



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 de la unidad, la paz y el desarrollo"

2023-I01-008239

**INFORME N.º 00178-2023-OEFA/DEAM-STEC**

**A** : **LLOJAN CHUQUISENGO PICÓN**  
Director de la Dirección de Evaluación Ambiental

**DE** : **SHIANNY VÁSQUEZ CARDEÑA**  
Ejecutiva de la Subdirección Técnica Científica

**MARIELA BERENICE CABALLERO DEL CASTILLO**  
Especialista en Evaluaciones Ambientales – Especialista I

**ASUNTO** : Evaluación ambiental focal de la superficie terrestre mediante el estudio multitemporal de imágenes satelitales en la unidad fiscalizable Fundo Buena Palma - Sector Bimboya de titularidad de Roel Ermed Silva Agip, ubicada en los distritos Padre Márquez y Nueva Requena, provincias Ucayali y Coronel Portillo, departamentos de Loreto y Ucayali, en 2023.

**EXPEDIENTE DE EVALUACIÓN** : 0030-2023-DEAM-EAF

**CÓDIGO DE ACCIÓN** : No aplica

**REFERENCIA** : a) Expediente de Supervisión N° 0231-2022-DSAP-CAGR  
b) Memorando N° 00435-2023-OEFA/DSAP  
c) Memorando N° 00184-2023-OEFA/DEAM  
d) Informe N.º 00164-2023-OEFA/DEAM-STEC

**FECHA** : Lima, 28 de junio de 2023

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	Ámbito de la unidad fiscalizable Fundo Buena Palma - Sector Bimboya
b.	Unidad fiscalizable en la zona de estudio o actividades económicas	Unidad fiscalizable Fundo Buena Palma - Sector Bimboya de titularidad Roel Ermed Silva Agip ubicada en los distritos Padre Márquez y Nueva Requena, provincias Ucayali y Coronel Portillo, departamentos de Loreto y Ucayali.
c.	Problemática identificada	Falta de información de áreas que han tenido cambio de cobertura desde el 2017 al 2023 dentro de la unidad fiscalizable Fundo Buena Palma – Sector Bimboya.
d.	La actividad se realizó en el marco de	Memorando N.º 00435-2023-OEFA/DSAP
e.	Tipo de evaluación	Evaluación ambiental focal
f.	Periodo de ejecución	Análisis en gabinete de imágenes satelitales de las fechas 03 de octubre de 2017, 31 de diciembre de 2021, 21 de mayo de 2022 y 25 de enero de 2023.

**Tabla 1.2.** Listado de profesionales que aportaron al este documento

N.º	Nombres y Apellidos	Profesión	Actividad desarrollada	N.º de Colegiatura
1	Shianny Vásquez Cardeña	Ingeniero Geóloga	Gabinete	CIP 112995
2	Mariela Berenice Caballero del Castillo	Bióloga	Gabinete	CBP 4896



N.º	Nombres y Apellidos	Profesión	Actividad desarrollada	N.º de Colegiatura
3	Lourdes Liseth Espinoza Quiroz	Ingeniera Geógrafa	Gabinete	CIP 235285
4	Marco Antonio Miranda Valiente	Ingeniero Ambiental	Gabinete	CIP 180884
5	George Edward Navarro Ulloa	Bachiller en Ingeniería Geográfica	Gabinete	No Aplica

## 2. ANTECEDENTES

Mediante el Memorando N.º 435-2023-OEFA/DSAP, la Dirección de Supervisión Ambiental en Actividades Productivas (en adelante, DSAP) solicitó a la Dirección de Evaluación Ambiental (en adelante, DEAM) apoyo técnico para realizar un estudio mediante análisis multitemporal de imágenes satelitales de la unidad fiscalizable Fundo Buena Palma - Sector Bimboya (en adelante, UF Fundo Buena Palma) de titularidad de Roel Ermed Silva Agip, ubicada en los distritos Padre Márquez y Nueva Requena, provincias Ucayali y Coronel Portillo, departamentos de Loreto y Ucayali.

Con el objetivo de brindar el soporte solicitado por la DSAP, se llevó a cabo reuniones de coordinación y se generó el acta de inicio N.º AI-022-2023-ITEGI donde se definió el alcance y propuesta para la atención de la evaluación ambiental focal de la superficie terrestre mediante el análisis multitemporal de imágenes satelitales en el área de estudio de la UF Fundo Buena Palma de titularidad de Roel Ermed Silva Agip (Ver Anexo 1).

Los detalles de la planificación se encuentran en el Plan de Evaluación Ambiental Focal de la superficie terrestre en la UF Fundo Buena Palma ubicada en los distritos Padre Márquez y Nueva Requena, provincias Ucayali y Coronel Portillo, departamentos de Loreto y Ucayali, que ha sido aprobado mediante informe N.º 00164-2023-OEFA/DEAM-STEC (Ver Anexo 2).

En ese sentido, desde el 15 de mayo hasta el 13 de junio de 2023, los especialistas asignados por la DEAM (mediante Memorando N.º 00184-2023-OEFA/DEAM), realizaron en gabinete, el análisis y procesamiento de imágenes satelitales de la UF Fundo Buena Palma. Dichas imágenes satelitales corresponden a la misión Sentinel-2 de las fechas 03 de octubre de 2017, 31 de diciembre de 2021, 21 de mayo de 2022 y 25 de enero de 2023.

## 3. OBJETIVOS

### 3.1 Objetivo general

Evaluar la superficie terrestre en el ámbito de la UF Fundo Buena Palma de titularidad Roel Ermed Silva Agip, mediante técnicas de teledetección espacial<sup>1</sup>.

### 3.2 Objetivos específicos

- Identificar áreas de cambio de cobertura para los años 2017, 2021, 2022 y 2023 mediante técnicas de teledetección dentro de la UF Fundo Buena Palma.
- Estimar el área impactada por el cambio de cobertura en la UF Fundo Buena Palma para los años 2017, 2021, 2022 y 2023 mediante técnicas de teledetección.

<sup>1</sup> Técnica que nos permite obtener información a distancia de los objetos situados sobre la superficie terrestre. (Chuvieco, 2010)



#### 4. ÁREA DE ESTUDIO

El área de estudio comprende el ámbito UF Fundo Buena Palma, la cual está ubicada los distritos Padre Márquez y Nueva Requena, provincias Ucayali y Coronel Portillo, de los departamentos de Loreto y Ucayali (Figura 4.1).

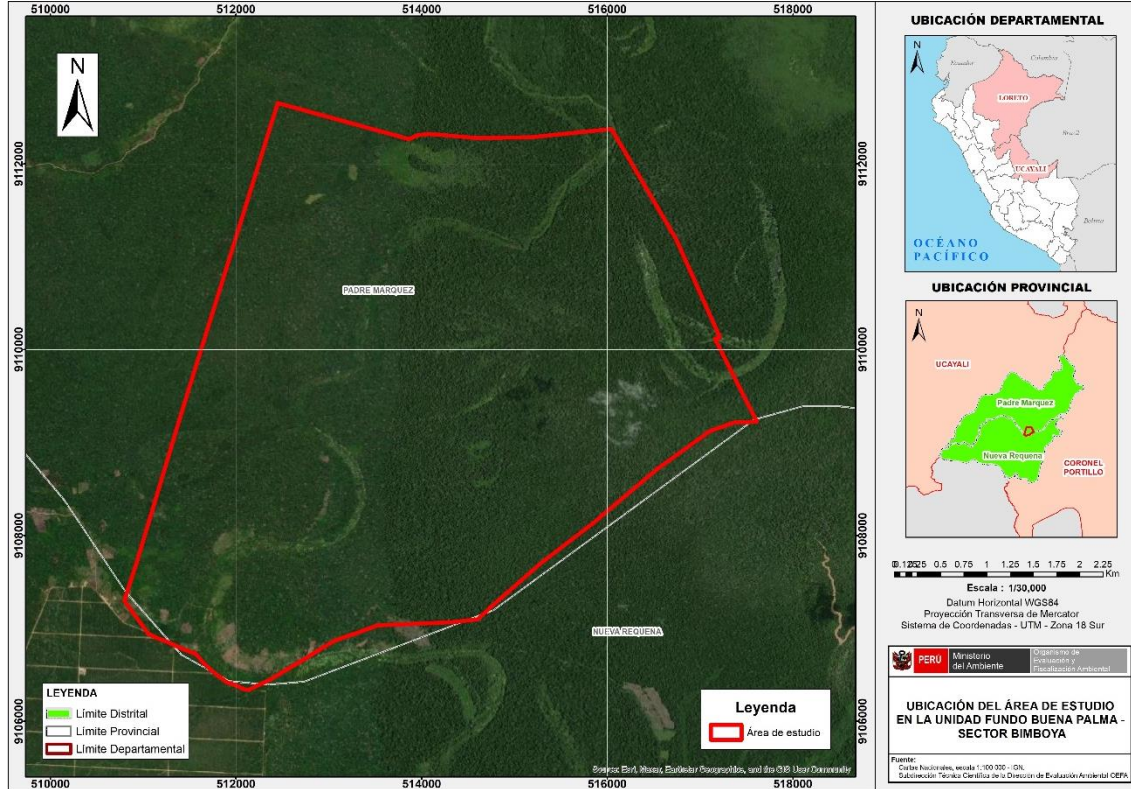


Figura 4.1. Ubicación del área de estudio en la UF Fundo Buena Palma

#### 5. METODOLOGÍA

Para la identificación de áreas de cambio de coberturas para los años 2017, 2021, 2022 y 2023 en la UF Fundo Buena Palma, se utilizaron los documentos indicados en la Tabla 5.1.

Tabla 5. Referencias empleadas

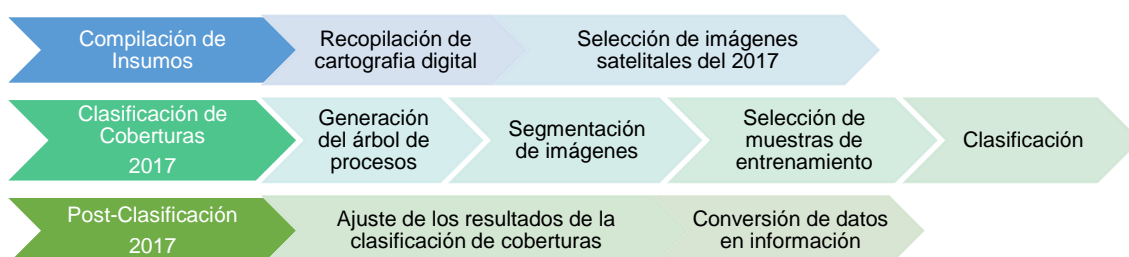
Matriz	Nombre	Sección	Dispositivo Legal	Entidad	País
Superficie terrestre	Manual técnico «Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales»	Todas las secciones	Marco del Convenio de Contrato 002-017-MINAGRI-DVDIAR-UEGPS/DE-PIADER y el Consorcio AIDER y SOUTH POLE CARBON ASSET MANAGEMENT	Ministerio de Desarrollo Agrario y Riego - MIDAGRI	Perú
	Trimble eCognition Developer for Windows operating system	Todas las secciones	--	Trimble	Alemania

El procedimiento metodológico se realizó de manera semi-automatizada para identificar las clases de cobertura por año mediante el análisis de imágenes satelitales obtenidas de la

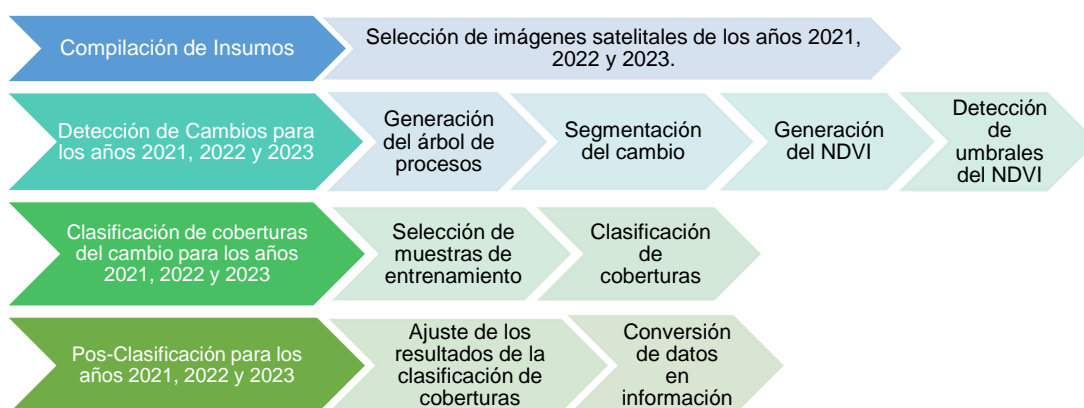


plataforma *Google Earth Engine*<sup>2</sup> en el área de estudio de la UF Fundo Buena Palma. Se realizaron dos (2) etapas de procesamiento, la primera consistió en la clasificación de coberturas para el 03 de octubre de 2017 (fecha base), y la segunda en la detección y clasificación sólo de los segmentos de cambio, manteniendo las demás áreas constantes para las fechas 31 de diciembre de 2021, 21 de mayo de 2022 y 25 de enero de 2023 (Figura 5.1 y Figura 5.2)

Se eligió el método de segmentación de la imagen empleado por MIDAGRI (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 2017.



**Figura 5.2.** Esquema de la metodología semi-automatizada para la detección y clasificación de cambios de cobertura analizados para los años 2021, 2022 y 2023.

<sup>2</sup> 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)



## 5.1. Clasificación para el 2017

### 5.1.1. 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
Roel Ermed Silva Agip	Límites de la UF Fundo Buena Palma

#### b. Selección de imágenes satelitales

Para la selección de la imagen satelital disponible para el 2017 se empleó la plataforma de *Google Earth Engine*<sup>3</sup> y se consultó la colección de imágenes satelitales de la misión Sentinel-2, las cuales se encuentran disponibles de forma gratuita y poseen una buena resolución espacial y espectral conveniente para los objetivos de la presente evaluación, como se muestra en la Tabla 5.3.

**Tabla 5.3.** Característica de las imágenes satelitales Sentinel 2

Sentinel-2 Bandas	Longitud de onda ( $\mu\text{m}$ )	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
Banda 11 - <i>SWIR</i>	1,610	20
Banda 12 - <i>SWIR</i>	2,190	20

Las escenas fueron seleccionadas teniendo en consideración los siguientes tres (3) criterios: (i) la fecha en la que fue tomada la imagen satelital, siendo de prioridad la más reciente; (ii) que la imagen satelital sea de nivel 2A (imagen ortorectificada y corregida atmosféricamente); y, (iii) 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.

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

<sup>3</sup> <https://code.earthengine.google.com/>



```
//Definición de "geometry"
var table = ee.FeatureCollection("users/OEFA_DSAP_BUENA_PALMA"),
    geometry =
    /* color: #d63000 */
    /* shown: false */
    /* displayProperties: [
    {
    "type": "rectangle"
    }
    ] */
    ee.Geometry.Polygon(
    [[[-76.07083793420857, -13.729916265236007],
    [-76.07083793420857, -13.746841409394511],
    [-76.04830737848347, -13.746841409394511],
    [-76.04830737848347, -13.729916265236007]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')
    .filterBounds (geometry)
    .filterDate ('2017-10-02','2017-10-04')
    .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: '20171003_TOA',
    scale: 10, region: geometry});
```

### 5.1.2. Clasificación de coberturas

#### a. Generación del árbol de procesos

Para la generación del árbol de procesos se empleó el *software eCognition Developer 10.1 Trial*<sup>4</sup> (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 ArcGIS*<sup>5</sup>.
- Clasificación con los algoritmos de *Classifier* utilizando el método de *Random Forest*.

<sup>4</sup> Programa especializado para la clasificación de objetos.

<sup>5</sup> Programa especializado en geoprocesamientos

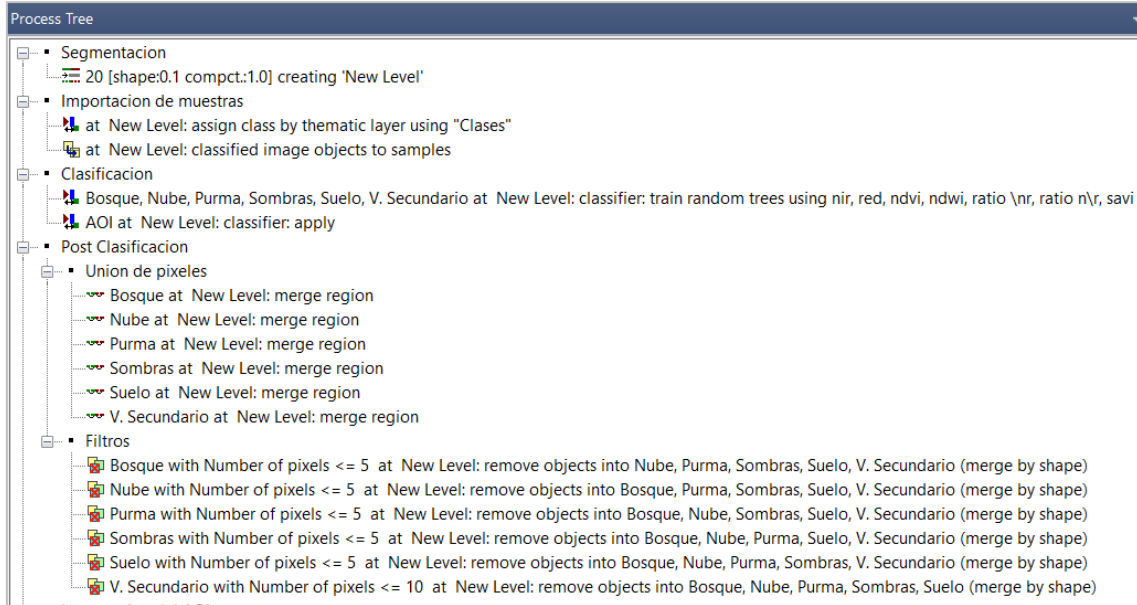


Figura 5.3. Regla de procesos para la clasificación de coberturas en el software eCognition Developer 10.1 Trial.

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

**Índice de vegetación diferenciada normalizada**

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 de vegetación diferenciada normalizada

NIR = Reflectancia en la banda del infrarrojo cercano

RED = Reflectancia en la banda roja del visible

**Índice diferencial de agua normalizado**

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

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:

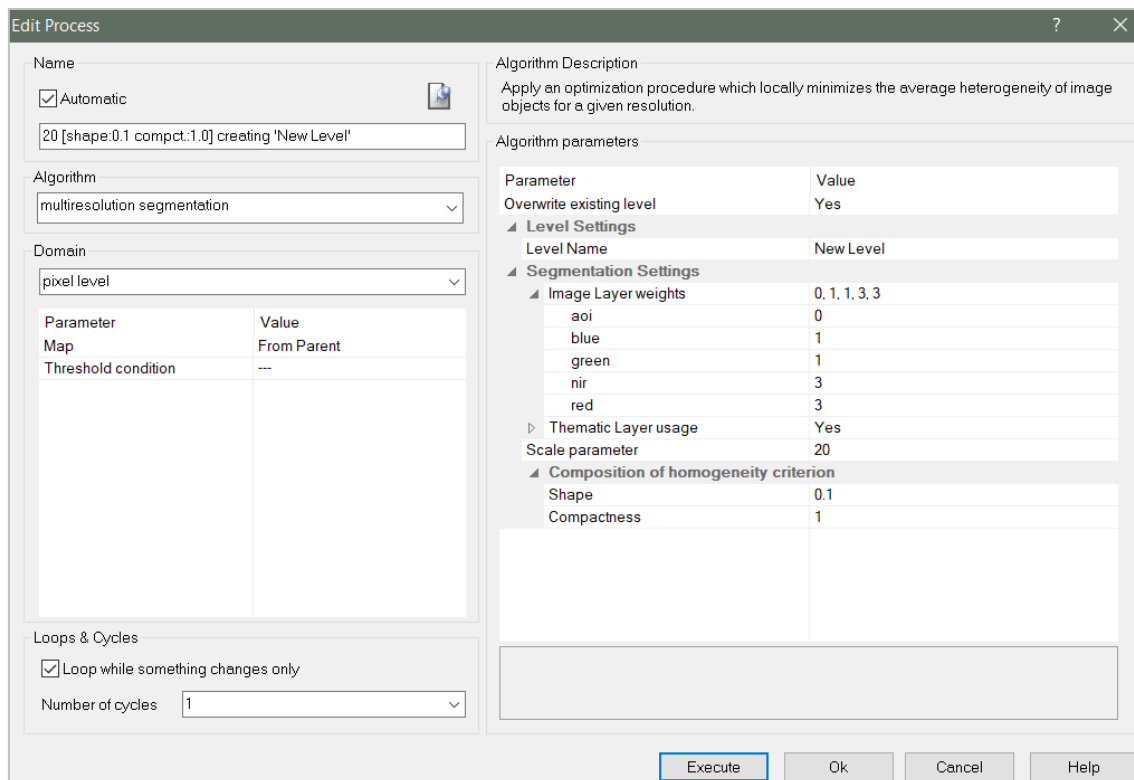
- Desviación estándar y mediana.
- Textura (muchos tipos).
- Extensión (por ejemplo: área, longitud, ancho, etc.).
- Forma (por ejemplo: redondo, asimétrico, compacto, etc.).
- Relaciones con los segmentos vecinos (diferencia media con los vecinos).

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 B3-GREEN y B8-NIR, colocándole los valores de 1, y a las demás bandas el valor nulo (0).
- 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* = 20, *Shape* = 0,1 y *Compactness* = 1 (Figura 5.4).



**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 con apoyo de la fointerpretación de las imágenes satelitales. En base a todo ello se definieron cuatro (4) clases de cobertura: Bosque húmedo, Purma, Suelo y vegetación secundaria. Cabe precisar que nube y sombras de nube fueron clasificadas 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 cuatro (4) clases definidas y descritas en sus respectivos atributos. Posteriormente con el *software* Envi 5.3<sup>6</sup> se verificó que las muestras seleccionadas cuentan con la firma espectral característica de cada clase identificada, 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.

<sup>6</sup> Programa especializado para el tratamiento digital de imágenes satelitales.

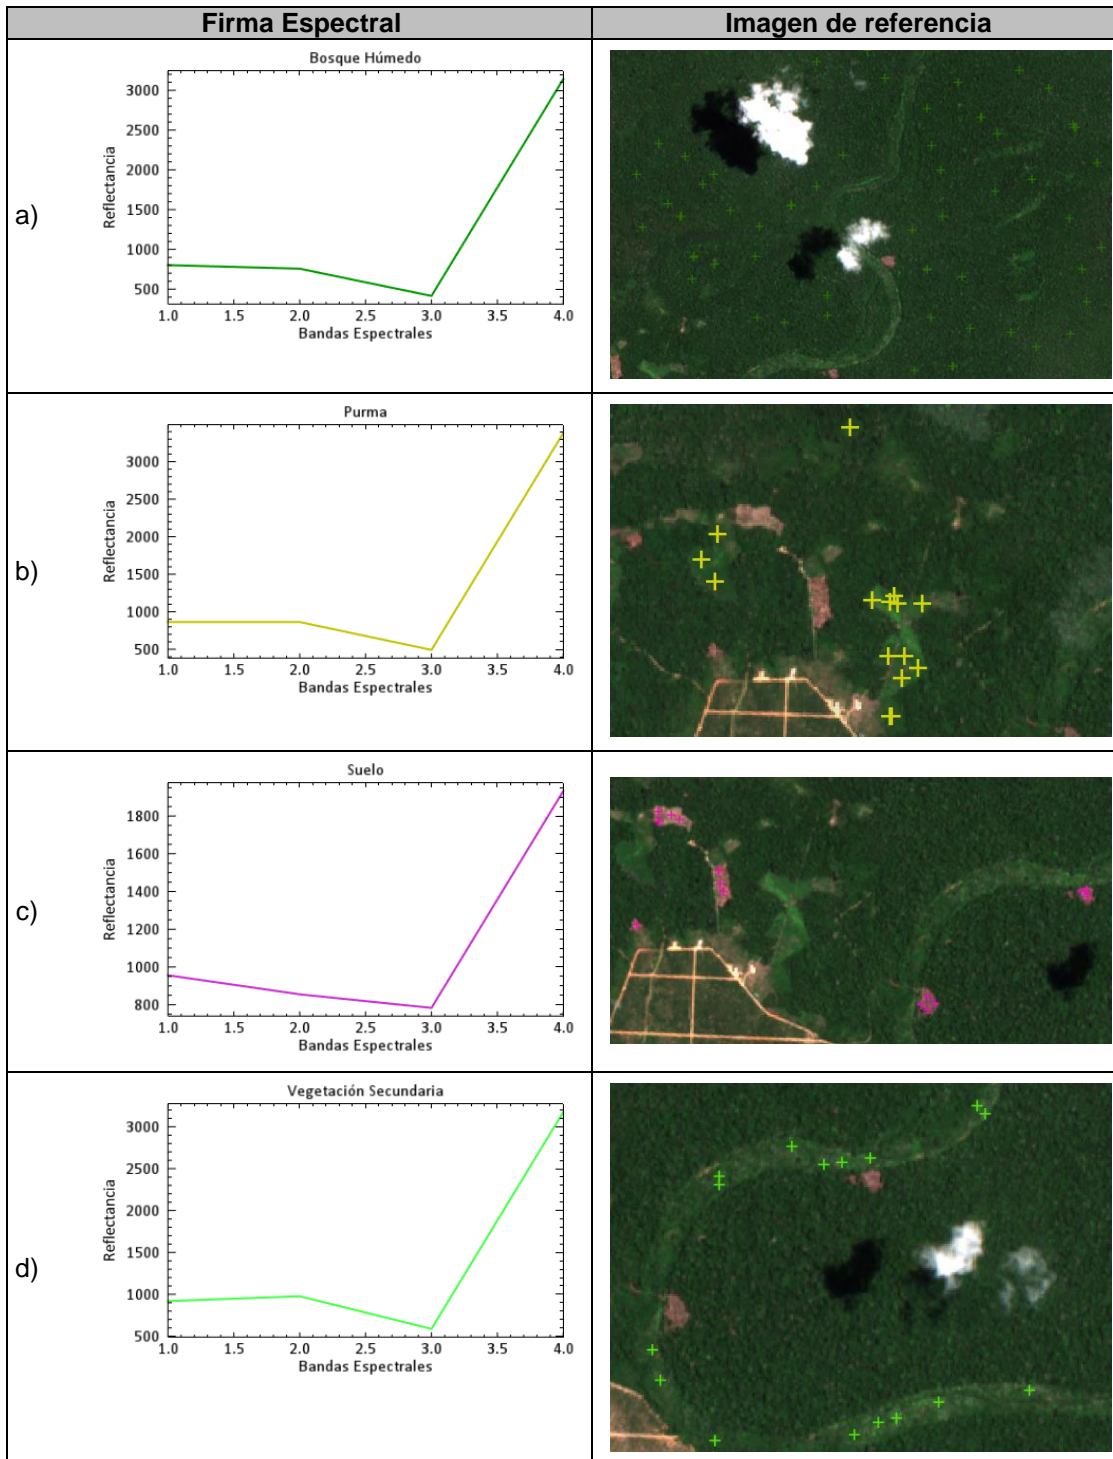


Figura 5.5. Firmas espectrales de la clase identificada: a) bosque húmedo, b) purma, c) suelo y d) vegetación secundaria

#### d. Clasificación de coberturas

En el *Árbol de Procesos*<sup>7</sup> se configuraron los parámetros del algoritmo de clasificación que permitieron interactuar con las muestras de entrenamiento. Se introdujeron los índices y

<sup>7</sup> 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.



ratios, así como las medianas de las bandas B2-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.

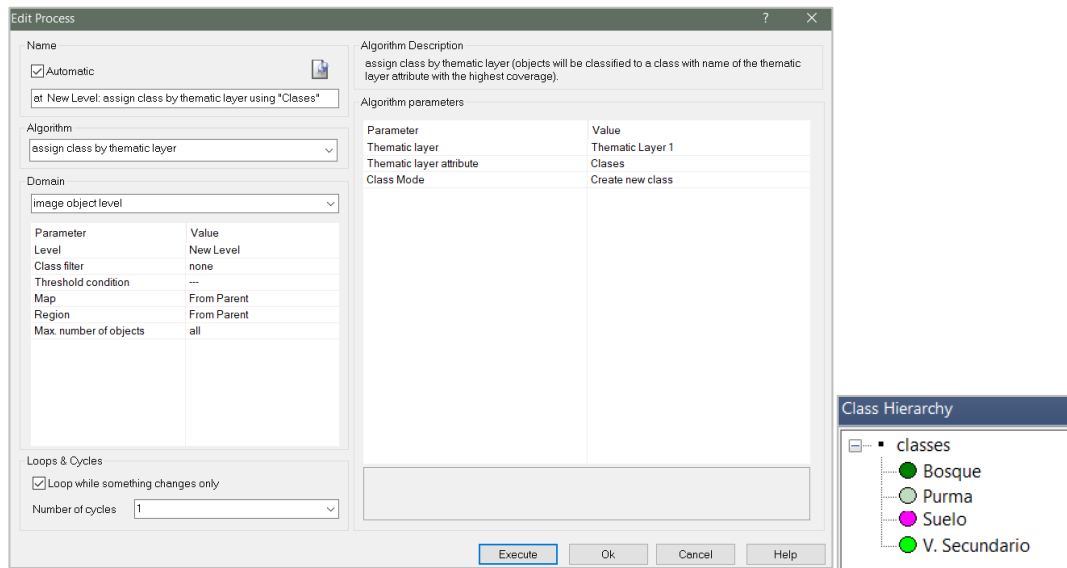


Figura 5.6. Relación de atributos y creación de clases

**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 los índices generados (NDVI, NDWI, SAVI y ratios) que influyen en la clasificación, tal como muestra la Figura 5.7.



“Decenio de la Igualdad de Oportunidades para Mujeres y Hombres”  
“Año de la unidad, la paz y el desarrollo”

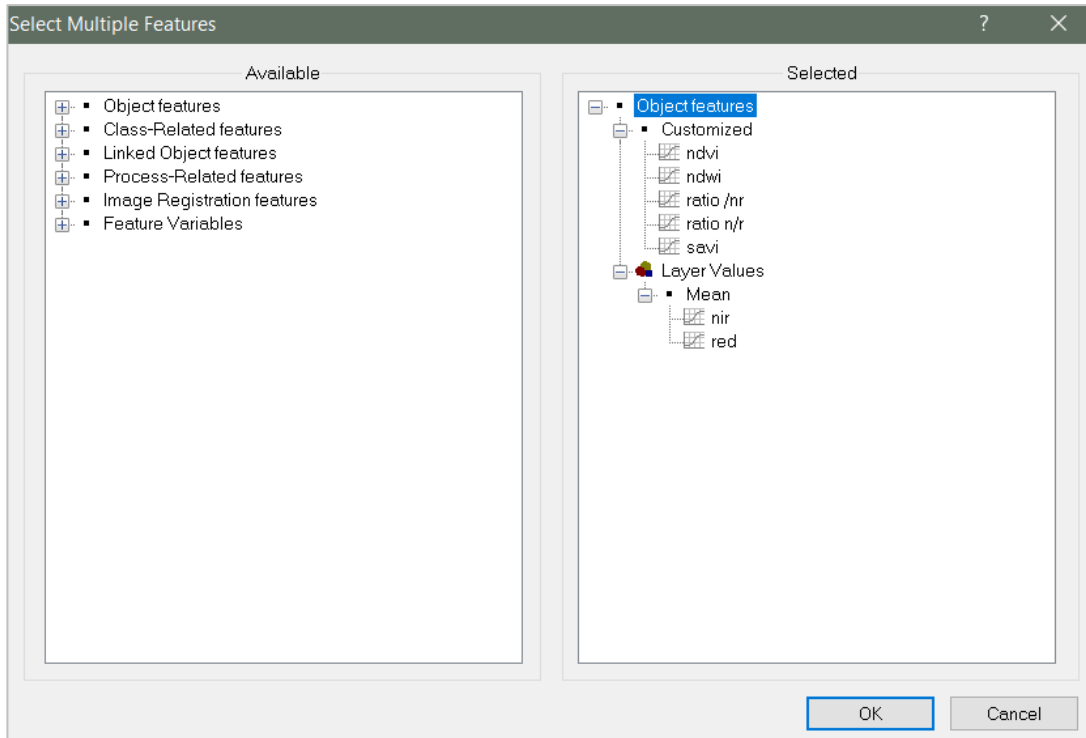


Figura 5.7. Ventana de *Select Múltiple Feature*, permite agregar parámetros, índice y ratios a la clasificación

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

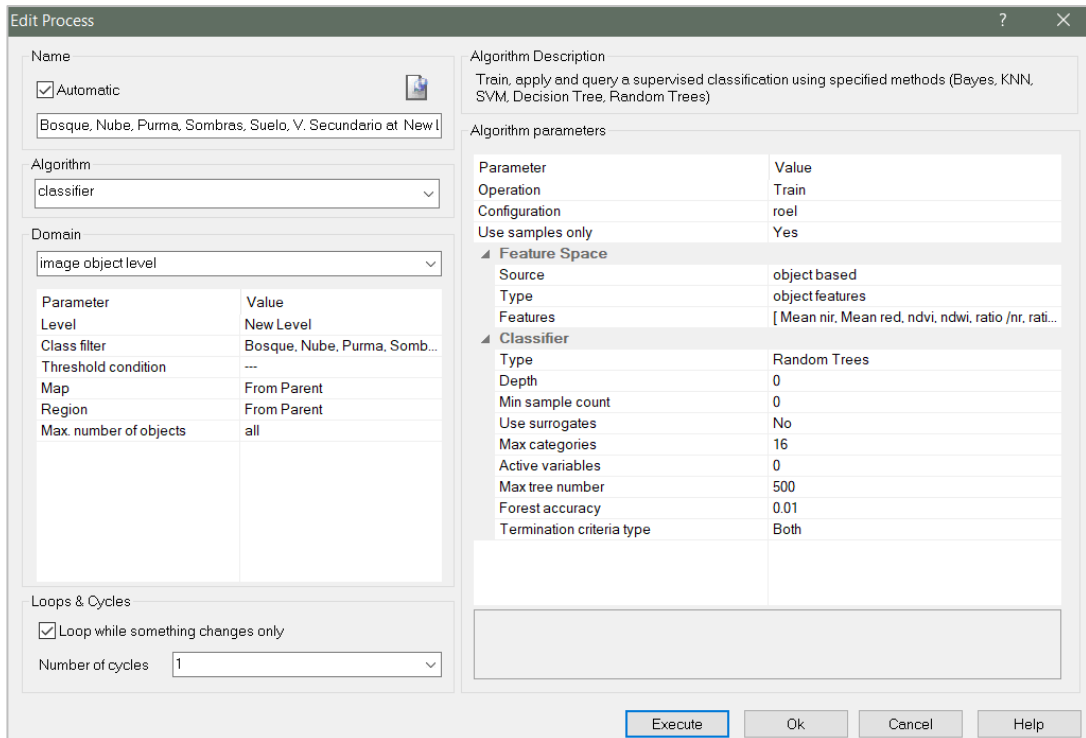


Figura 5.8. Configuración del clasificador del algoritmo *Random Forest*

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

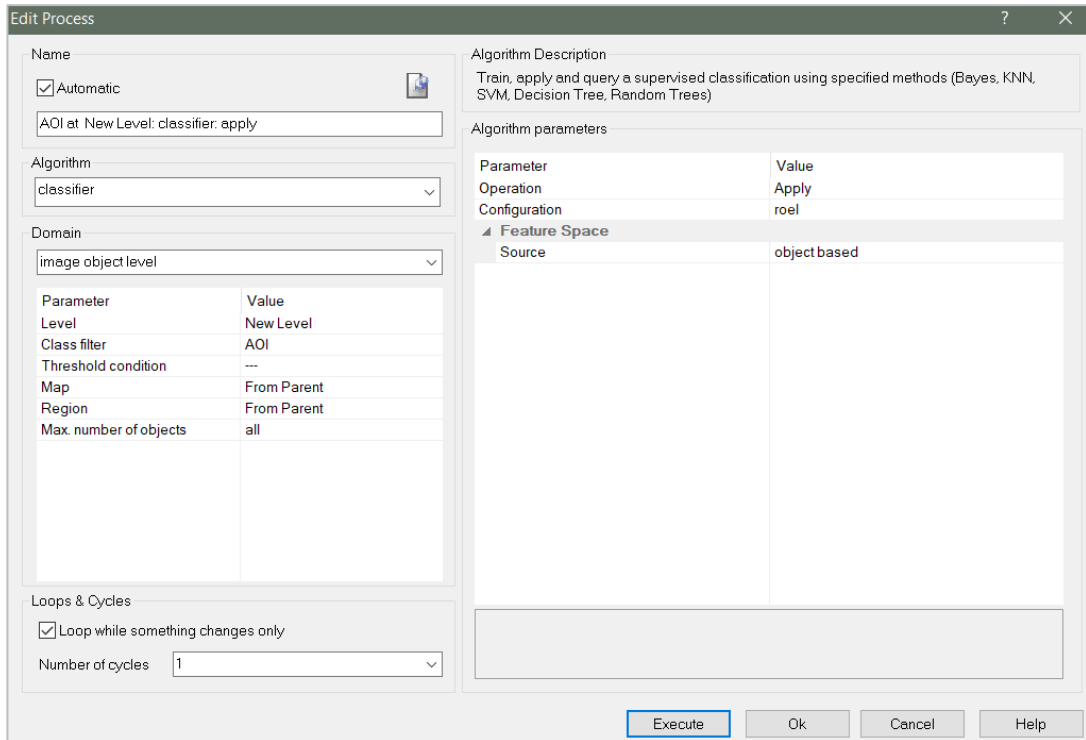


Figura 5.9. Configuración de la aplicación del algoritmo Classifier

### 5.1.3. Post Clasificación del 2017

#### 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*.



## 5.2. Detección y clasificación de cambios de coberturas para los años 2021, 2022 y 2023

### 5.2.1. Compilación de insumos

#### a. Selección de imágenes satelitales

Para la selección de imágenes satelitales disponibles para las fechas 31 de diciembre de 2021, 21 de mayo de 2022 y 25 de enero de 2023, se empleó la plataforma de *Google Earth Engine* y se consultó la colección de imágenes satelitales de la misión Sentinel-2, las cuales se encuentran disponibles de forma gratuita y poseen una buena resolución espacial y espectral conveniente para los objetivos de la presente evaluación, como se muestra en la Tabla 5.3. Cabe precisar que para la fecha 03 de octubre de 2017 se encuentra descrita en la sección b del subtítulo 5.1.1.

Las escenas fueron seleccionadas teniendo en consideración los siguientes tres (3) criterios: (i) la fecha en la que fue tomada la imagen satelital, siendo de prioridad la más reciente; (ii) que la imagen satelital sea de nivel 2A (imagen ortorectificada y corregida atmosféricamente); y, (iii) 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.

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

- Para el 31 de diciembre de 2021

```
//Definición de "geometry"
var table = ee.FeatureCollection("users/OEFA_DSAP_BUENA_PALMA"),
    geometry =
    /* color: #d63000 */
    /* shown: false */
    /* displayProperties: [
    {
    "type": "rectangle"
    }
    ] */
    ee.Geometry.Polygon(
    [[[-76.07083793420857, -13.729916265236007],
    [-76.07083793420857, -13.746841409394511],
    [-76.04830737848347, -13.746841409394511],
    [[[-76.07083793420857, -13.729916265236007],
    [-76.04830737848347, -13.729916265236007]]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')
    .filterBounds (geometry)
    .filterDate ('2021-12-30','2022-01-01')
    .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: '20211231_TOA',  
scale: 10,  
region: geometry});
```

- Para el 21 de mayo de 2022

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_BUENA_PALMA"),  
geometry =  
/* color: #d63000 */  
/* shown: false */  
/* displayProperties: [  
  {  
    "type": "rectangle"  
  }  
]*/  
ee.Geometry.Polygon(  
  [[[-76.07083793420857, -13.729916265236007],  
    [-76.07083793420857, -13.746841409394511],  
    [-76.04830737848347, -13.746841409394511],  
    [[[-76.07083793420857, -13.729916265236007],  
      [-76.04830737848347, -13.729916265236007]]], null, false];  
//Imagen para SENTINEL 2A  
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')  
.filterBounds (geometry)  
.filterDate ('2022-05-20','2022-05-22')  
.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: '20220521_TOA',  
scale: 10,  
region: geometry});
```

- Para el 25 de enero de 2023

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_BUENA_PALMA"),  
geometry =  
/* color: #d63000 */  
/* shown: false */
```



```

/* displayProperties: [
  {
    "type": "rectangle"
  }
]*/
ee.Geometry.Polygon(
  [[[[-76.07083793420857, -13.729916265236007],
    [-76.07083793420857, -13.746841409394511],
    [-76.04830737848347, -13.746841409394511],
    [[[-76.07083793420857, -13.729916265236007],
    [-76.04830737848347, -13.729916265236007]], null, false];
//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')
.filterBounds (geometry)
.filterDate ('2023-01-24','2023-01-26')
.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: '20230125_TOA',
  scale: 10,
  region: geometry});

```

En la Tabla 5.4 se resume las imágenes satelitales empleadas para el análisis de teledetección.

Tabla 5.4. Resumen de imágenes satelitales usadas

Fecha	Sensor	Fecha de captura	Tipo de descarga	Nivel de tratamiento
31/12/2021	Sentinel 2A	2021-12-30 / 2022-01-01	Mosaico de imágenes	Reflectancia TOA
21/05/2022	Sentinel 2A	2022-05-20 / 2022-05-22	Mosaico de imágenes	Reflectancia TOA
25/01/2023	Sentinel 2A	2023-01-24 / 2023-01-26	Mosaico de imágenes	Reflectancia TOA

### 5.2.2. Detección de cambios

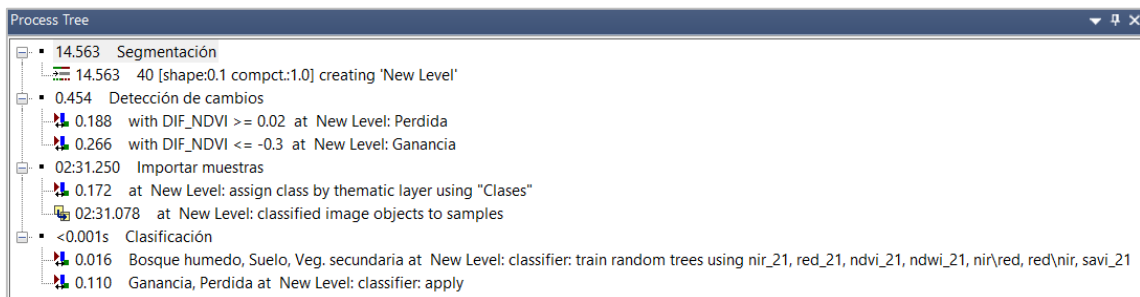
#### a. Generación del árbol de procesos

Para la generación del árbol de procesos se empleó el software *eCognition Developer* 10.1 Trial (Figura 5.10), 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. Las muestras han sido creadas previamente mediante el *software* ArcGIS.
- 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.



**Figura 5.10.** 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) a la fecha (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 fecha 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 uno (1), y a las demás bandas dejar con valor nulo (cero), 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* = 40, *Shape* = 0,1 y *Compactness* = 1 (Figura 5.11).

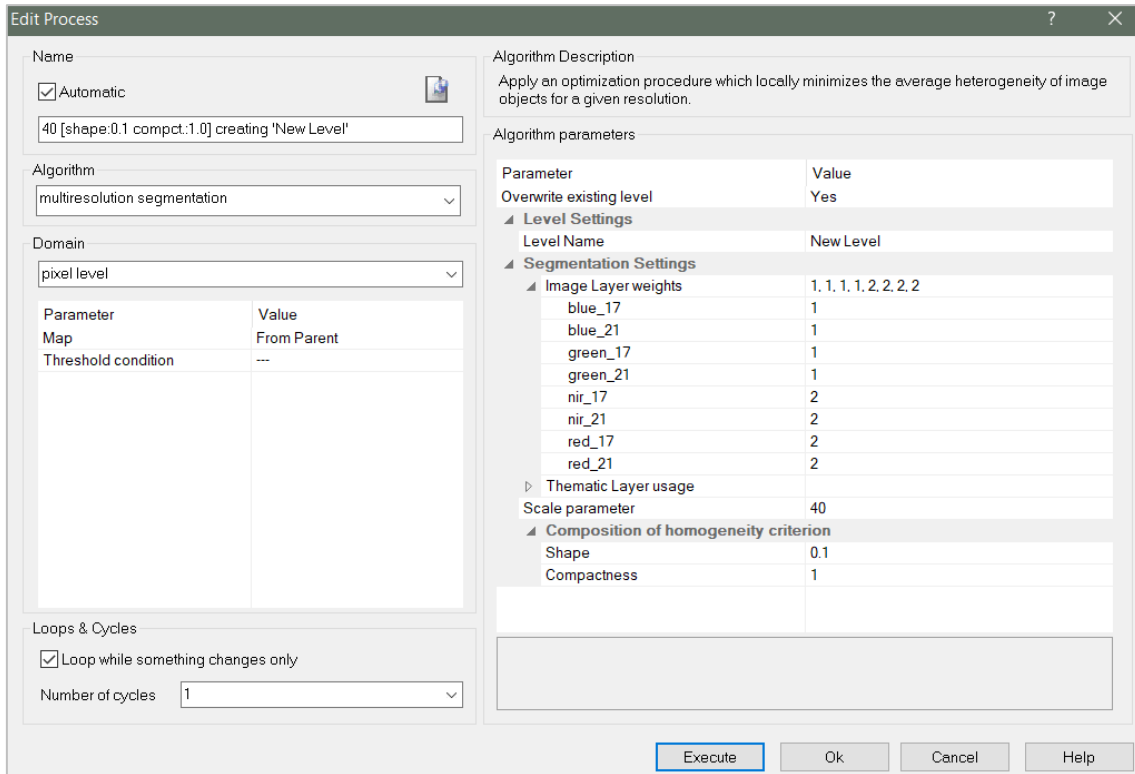


Figura 5.11. Resultado de la configuración de parámetros para la segmentación en *eCognition Developer 10.1 Trial*.

### c. Generación del Índice de vegetación diferenciada normalizada (NDVI)

Para el proceso de detección de cambios es de suma importancia contar con los NDVI de cada fecha, 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 NDVIs, 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 ganancia en la reflectancia de una zona que ha sido intervenido en el año 1, a lo que uno puede interpretar como una emergencia 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 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 pérdida son todos aquellos valores mayores a 0,02, y aquellos valores que representan la ganancia son menores a -0,3.

### 5.2.3. Clasificación de coberturas de cambio

#### a. Selección de muestras de entrenamiento

La segmentación y detección del cambio generaron muestras de entrenamiento (puntos) con su respectivo atributo (nombre de la clase) con apoyo de la fotointerpretación de las imágenes satelitales. Se definieron clases de cobertura por cada año analizado considerando el mismo criterio de selección de muestras mencionado en la sección c del subtítulo 5.1.2.

#### b. Clasificación de coberturas

Esta clasificación se realizó para la fecha 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 5.12.

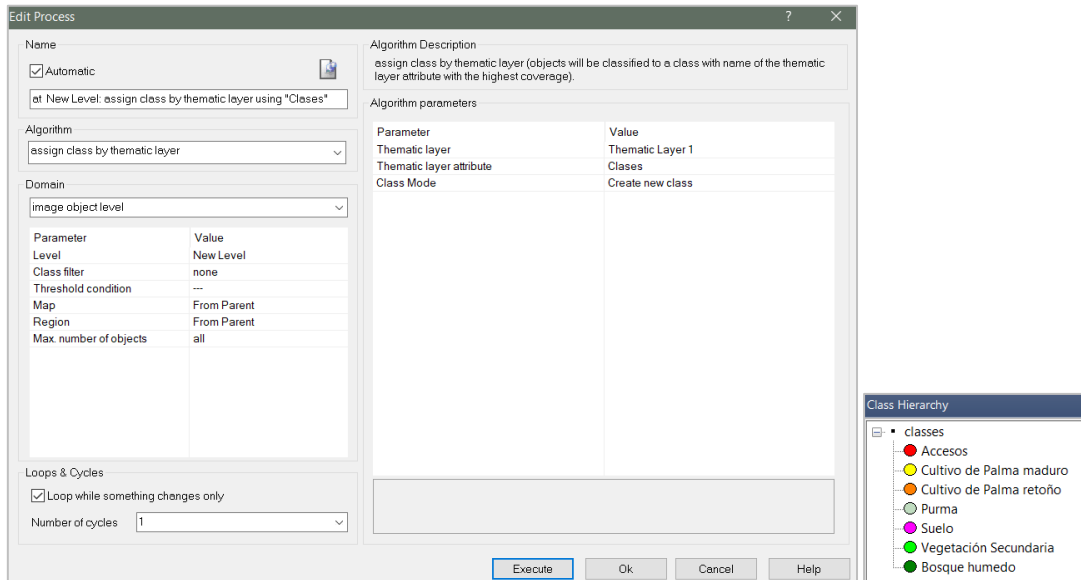


Figura 5.12. Relación de atributos y creación de clases

#### ii. Asignación de clases a los segmentos:

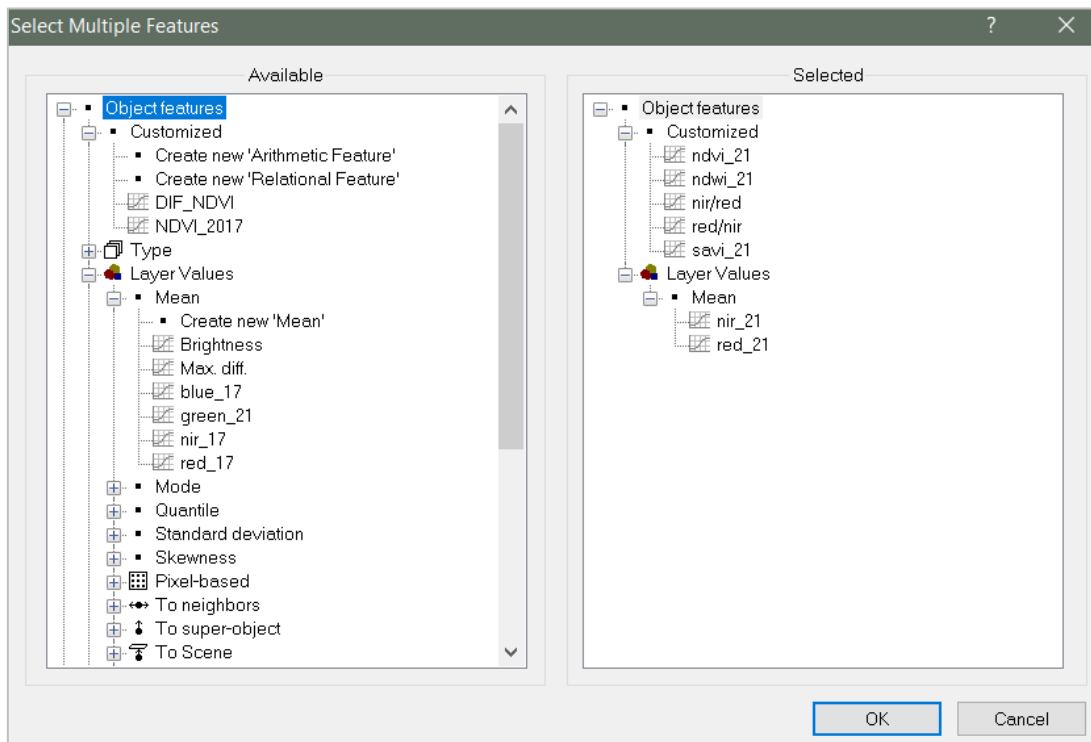
Posteriormente en el software *eCognition Developer 10.1 Trial* se configuró el algoritmo *Classified Image Objects to Samples*, el cual convirtió las muestras de entrenamiento de puntos a segmentos, relacionando los atributos y asignándole las clases, generando finalmente las muestras a nivel de segmento.



### 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*), índices NDWI, SAVI y ratios que influyen en la clasificación, tal como muestra la Figura 5.13.



**Figura 5.13.** 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 5.14.



“Decenio de la Igualdad de Oportunidades para Mujeres y Hombres”  
“Año de la unidad, la paz y el desarrollo”

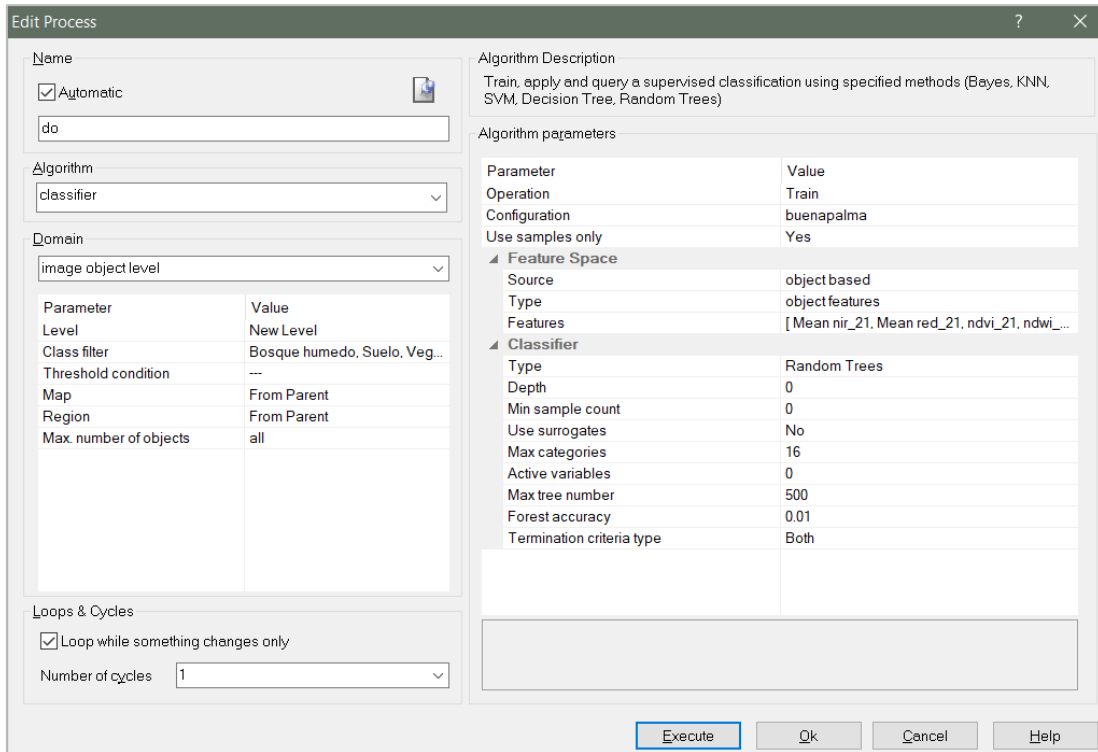


Figura 5.14. Configuración del clasificador del algoritmo *Random Forest*

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 5.15.

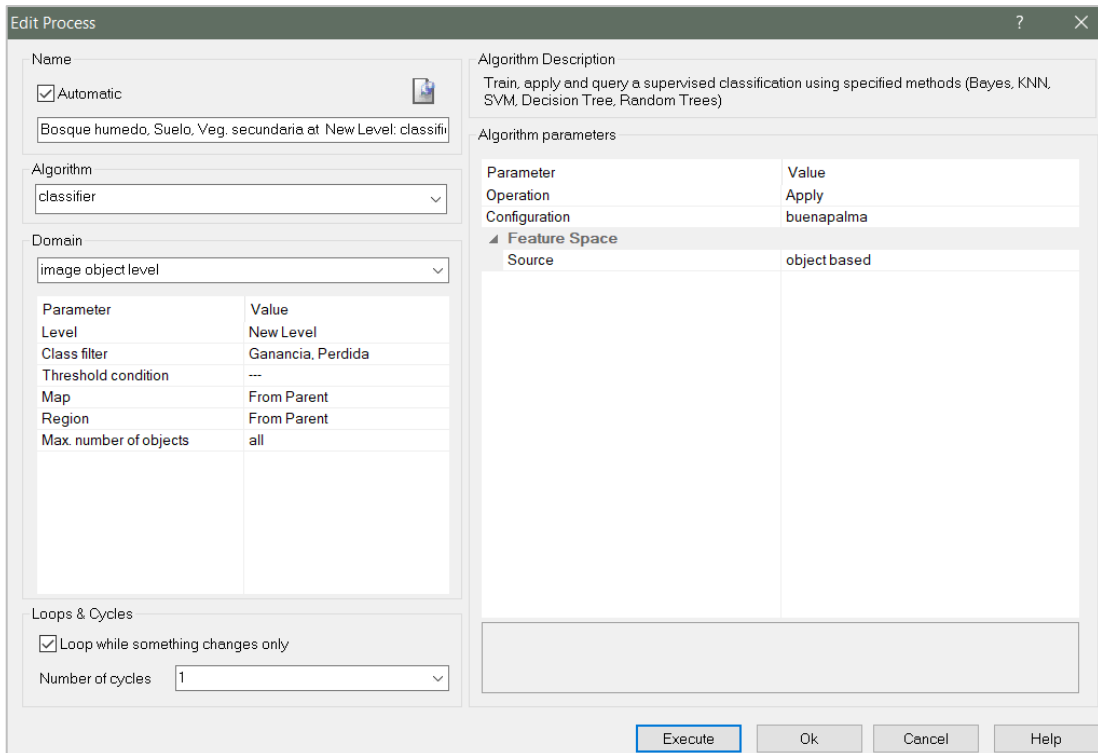


Figura 5.15. Configuración de la aplicación del algoritmo *Classifier*



#### 5.2.4. Post-Clasificación para los años 2021, 2022 y 2023

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



### 6. RESULTADOS

De la identificación de áreas de coberturas para los años 2017, 2021, 2022 y 2023 mediante el análisis multitemporal de imágenes satelitales dentro de la UF Fundo Buena Palma, se detalla lo siguiente:

Para el 2017 se identificaron siete (7) clases de coberturas; *Bosque húmedo* con una extensión de 2461,16 ha, *Purma* con una extensión de 7,86 ha, *Suelo* con una extensión 8,80 ha, *vegetación secundaria* con una extensión de 123,81 ha, *accesos* con una extensión de 0,35 ha, *nube* con una extensión de 81,34 ha; y, *Sombras de nube* con una extensión de 69,55 ha (Figura 6.1).

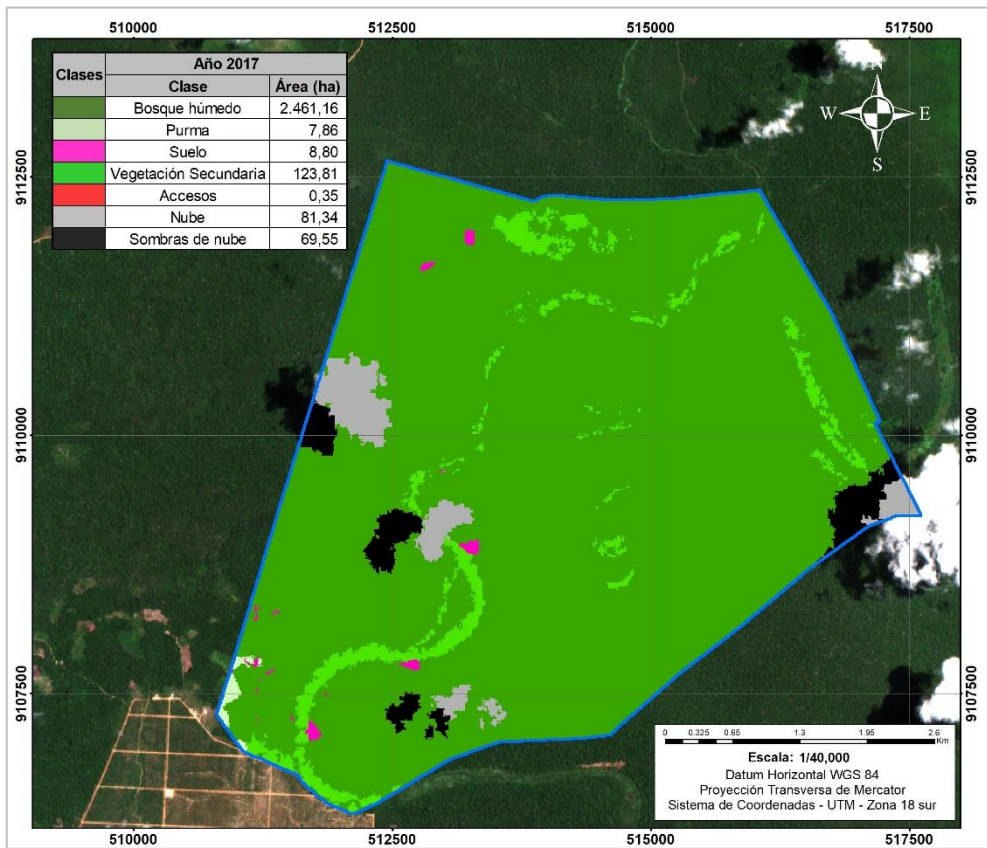


Figura 6.1. Clases de cobertura del 2017 dentro del área de la UF Fundo Buena Palma

Para el 2021 se identificaron ocho (8) clases de coberturas; *Bosque húmedo* con una extensión de 2083,79 ha, *Purma* con una extensión de 98,05 ha, *Suelo* con una extensión 300,76 ha, *vegetación secundaria* con una extensión de 163,21 ha, *Cultivos de palma retoño* con una extensión de 51,48 ha, *accesos* con una extensión de 23,41 ha, *nube* con una extensión de 51,48 ha; y, *Sombras de nube* con una extensión de 69,55 ha (Figura 6.2).



“Decenio de la Igualdad de Oportunidades para Mujeres y Hombres”  
“Año de la unidad, la paz y el desarrollo”

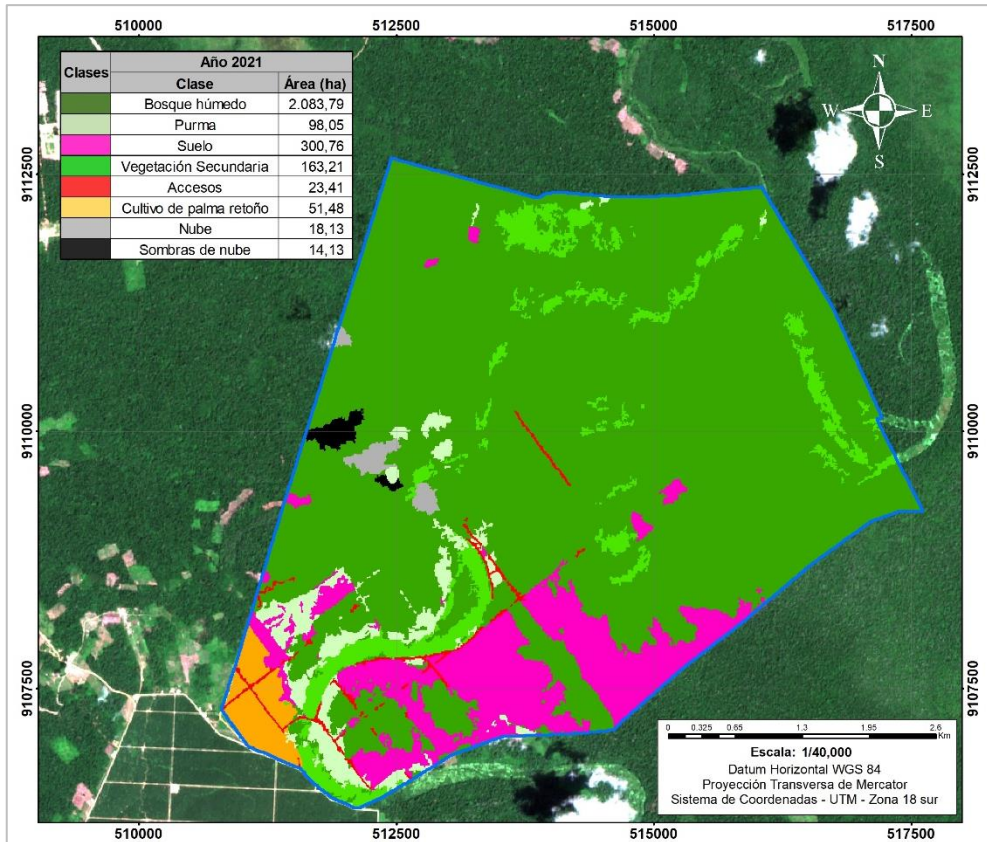


Figura 6.2. Clases de cobertura del 2021 dentro del área de la UF Fundo Buena Palma

Para el 2022 se identificaron siete (7) clases de coberturas; *Bosque húmedo* con una extensión de 1926,53 ha, *Purma* con una extensión de 149,56 ha, *Suelo* con una extensión 364,20 ha, vegetación secundaria con una extensión de 195,37 ha, *Cultivos de palma retoño* con una extensión de 82,52 ha, *Cultivos de palma maduro* con una extensión de 0,06 ha; y, *accesos* con una extensión de 34,72 ha (Figura 6.3).



“Decenio de la Igualdad de Oportunidades para Mujeres y Hombres”  
“Año de la unidad, la paz y el desarrollo”

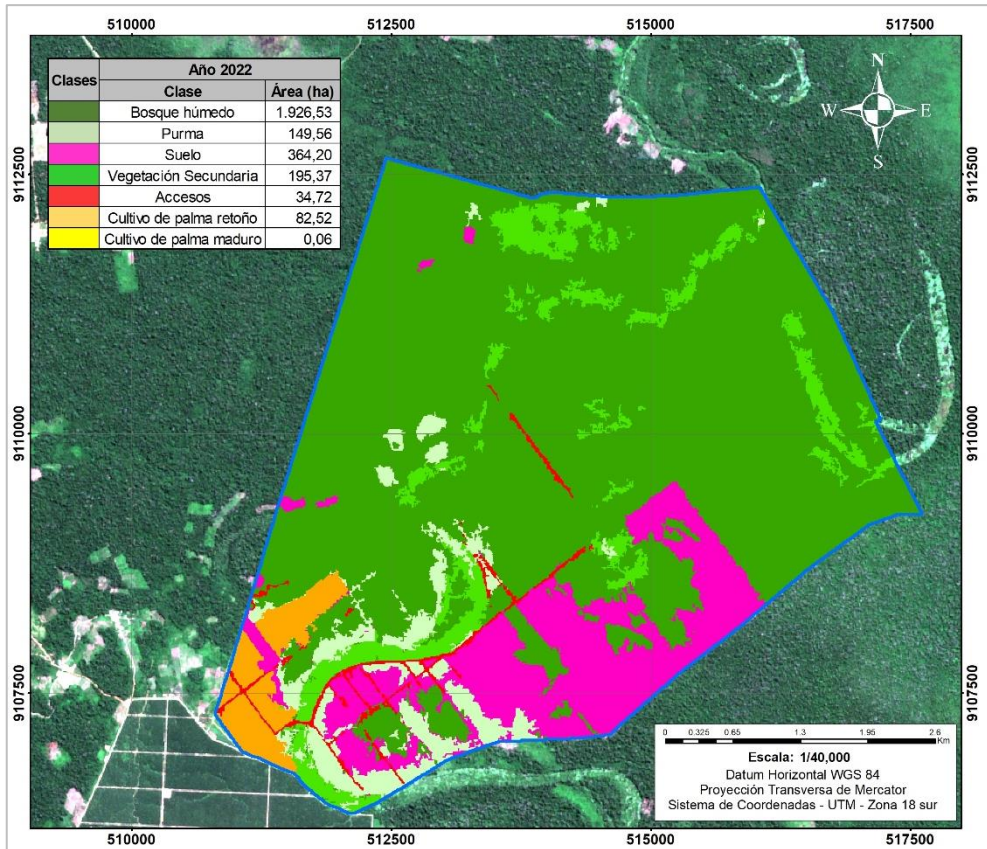


Figura 6.3. Clases de cobertura del 2022 dentro del área de la UF Fundo Buena Palma

Para el 2023 se identificaron ocho (8) clases de coberturas; *Bosque húmedo* con una extensión de 1638,67 ha, *Purma* con una extensión de 228,68 ha, *Suelo* con una extensión 548,39 ha, *vegetación secundaria* con una extensión de 198,66 ha, *Cultivos de palma retoño* con una extensión de 83,71 ha, *Cultivos de palma maduro* con una extensión de 0,05 ha, *accesos* con una extensión de 34,53 ha; y, *cuerpos de agua* con una extensión de 20,27 ha (Figura 6.4).



“Decenio de la Igualdad de Oportunidades para Mujeres y Hombres”  
“Año de la unidad, la paz y el desarrollo”

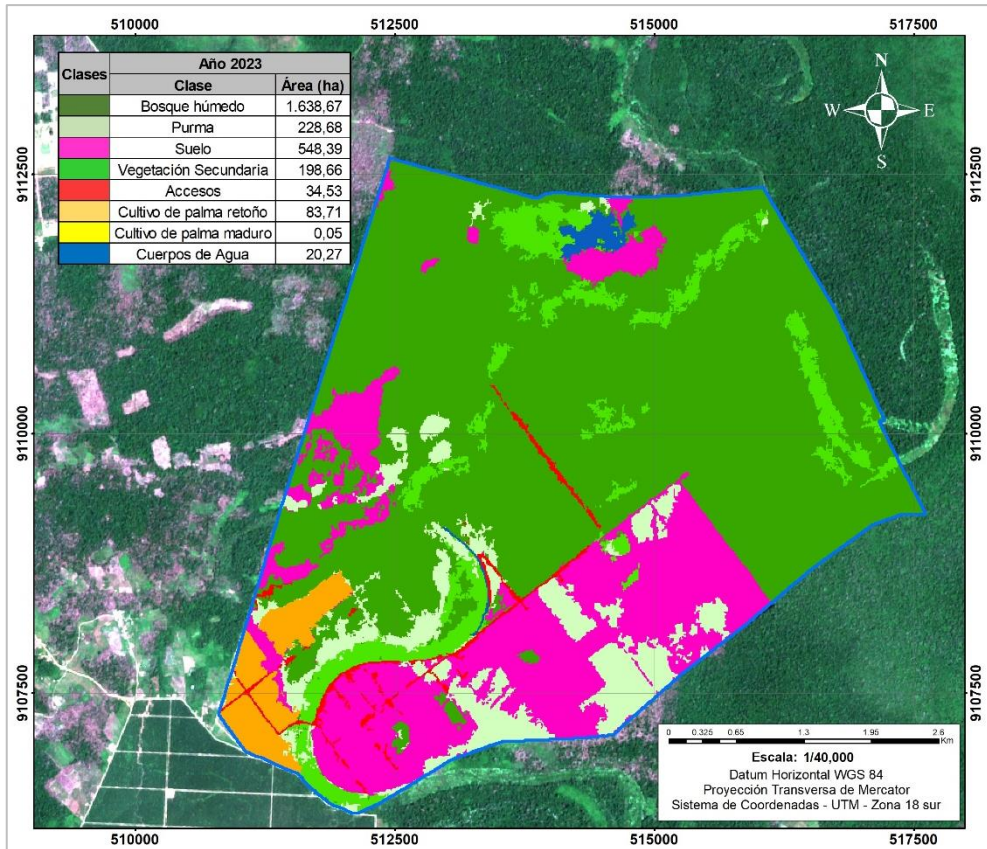


Figura 6.4. Clases de cobertura del 2023 dentro del área de la UF Fundo Buena Palma

De la estimación del área cambio de cobertura para el 2017, 2021, 2022 y 2023 se tiene que el Bosque húmedo ha tenido una pérdida de cobertura de 822,49 ha equivalente al 33,5% de la cobertura inicial, el suelo y la purma han aumentado en 539,59 ha y 220,82 ha respectivamente. El Cultivo de Palma retoño ha aumentado debido al crecimiento en la producción agrícola de la zona en 83,71 ha así como los accesos en 34,18 ha. Para el 2023 se evidencia la presencia de cuerpos de agua al norte de la UF en 20,27 ha (Tabla 6.1)

Tabla 6.1. Superficie de coberturas por año clasificado

Clases	Clases	2017	2021	2022	2023
	Bosque húmedo	2.461,16	2.083,79	1.926,53	1.638,67
	Purma	7,86	98,05	149,56	228,68
	Suelo	8,80	300,76	364,20	548,39
	Vegetación Secundaria	123,81	163,21	195,37	198,66
	Accesos	0,35	23,41	34,72	34,53
	Cultivo de palma retoño	-	51,48	82,52	83,71
	Cultivo de palma maduro	-	-	0,06	0,05
	Cuerpos de Agua	-	-	-	20,27
	Nube	81,34	18,13	-	-
	Sombras de nube	69,55	14,13	-	-



## 7. CONCLUSIONES

- i. Como resultado del análisis de las imágenes satelitales, se identificaron siete (7) clases de coberturas en el 2017 como son; Bosque húmedo, Purma, Suelo, Vegetación secundaria, Accesos, Nube y Sombras de nube; ocho (8) clases de coberturas en el 2021: Bosque húmedo, Purma, Suelo, Vegetación secundaria, Cultivos de palma retoño, Accesos, Nube y Sombras de nube; siete (7) clases de coberturas en el 2022: Bosque húmedo, Purma, Suelo, Vegetación secundaria, Accesos, Cultivo de palma retoño y cultivo de palma maduro; y, finalmente ocho (8) clases de coberturas en el 2023; Bosque húmedo, Purma, Suelo, Vegetación secundaria, cultivos de palma retoño, cultivo de palma maduro, los accesos y los cuerpos de agua.
- ii. Se estimaron las extensiones de las áreas de cambio de cobertura para el 2017, 2021, 2022 y 2023 obteniendo que el Bosque húmedo ha tenido una pérdida de cobertura de 822,49 ha equivalente al 33,5% de la cobertura inicial, el suelo y la purma han aumentado en 539,59 ha y 220,82 ha respectivamente. El Cultivo de Palma retoño ha aumentado debido al crecimiento en la producción agrícola de la zona en 83,71 ha así como los accesos en 34,18 ha, y para el 2022 se evidencia la presencia de cuerpos de agua al norte de la UF en 20,27 ha.

## 8. RECOMENDACIONES

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

## 9. ANEXOS

Anexo 1: Acta de inicio N.º AI-022-2023-ITEGI

Anexo 2: Plan de evaluación ambiental focal PEAFA N.º 00164-2023-OEFA/DEAM-STEC

Anexo 3: Ficha de almacenamiento de productos

Atentamente:

[SVASQUEZ]



**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 de la unidad, la paz y el desarrollo"

**[MCABALLERO]**

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

Atentamente:

**[LCHUQUISENGO]**



"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: 09369207"



09369207