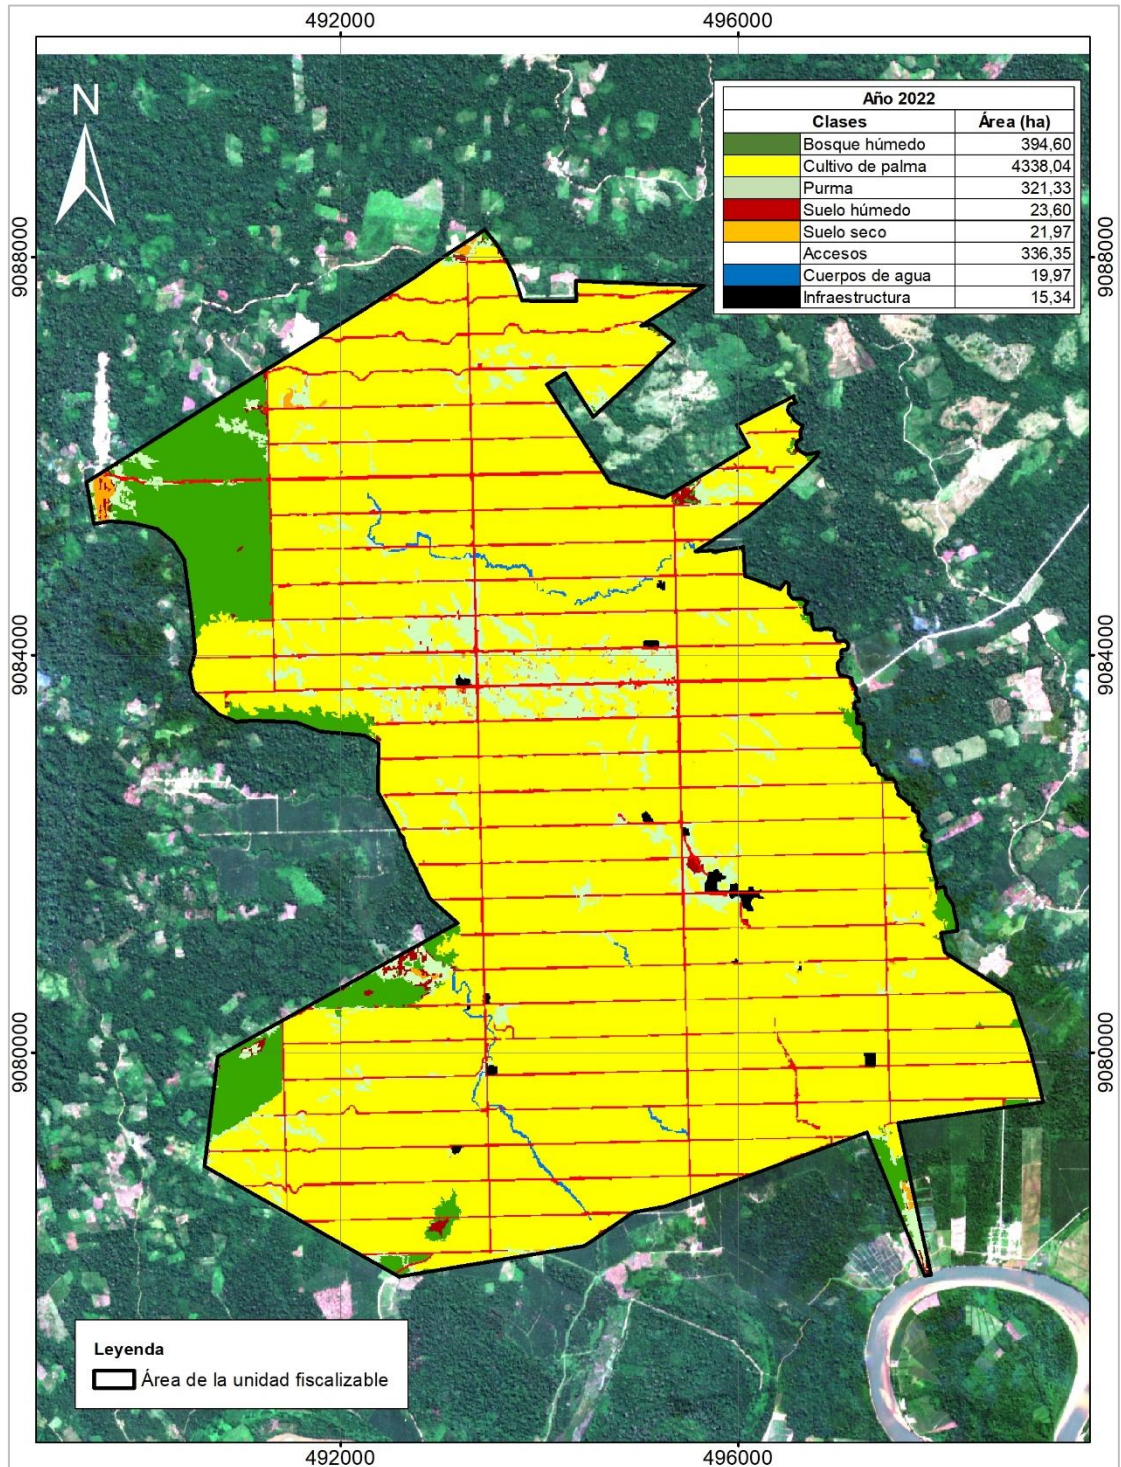


Figura 6.3. Clases de cobertura del año 2022 dentro del área de la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»



Figura 6.4. Determinación de cobertura para el año 2022.

Haciendo un análisis general del año 2020 al 2022 (Tabla 6.1), se tiene que el Bosque húmedo ha tenido una pérdida de cobertura de 31,08 ha, el cultivo de palma se ha mantenido en producción en el periodo de análisis, la Purma aumentó 15,62 ha y el acceso aumentó 15,19 ha. Las coberturas como el suelo húmedo, suelo seco, cuerpos de agua y la infraestructura no han sufrido modificaciones significantes.

Tabla 6.1. Superficie de coberturas por año clasificado

Clase	Año 2020	Año 2022
Bosque húmedo	425,68	394,60
Cultivo de palma	4342,01	4338,04
Purma	305,71	321,33
Suelo húmedo	27,47	23,60
Suelo seco	16,78	21,97
Accesos	321,16	336,35
Cuerpos de agua	18,19	19,97
Infraestructura	14,20	15,34

Se calcularon extensiones de las áreas de cambio de cobertura para el periodo 2020-2022 en el área dentro de la UFFZS, las celdas resaltadas en amarillo son las extensiones de las coberturas que no han sufrido cambio, tal como se muestra en la Tabla 6.2.

Tabla 6.2. Áreas de cambio para el periodo 2020-2022

		2022								
CLASE	Bosque húmedo	Cultivo de palma	Purma	Suelo húmedo	Suelo seco	Accesos	Cuerpos de agua	Infraestructura	Total	
2020	Bosque húmedo	394,60	3,45	16,89	6,64	2,60	0,79	0,71	-	425,68
	Cultivo de palma	-	4317,90	15,42	-	4,19	3,43	0,83	0,26	4342,01
	Purma	-	11,79	281,45	1,18	0,65	9,91	0,17	0,57	305,71
	Suelo húmedo	-	4,40	6,08	15,21	1,54	0,23	-	-	27,47
	Suelo seco	-	0,50	1,48	0,57	12,99	0,85	0,08	0,31	16,78
	Accesos	-	-	-	-	-	321,16	-	-	321,16
	Cuerpos de agua	-	-	-	-	-	-	18,19	-	18,19
	Infraestructura	-	-	-	-	-	-	-	14,20	14,20
	Total	394,60	4.338,04	321,33	23,60	21,97	336,35	19,97	15,34	5471,21



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

b. Identificar áreas de cambio de cobertura en las zonas fronterizas a la UFFT en tres (3) periodos de análisis (2019-2020, 2020-2021 y 2021-2022) mediante el análisis multitemporal de imágenes satelitales, así como estimar sus extensiones como apoyo para la evaluación de la continuidad de dicha unidad.

Para el año 2019 se identificaron nueve (09) clases de coberturas; Bosque húmedo con una extensión de 2185,90 ha, cultivo de palma una extensión de 365,39 ha, purma con una extensión de 352,36 ha, suelo húmedo con una extensión 270,29 ha, suelo seco con una extensión 77,25 ha, accesos con una extensión de 12,52 ha, cuerpos de agua con una extensión de 6,38 ha, Infraestructura con una extensión de 0,01 ha y otros cultivos con una extensión de 1,83 ha. (Figura 6.5 y Figura 6.6)




Figura 6.5. Determinación de cobertura para el año 2019.



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

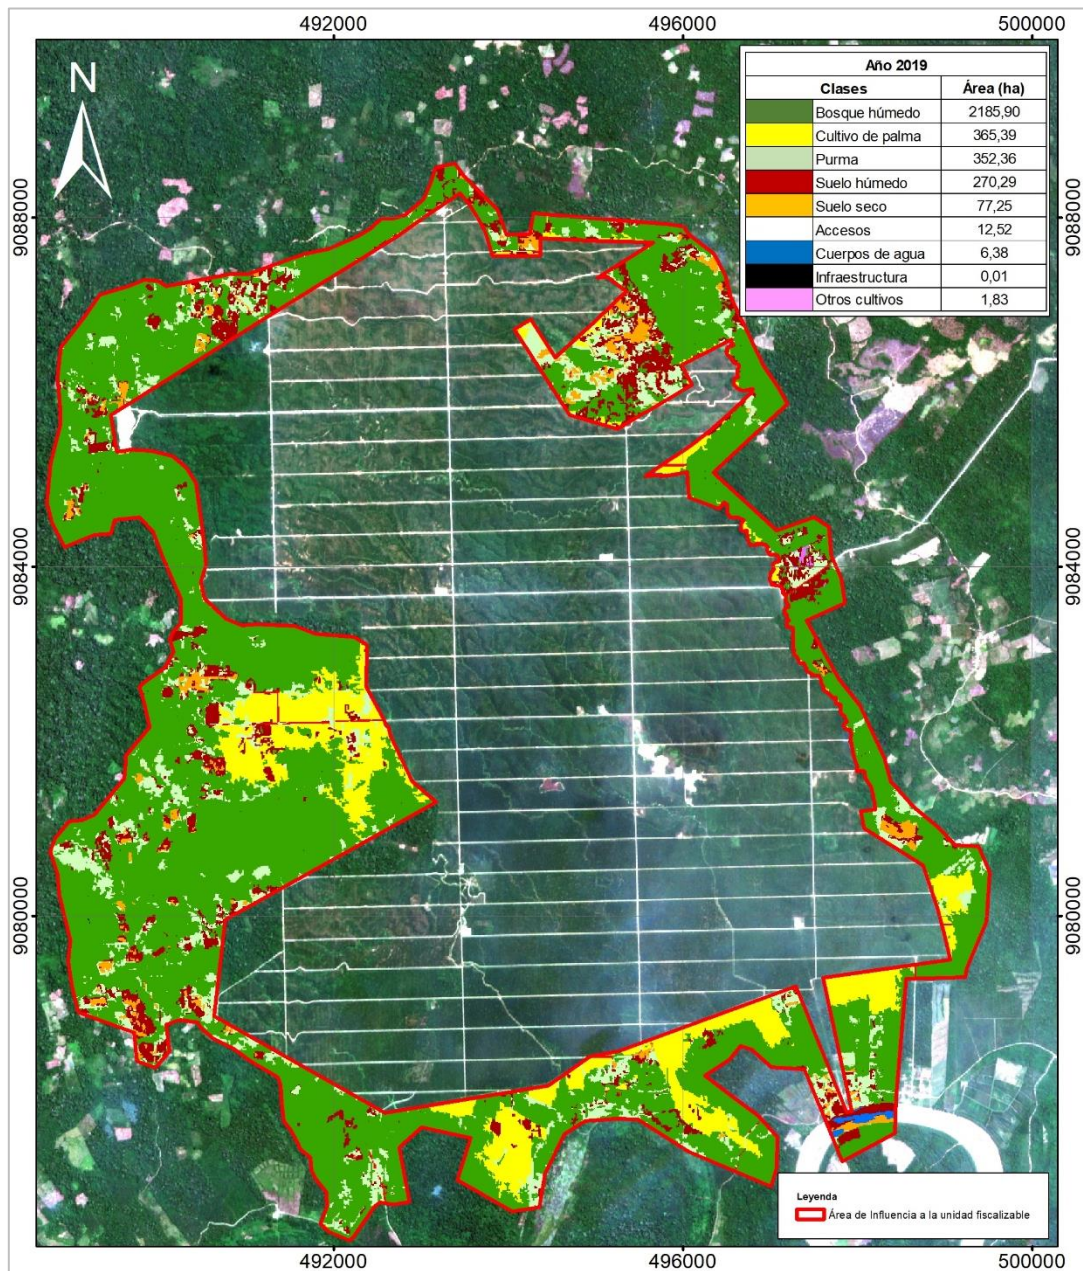


Figura 6.6. Clases de cobertura del año 2019 en el área de influencia de la UFFZS

Para el año 2020 se identificaron nueve (09) clases de coberturas; Bosque húmedo con una extensión de 2113,81 ha, cultivo de palma una extensión de 388,95 ha, purma con una extensión de 417,16 ha, suelo húmedo con una extensión 220,03 ha, suelo seco con una extensión 101,26 ha, accesos con una extensión de 14,28 ha, cuerpos de agua con una extensión de 6,39 ha, Infraestructura con una extensión de 0,01 ha y otros cultivos con una extensión de 10,04 ha. (Figura 6.7 y Figura 6.8)



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

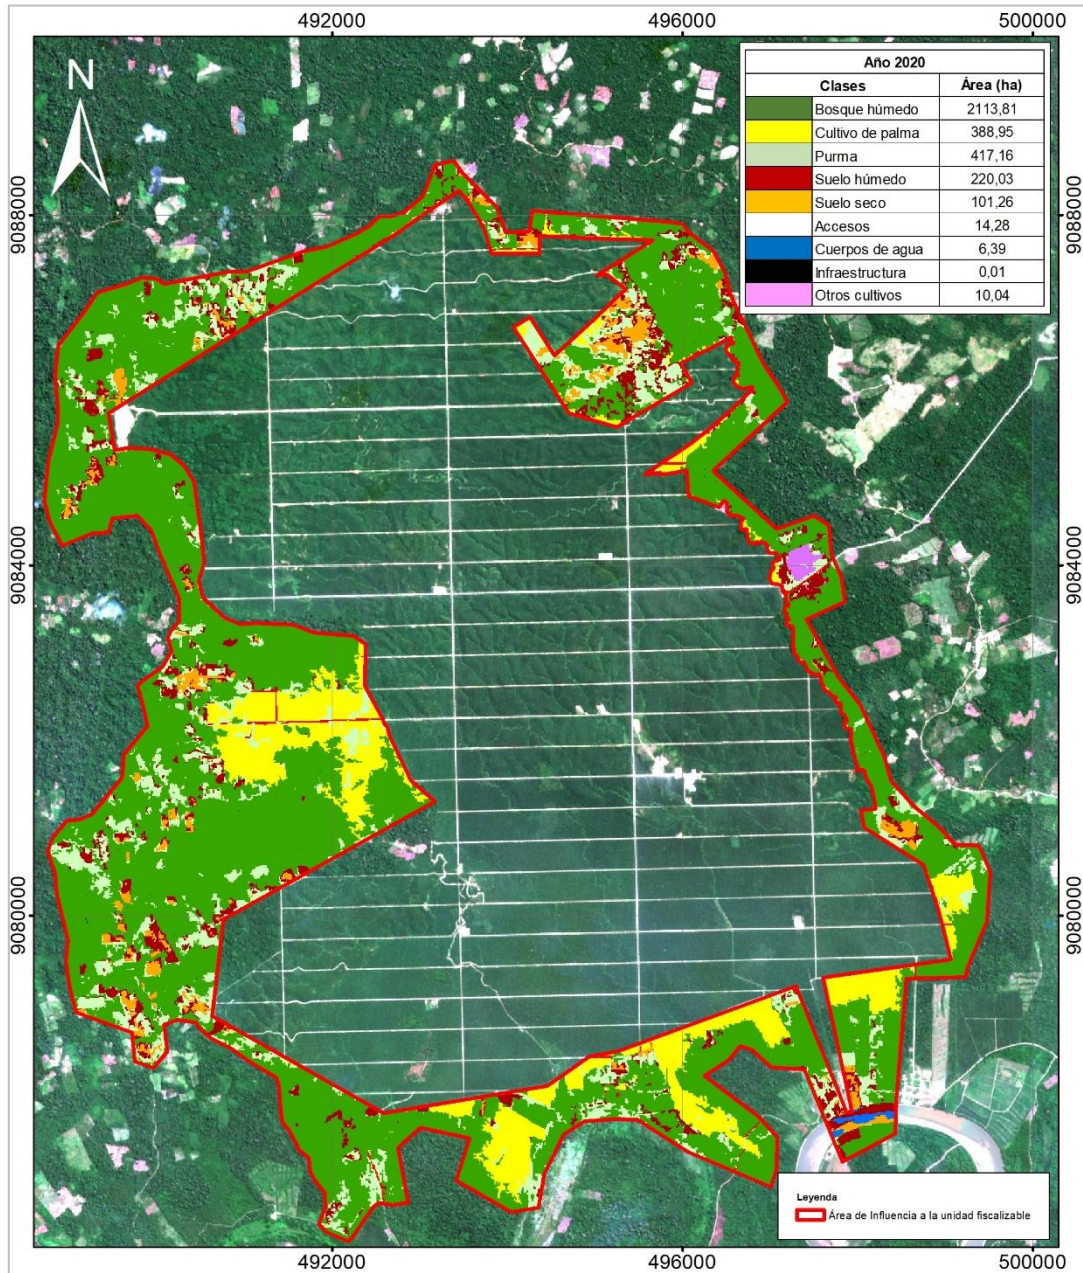


Figura 6.7. Clases de cobertura del año 2020 en el área de influencia de la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»




Figura 6.8. Determinación de cobertura para el año 2020.

Para el año 2021 se identificaron nueve (09) clases de coberturas; Bosque húmedo con una extensión de 1834,47 ha, cultivo de palma una extensión de 408,33 ha, purma con una extensión de 560,58 ha, suelo húmedo con una extensión 243,24 ha, suelo seco con una extensión 179,57 ha, accesos con una extensión de 17,34 ha, cuerpos de agua con una extensión de 17,14 ha, Infraestructura con una extensión de 0,02 ha y otros cultivos con una extensión de 11,15 ha. (Figura 6.9 y Figura 6.10)



Figura 6.9. Determinación de cobertura para el año 2021.

«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

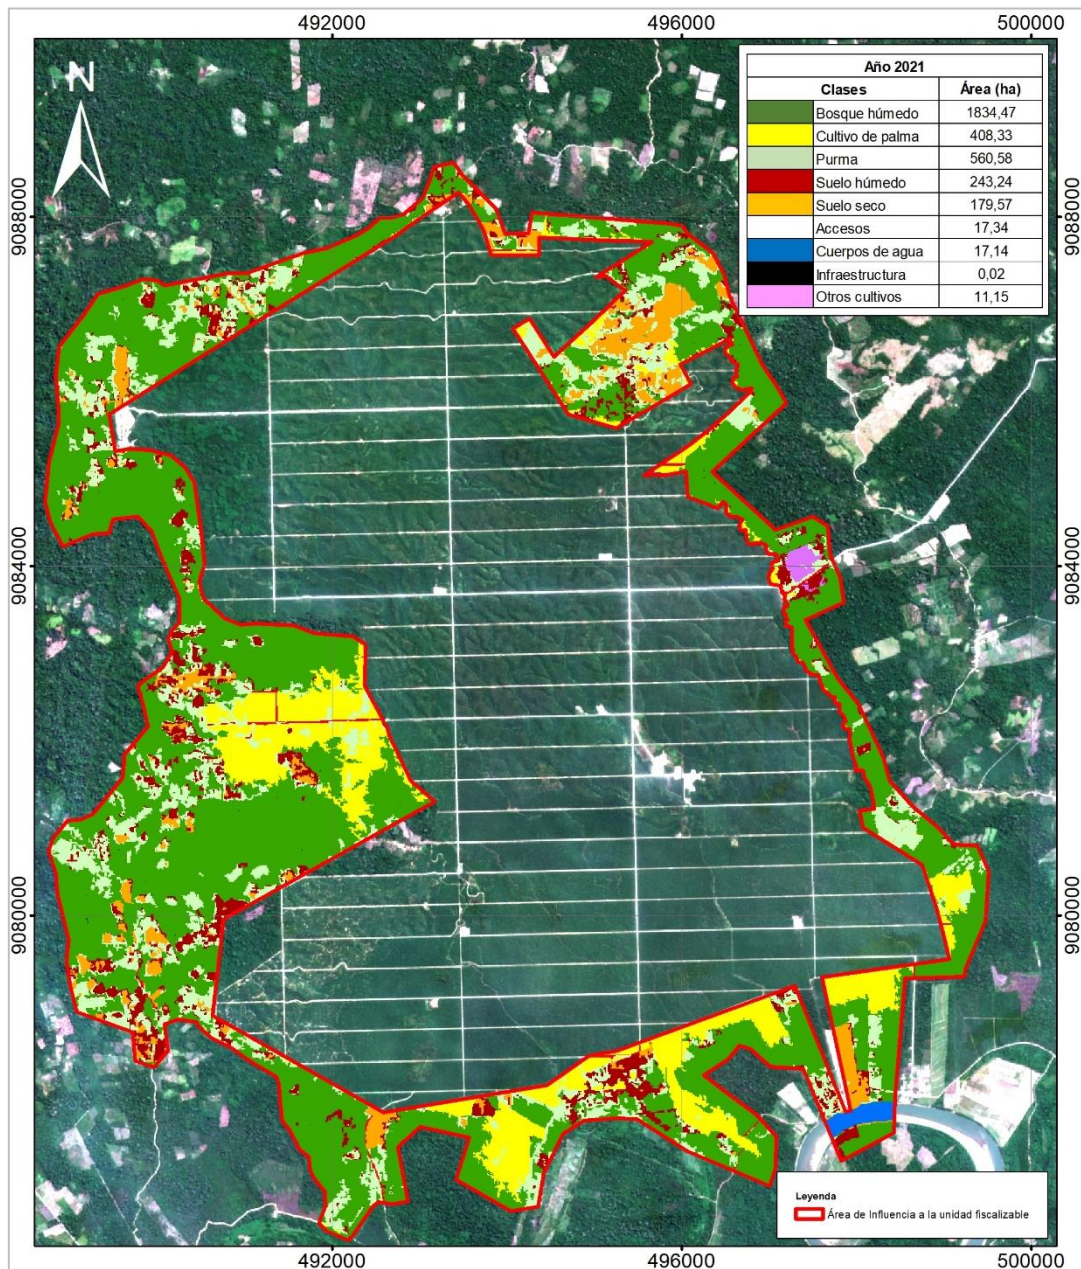


Figura 6.10. Clases de cobertura del año 2021 en el área de influencia de la UFFZS

Para el año 2022 se identificaron nueve (09) clases de coberturas; Bosque húmedo con una extensión de 1771,94 ha, cultivo de palma una extensión de 434,00 ha, purma con una extensión de 671,97 ha, suelo húmedo con una extensión 225,70 ha, suelo seco con una extensión 113,95 ha, accesos con una extensión de 22,76 ha, cuerpos de agua con una extensión de 17,75 ha, Infraestructura con una extensión de 0,21 ha y otros cultivos con una extensión de 13,54 ha. (Figura 6.11 y Figura 6.12)



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

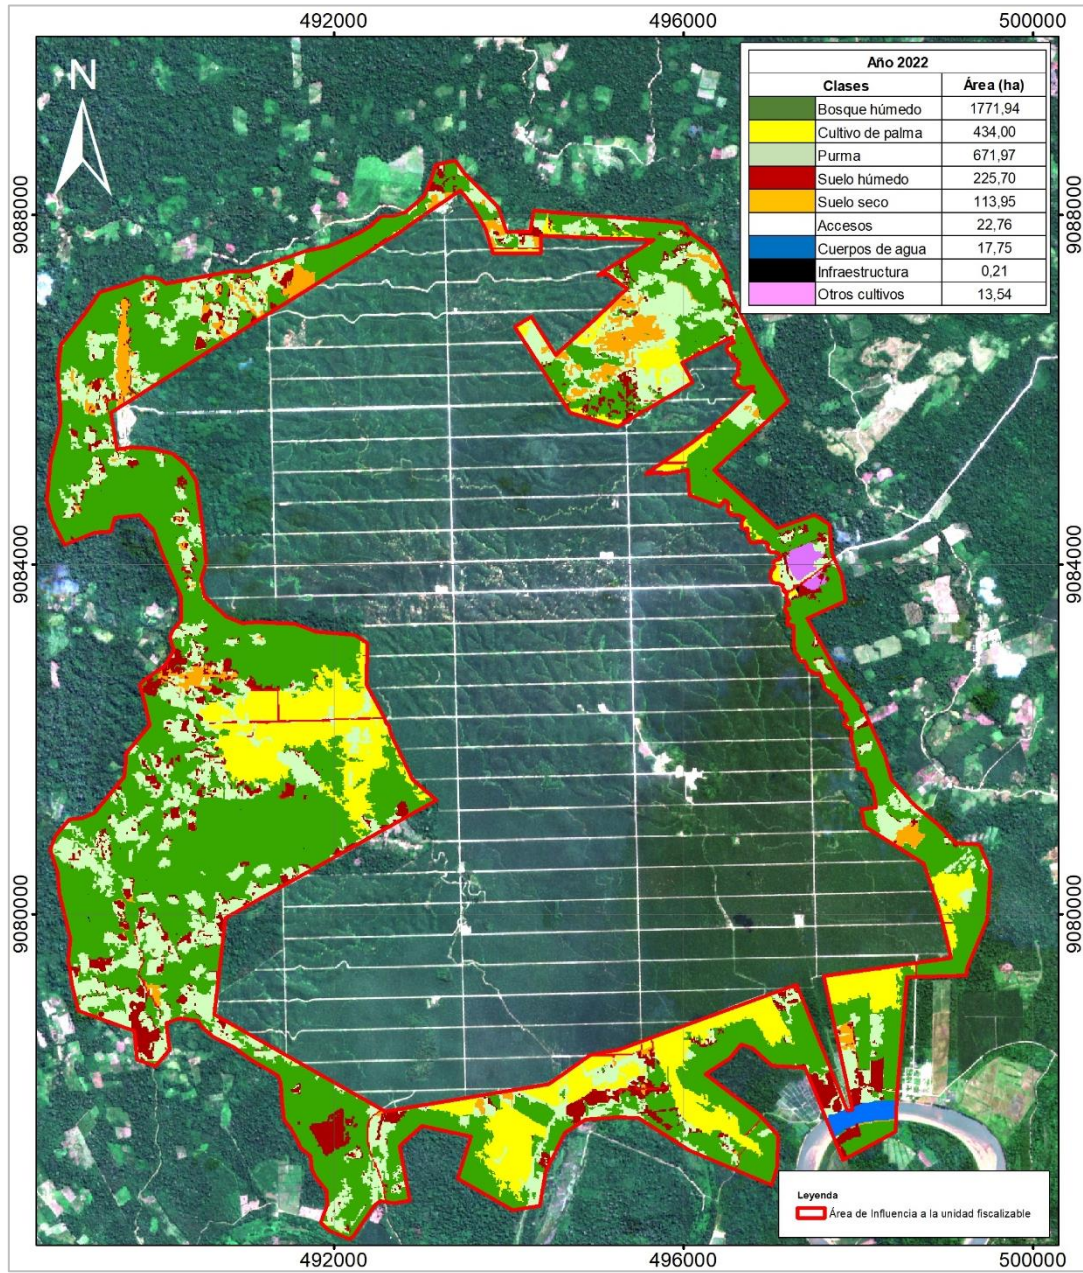


Figura 6.11. Clases de cobertura del año 2022 en el área de influencia de la UFFZS

«Decenio de la igualdad de oportunidades para mujeres y hombres»
 «Año del fortalecimiento de la soberanía nacional»
 «Año del bicentenario del Congreso de la República del Perú»




Figura 6.12. Determinación de cobertura para el año 2022.

Haciendo un análisis general de los años 2019, 2020, 2021 y 2022 (Tabla 6.3), se tiene que el bosque húmedo ha tenido una pérdida de cobertura de 413,96 ha (equivalente al 18,94% de su cobertura inicial), el cultivo de palma ha aumentado 68,60 ha, la purma aumentó 319,61 ha (equivalente al 90% de su cobertura inicial), el acceso aumentó a 22,76 ha (equivalente a 82% de su cobertura inicial). Las coberturas como el suelo húmedo y seco, cuerpos de agua y la infraestructura no han sufrido modificaciones significantes.

Tabla 6.3. Superficie de coberturas por año clasificado

Clase	Año 2019	Año 2020	Año 2021	Año 2022
Bosque húmedo	2185,90	2113,81	1834,47	1771,94
Cultivo de palma	365,39	388,95	408,33	434,00
Purma	352,36	417,16	560,58	671,97
Suelo húmedo	270,29	220,03	243,24	225,70
Suelo seco	77,25	101,26	179,57	113,95
Accesos	12,52	14,28	17,34	22,76
Cuerpos de agua	6,38	6,39	17,14	17,75
Infraestructura	0,01	0,01	0,02	0,21
Otros cultivos	1,83	10,04	11,15	13,54

Se calcularon extensiones de las áreas de cambio de cobertura para el periodo 2019-2020, 2020-2021 y 2021-2022 en el área de influencia de la UFFZS, las celdas resaltadas en amarillo son las extensiones de las coberturas que no han sufrido cambio, tal como se muestra en la Tabla 6.4.



«Decenio de la igualdad de oportunidades para mujeres y hombres»

«Año del fortalecimiento de la soberanía nacional»

«Año del bicentenario del Congreso de la República del Perú»

Tabla 6.4. Áreas de cambio para el periodo 2019-2020, 2020-2021 y 2021-2022

2020											
CLASE	Bosque húmedo	Cultivo de palma	Purma	Suelo húmedo	Suelo seco	Accesos	Cuerpos de agua	Infraestructura	Otros cultivos	Total	
2019	Bosque húmedo	2113,81	0,92	11,51	43,66	15,58	0,01	-	-	0,41	2185,90
	Cultivo de palma	-	365,39	-	-	-	-	-	-	-	365,39
	Purma	-	1,04	330,21	9,69	7,49	1,03	0,01	-	2,89	352,36
	Suelo húmedo	-	21,47	65,93	162,58	14,69	0,70	-	-	4,91	270,29
	Suelo seco	-	0,12	9,51	4,10	63,50	0,02	-	-	-	77,25
	Accesos	-	-	-	-	-	12,52	-	-	-	12,52
	Cuerpos de agua	-	-	-	-	-	-	6,38	-	-	6,38
	Infraestructura	-	-	-	-	-	-	-	0,01	-	0,01
	Otros cultivos	-	-	-	-	-	-	-	-	1,83	1,83
	Total	2113,81	388,95	417,16	220,03	101,26	14,28	6,39	0,01	10,04	3271,93

2021											
CLASE	Bosque húmedo	Cultivo de palma	Purma	Suelo húmedo	Suelo seco	Accesos	Cuerpos de agua	Infraestructura	Otros cultivos	Total	
2020	Bosque húmedo	1834,47	14,28	129,40	74,76	58,33	2,06	0,32	-	0,14	2113,77
	Cultivo de palma	-	388,95	-	-	-	-	-	-	-	388,95
	Purma	-	1,87	346,73	39,41	27,98	0,68	0,22	-	0,28	417,16
	Suelo húmedo	-	3,23	64,28	121,13	23,58	0,14	6,93	0,01	0,69	219,98
	Suelo seco	-	-	20,17	7,95	69,68	0,18	3,28	-	-	101,26
	Accesos	-	-	-	-	-	14,28	-	-	-	14,28
	Cuerpos de agua	-	-	-	-	-	-	6,39	-	-	6,39
	Infraestructura	-	-	-	-	-	-	-	0,01	-	0,01
	Otros cultivos	-	-	-	-	-	-	-	-	10,04	10,04
	Total	1834,47	408,33	560,58	243,24	179,57	17,34	17,14	0,02	11,15	3271,84

2022											
CLASE	Bosque húmedo	Cultivo de palma	Purma	Suelo húmedo	Suelo seco	Accesos	Cuerpos de agua	Infraestructura	Otros cultivos	Total	
2021	Bosque húmedo	1771,94	0,26	12,13	35,08	14,60	0,46	-	-	-	1834,47
	Cultivo de palma	-	408,21	0,12	-	-	-	-	-	-	408,33
	Purma	-	16,83	498,41	25,48	16,91	2,13	0,03	0,19	0,59	560,58
	Suelo húmedo	-	7,39	78,31	144,85	9,45	1,41	-	-	1,80	243,21
	Suelo seco	-	1,31	83,00	20,28	72,98	1,42	0,58	-	-	179,57
	Accesos	-	-	-	-	-	17,34	-	-	-	17,34
	Cuerpos de agua	-	-	-	-	-	-	17,14	-	-	17,14
	Infraestructura	-	-	-	-	-	-	-	0,02	-	0,02
	Otros cultivos	-	-	-	-	-	-	-	-	11,15	11,15
	Total	1771,94	434,00	671,97	225,70	113,95	22,76	17,75	0,21	13,54	3271,81



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

c. Ortomosaico RGB de los componentes que no lograron ser identificados con el análisis de imágenes satelitales dentro de la UFFZS mediante levantamiento fotogramétrico con RPAS .

En esta sección se presentan los resultados obtenidos del levantamiento fotogramétrico con RPAS en áreas aledañas al límite de la UFFZS y en la zona del campamento principal, ubicados en los distritos Nueva Requena y Curimana, provincias Coronel Portillo y Padre Abad, departamento Ucayali. Como resultado del procesamiento fotogramétrico se obtuvieron diez (10) ortomosaicos RGB detallados en el reporte de procesamiento de software fotogramétrico N.º RSPF-0134-2022-ITEGI (Anexo 4).

En la Figura 6.13 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-81 en áreas aledañas a la UFFZS, con una resolución espacial de 4,04 cm/pix y que abarcó un área de 0,655 km².




Figura 6.13. Ortomosaico FT-OU-81 en áreas aledañas a la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

En la Figura 6.14 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-82 en áreas aledañas a la UFFZS, con una resolución espacial de 4,24 cm/pix y que abarcó un área de 0,895 km².




Figura 6.14. Ortomosaico FT-OU-82 en áreas aledañas a la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

En la Figura 6.15 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-83 en áreas aledañas a la UFFZS, con una resolución espacial de 4,09 cm/pix y que abarcó un área de 1,12 km².



Figura 6.15. Ortomosaico FT-OU-83 en áreas aledañas a la UFFZS

En la Figura 6.16 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-84-86-88 en áreas aledañas a la UFFZS, con una resolución espacial de 3,99 cm/pix y que abarcó un área de 4,36 km².




Figura 6.16. Ortomosaico FT-OU-84-86-88 en áreas aledañas a la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

En la Figura 6.17 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-85 en áreas aledañas a la UFFZS, con una resolución espacial de 4,14 cm/pix y que abarcó un área de 0,947 km².




Figura 6.17. Ortomosaico FT-OU-85 en áreas aledañas a la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

En la Figura 6.18 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-87 en áreas aledañas a la UFFZS, con una resolución espacial de 4,14 cm/pix y que abarcó un área de 0,841 km².

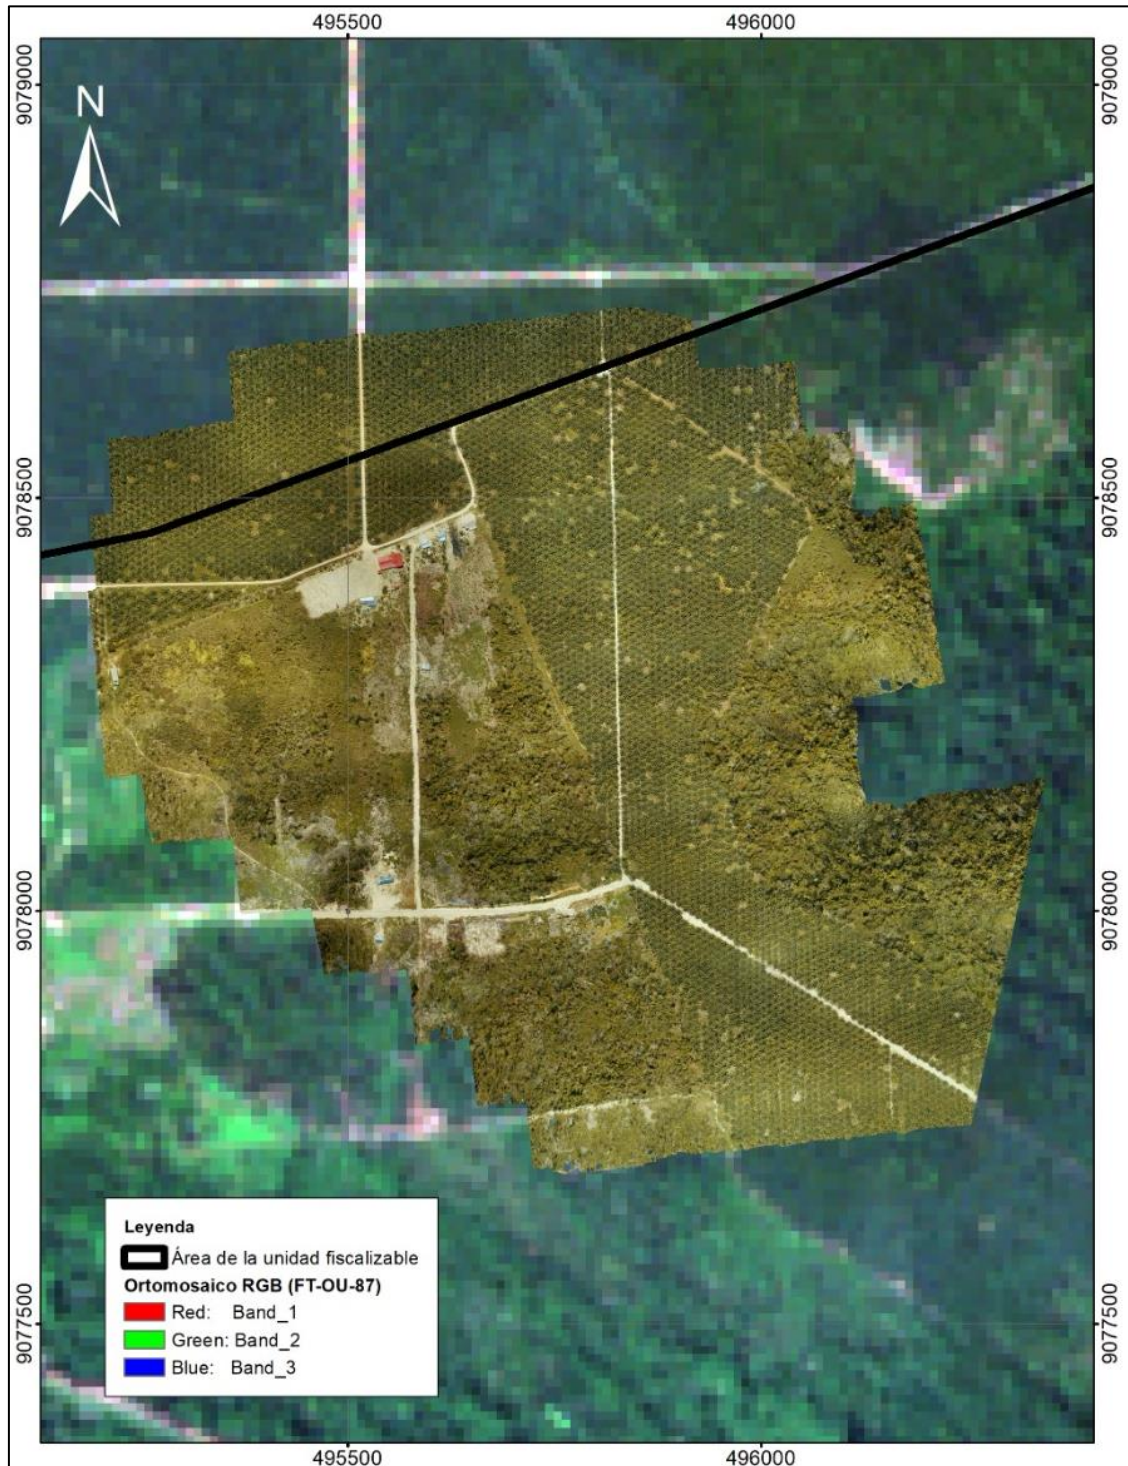


Figura 6.18. Ortomosaico FT-OU-87 en áreas aledañas a la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

En la Figura 6.19 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-89 en áreas aledañas a la UFFZS, con una resolución espacial de 4,18 cm/pix y que abarcó un área de 0,892 km².




Figura 6.19. Ortomosaico FT-OU-89 en áreas aledañas a la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

En la Figura 6.20 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-90 en áreas aledañas a la UFFZS, con una resolución espacial de 4,11 cm/pix que abarcó un área de 0,947 km².




Figura 6.20. Ortomosaico FT-OU-90 en áreas aledañas a la UFFZS

En la Figura 6.21 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-91 en áreas aledañas a la UFFZS, con una resolución espacial de 4,38 cm/pix que abarcó un área de 1,26 km².

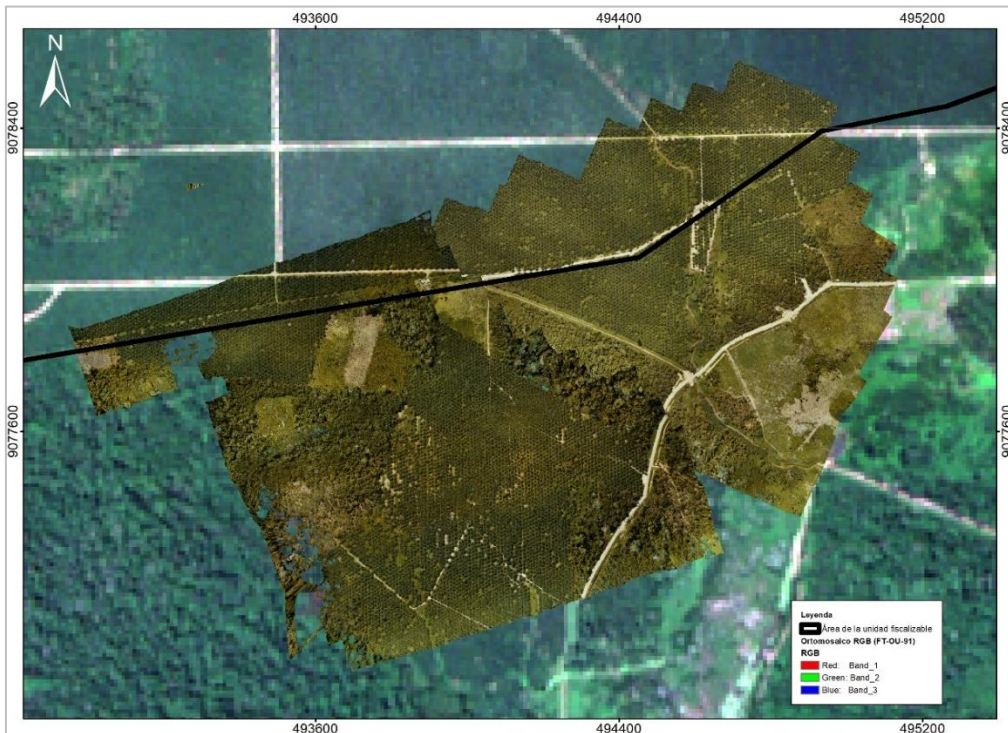


Figura 6.21. Ortomosaico FT-OU-91 en áreas aledañas a la UFFZS



«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

En la Figura 6.22 se muestra el ortomosaico FT-OU-92 en áreas aledañas a la UFFZS, con una resolución espacial de 4,09 cm/pix y que abarcó un área de 1,13 km².




Figura 6.22. Ortomosaico FT-OU-92 en áreas aledañas a la UFFZS



En la Figura 6.23 se muestra el ortomosaico RGB del levantamiento fotogramétrico FT-OU-93 en áreas aledañas a la UFFZS, con una resolución espacial de 3,91 cm/pix y que abarcó un área de 0,61 km².

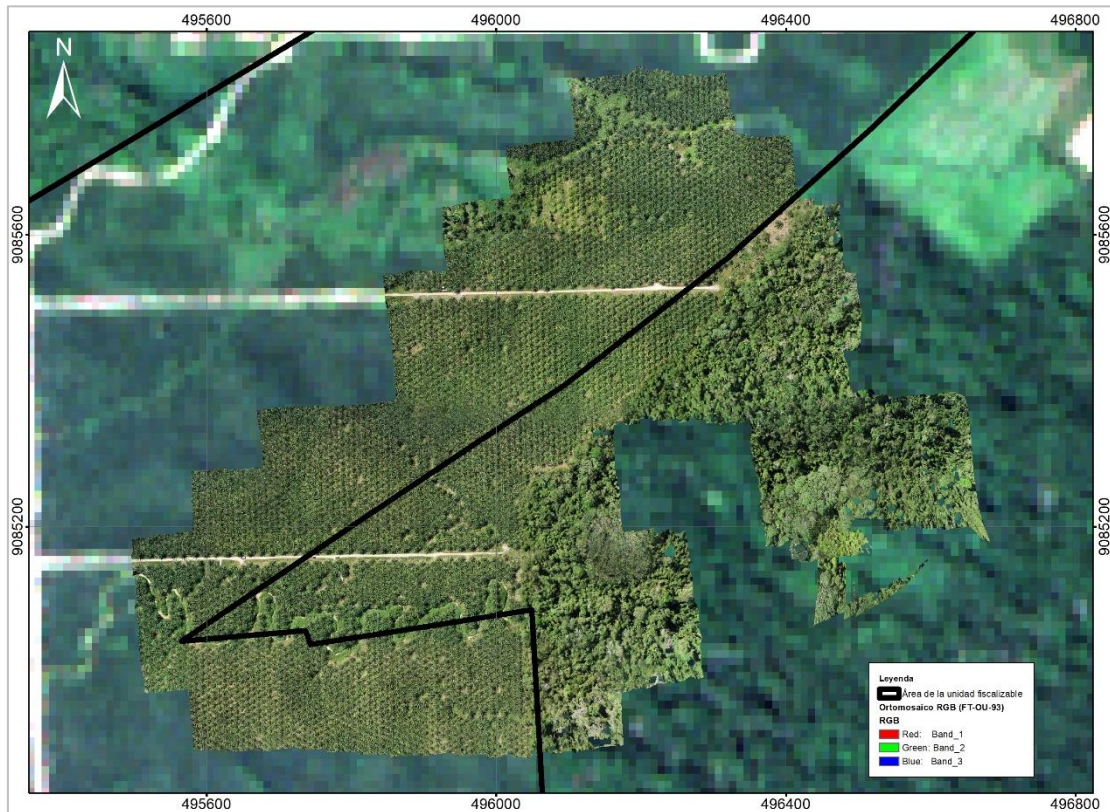


Figura 6.23. Levantamiento fotogramétrico FT-OU-91 en áreas aledañas a la UFFZS

7. CONCLUSIONES

- i. Para el periodo de análisis 2020-2022 se identificaron ocho (8) clases de cobertura: Bosque húmedo, cultivo de palma, purma, suelo húmedo, suelo seco, accesos, cuerpos de agua e Infraestructura, en la cual se determinó que Bosque húmedo ha tenido una pérdida de cobertura de 31,08 ha, el cultivo de palma se ha mantenido en producción en el periodo de análisis, la Purma aumentó 15,62 ha y el acceso aumentó 15,19 ha. Las coberturas como el suelo húmedo, suelo seco, cuerpos de agua y la infraestructura no han sufrido modificaciones significantes en el área de estudio dentro de la unidad fiscalizable Fundo Zanja Seca.
- ii. Para el periodo de análisis 2019-2020, 2020-2021 y 2021-2022 se identificaron nueve (9) clases de cobertura: Bosque húmedo, cultivo de palma, purma, suelo húmedo, suelo seco, accesos, cuerpos de agua, infraestructura y otros cultivos, en la cual se determinó que el bosque húmedo ha tenido una pérdida de cobertura de 413,96 ha (equivalente al 18,94% de su cobertura inicial), el cultivo de palma ha aumentado 68,60 ha, la purma aumentó 319,61 ha (equivalente al 90% de su cobertura inicial), el acceso aumentó a 22,76 ha (equivalente a 82% de su cobertura inicial). Las coberturas como el suelo húmedo y seco, cuerpos de agua y la infraestructura no han sufrido modificaciones significantes en el área de influencia de la unidad fiscalizable Fundo Zanja Seca.



PERÚ

Ministerio
del Ambiente

Organismo de Evaluación y
Fiscalización Ambiental - OEFA

STEC: Subdirección
Técnica Científica

«Decenio de la igualdad de oportunidades para mujeres y hombres»
«Año del fortalecimiento de la soberanía nacional»
«Año del bicentenario del Congreso de la República del Perú»

- iii. Se generaron diez (10) ortomosaicos RGB producto del levantamiento fotogramétrico con RPAS, en áreas aledañas a la unidad fiscalizable Fundo Zanja Seca.

8. RECOMENDACIONES

Se recomienda remitir el presente informe a la DSAP para los fines que se estimen convenientes.

9. ANEXOS

Anexo 1: Acta de Inicio de Estudio.

Anexo 2: Plan de Estudio.

Anexo 3: Reporte de Campo.

Anexo 4: Reportes de procesamiento de software fotogramétrico

Anexo 5: Ficha de puntos de validación del Mapa de Cobertura y Uso 2022 de la UF Fundo Zanja Seca

Anexo 6: Ficha de almacenamiento de productos

Atentamente:

[LFAJARDO]

[MCBALLERO]

Visto este informe la Dirección de Evaluación Ambiental ha dispuesto su aprobación.

Atentamente:

[FGARCIA]



"Esta es una copia auténtica imprimible de un documento electrónico archivado por el OEFA, aplicando lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. N° 026-2016-PCM. Su autenticidad e integridad pueden ser contrastadas a través de la siguiente dirección web: <https://sistemas.oefa.gob.pe/verifica> e ingresando la siguiente clave: 03588344"



03588344