

**PERÚ**Ministerio  
del AmbienteOrganismo de Evaluación y  
Fiscalización Ambiental - OEFASTEC: 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 00133-2023-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 en la unidad fiscalizable Granja Sinchi II de titularidad Redondos S.A., en el distrito Humay, provincia Pisco, departamento Ica, en el 2022 y 2023.

**EXPEDIENTE DE EVALUACIÓN** : 0008-2022-DEAM-EAF

**CÓDIGO DE ACCIÓN** : No aplica

**REFERENCIA** : a) Acuerdo de cumplimiento N° 004-2022/OEFA/DSAP-CAGR  
b) Memorando N° 00435-2023-OEFA/DSAP  
c) Memorando N° 00184-2023-OEFA/DEAM  
d) Informe N° 00120-2023-OEFA/DEAM-STEC

**FECHA** : Lima, 31 de mayo 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 Granja Sinchi II
b.	Unidad fiscalizable en la zona de estudio o actividades económicas	Unidad fiscalizable Granja Sinchi II de titularidad Redondos S.A. ubicada en el distrito Humay, provincia Pisco, departamento Ica.
c.	Problemática identificada	Falta de información de las áreas impactadas como resultado del retiro progresivo de las lagunas de Biosol
d.	La actividad se realizó en el marco de	Memorando N.º 00435-2023-OEFA/DSAP Acuerdo de cumplimiento N° 004-2022/OEFA/DSAP-CAGR
e.	Tipo de evaluación	Evaluación ambiental focal
f.	Periodo de ejecución	Análisis en gabinete de imágenes satelitales de las fechas 05 de mayo, 19 de junio, 14 de julio, 01 de diciembre del 2022 y 31 de marzo, 15 de mayo del 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 Granjas Sinchi II (en adelante, UF Granja Sinchi II) de titularidad de Redondos S.A., ubicada en el distrito Humay, provincia de Pisco y departamento de Ica.

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-021-2023-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 Granja Sinchi II de titularidad de Redondos S.A. (Ver Anexo 1).

Los detalles de la planificación se encuentran en el Plan de Evaluación Ambiental Focal de la superficie terrestre en la UF Granja Sinchi II ubicada en el distrito Humay, provincia Pisco, departamento Ica, que ha sido aprobado mediante informe N.º 00120-2023-OEFA/DEAM-STEC (Ver Anexo 2), en el cual se incorpora la fecha del 15 de mayo 2023 para que sean analizados en cinco (5) períodos.

En ese sentido, desde el 02 hasta el 20 de mayo de 2023, los especialistas designados por la DEAM (mediante Memorando N.º 00184-2023-OEFA/DEAM), realizaron en gabinete, el análisis y procesamiento de imágenes satelitales de la UF Granja Sinchi II. Dichas imágenes satelitales corresponden a la misión Sentinel-2 de las fechas 05 de mayo, 19 de junio, 14 de julio, 01 de diciembre del 2022 y 31 de marzo, 15 de mayo del 2023.

## 3. OBJETIVOS

### 3.1 Objetivo general

Evaluar la superficie terrestre en el ámbito de la UF Granja Sinchi II de titularidad Redondos S.A., mediante técnicas de teledetección espacial<sup>1</sup>.

### 3.2 Objetivos específicos

- Identificar áreas de vertimientos y acumulación de aguas residuales industriales inadecuadamente tratadas mediante técnicas de teledetección espacial dentro del ámbito de la UF Granja Sinchi II de titularidad de Redondos S.A.
- Estimar el área impactada producto de vertimientos, acumulación de aguas residuales industriales inadecuadamente tratadas en la UF Granja Sinchi II en cinco (5) periodos de análisis mediante el análisis multitemporal de imágenes satelitales.

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



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”

#### 4. ÁREA DE ESTUDIO

El área de estudio comprende el ámbito UF Granja Sinchi II, la cual está ubicada en el distrito Humay, provincia Pisco, departamento Ica (Figura 4.1).

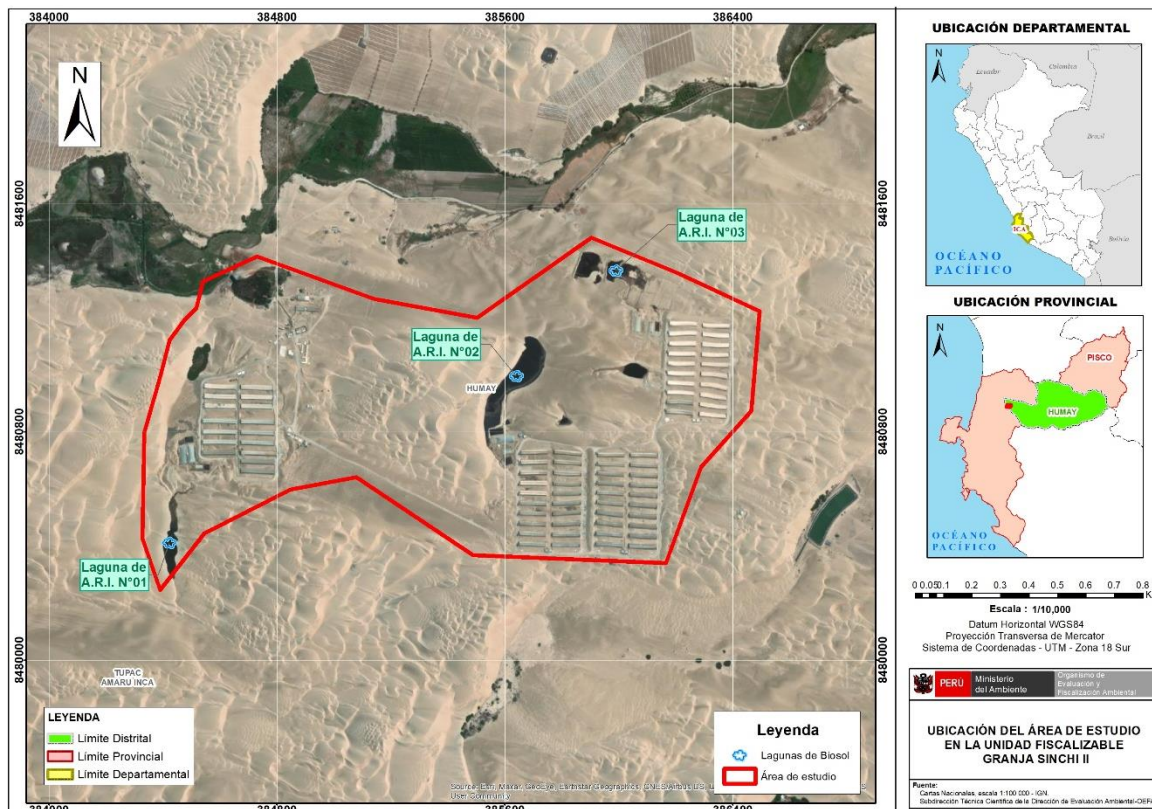


Figura 4.1. Ubicación del área de estudio en la UF Granja Sinchi II

#### 5. METODOLOGÍA

Para la identificación de zonas de vertimientos y acumulación de aguas residuales industriales inadecuadamente tratadas (lagunas de biosol) en la UF Granja Sinchi II, se utilizó el siguiente documento:

- 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.
- Guía de usuario para la generación de información cartográfica en el sistema eCognition development.

Tabla 5. Referencias empleadas

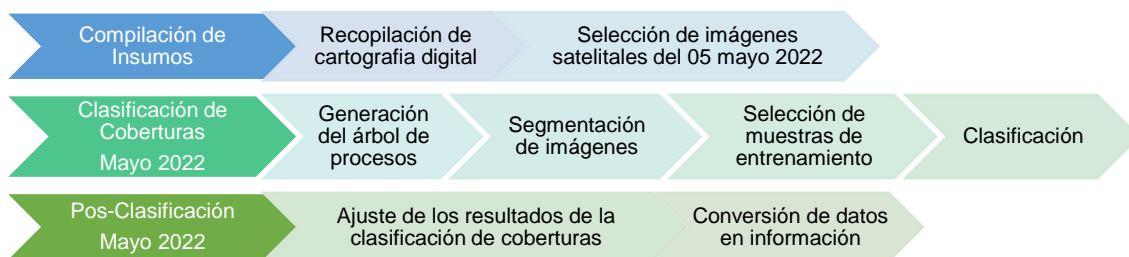
Matriz	Nombre	Sección	Dispositivo Legal	Entidad	País
Superficie terrestre	Manual técnico «Metodología para clasificación de coberturas a partir del procesamiento de imágenes satelitales»	Todas las secciones	Marco del Convenio de Contrato 002-017-MINAGRI-DVDIAR-UEGPS/DE-PIADER y el Consorcio AIDER y SOUTH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



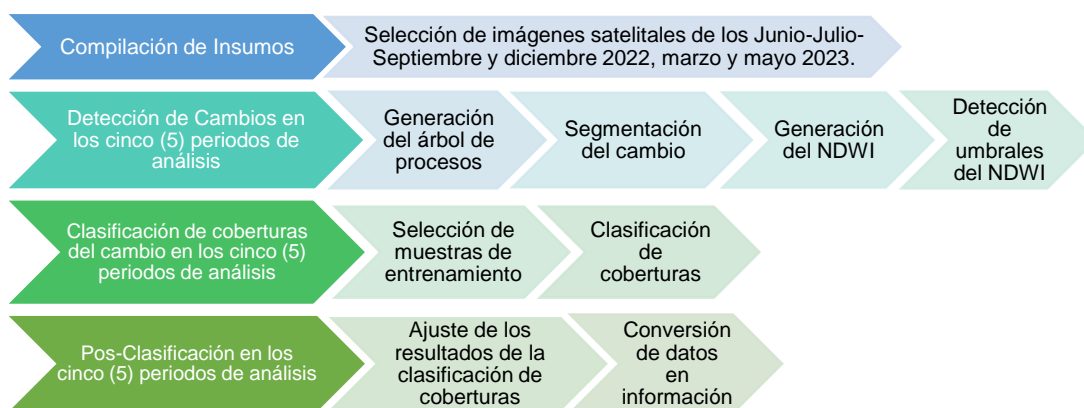
Matriz	Nombre	Sección	Dispositivo Legal	Entidad	País
	for Windows operating system				

El procedimiento metodológico se realizó de manera semi-automatizada para identificar las clases de cobertura por fecha mediante el análisis de imágenes satelitales obtenidas de la plataforma *Google Earth Engine*<sup>2</sup> en el área de estudio de la UF Granja Sinchi II. Se realizaron dos (2) etapas de procesamiento, la primera consistió en la clasificación de zonas de vertimiento de aguas residuales industriales (lagunas de biosol) para el 05 de mayo del 2022 (fecha base), y la segunda en la detección y clasificación sólo de los segmentos de cambio, manteniendo las demás áreas constantes en los cinco (5) periodos de análisis. (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 zonas de vertimientos para la fecha 05 de mayo de 2022.



**Figura 5.2.** Esquema de la metodología semi-automatizada para la detección y clasificación de cambios de cobertura para los cinco (5) períodos de análisis.

## 5.1. Clasificación para la fecha 05 de mayo de 2022

### 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.

<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)

**Tabla 5.2.** Cartografía digital utilizada como insumo para la clasificación

Institución	Cartografía Digital
Redondos SA	Límites de la UF Granja Sinchi II Ubicación de las lagunas de biosol en la unidad fiscalizable

**b. Selección de imágenes satelitales**

Para la selección de la imagen satelital disponible para la fecha 05 de mayo de 2023 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 (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
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:

```
//Definición de "geometry"
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),
    geometry =
    /* color: #d63000 */
    /* shown: false */
    /* displayProperties: [
    {
    "type": "rectangle"
    }
    ]*/
```

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



```
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_SR')
```

```
.filterBounds (geometry)
```

```
.filterDate ('2022-05-04','2022-05-06')
```

```
.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: '20220505_BOA',
```

```
  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 geoprocementos

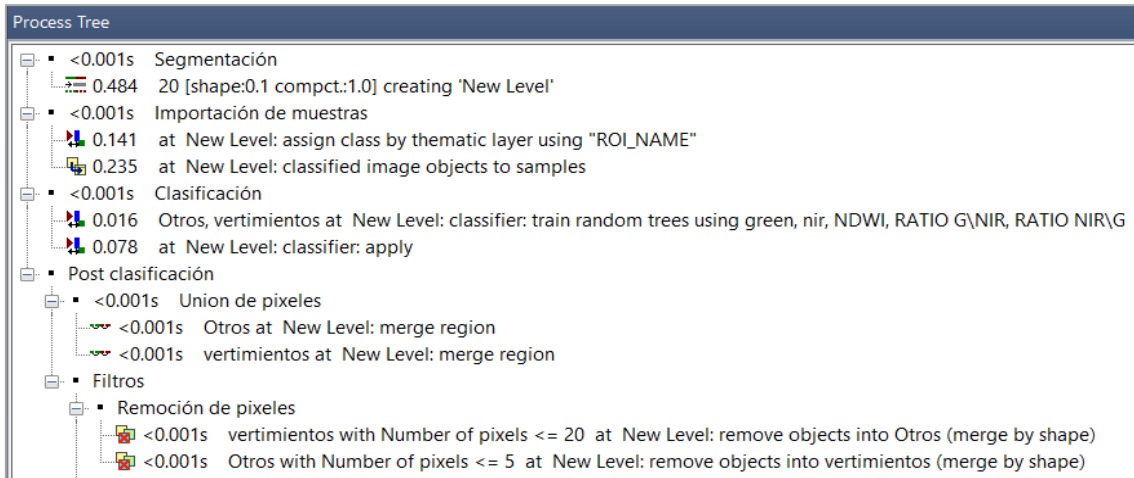


Figura 5.3. Regla de procesos para la clasificación de coberturas en el software eCognition Developer 10.1 Trial.

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

### 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

#### **b. Segmentación de imágenes**

Para la selección de objetos, fue necesario agrupar información relevante eliminando el efecto de pixeles 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).

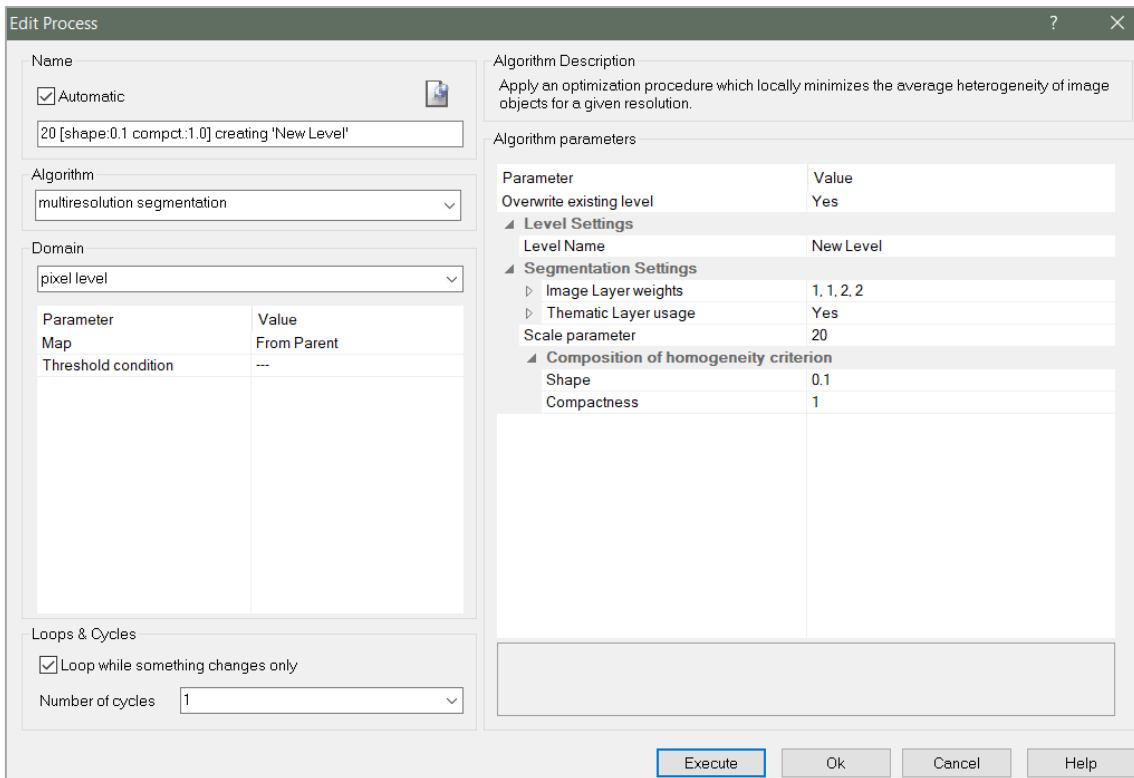


Figura 5.4. Resultado de la configuración de parámetros para la segmentación en *eCognition Developer 10.1 Trial*.

### c. Selección de muestras de entrenamiento

La segmentación generó una preclasificación de clases de cobertura con apoyo de la fotointerpretación de las imágenes satelitales. En base a todo ello se definieron dos (2) clases de cobertura: vertimientos y otros.

Para la generación de las muestras de entrenamiento, con el *software* ArcGIS, se generó una capa de puntos (archivo *Shapefile*) agrupados según las dos (2) 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 la clase vertimientos, como se detalla en la Figura 5.5. Luego se procedió con la importación del

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



archivo *Shapefile* de las muestras de entrenamiento al inicio de la configuración de las reglas de proceso.

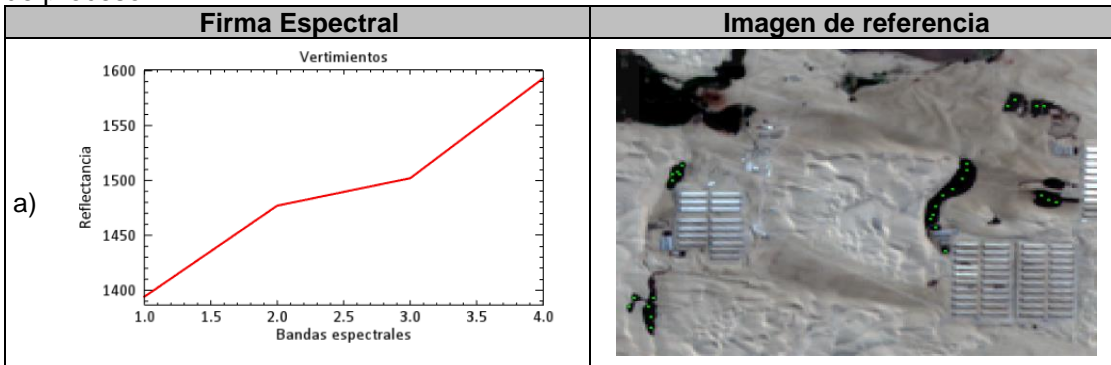


Figura 5.5. Firmas espectrales de la clase identificada: a) Vertimientos

#### 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 ratios, así como las medianas de las bandas B3-GREEN 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.

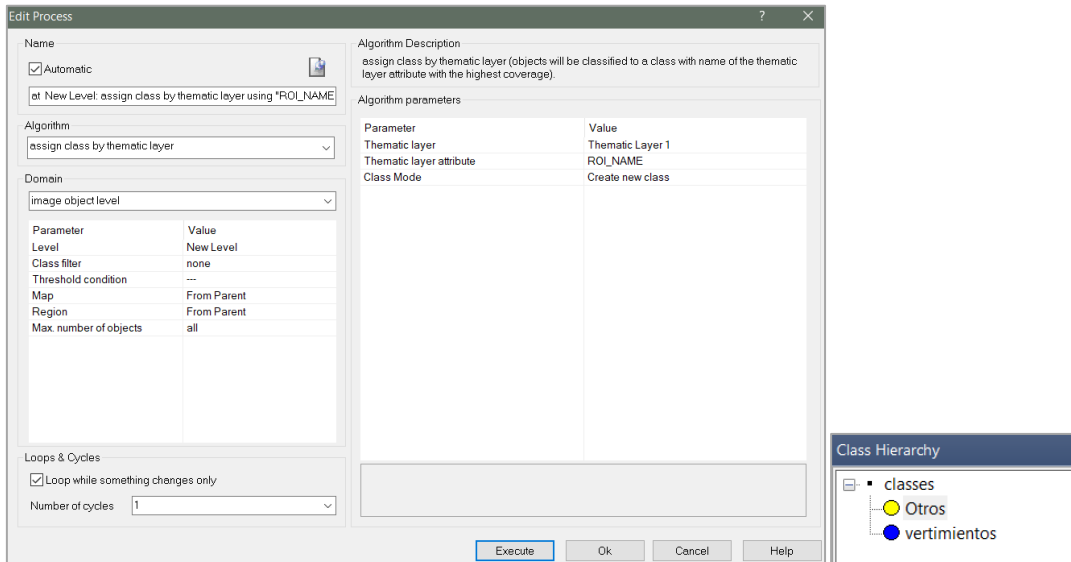


Figura 5.6. Relación de atributos y creación de clases

##### 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.

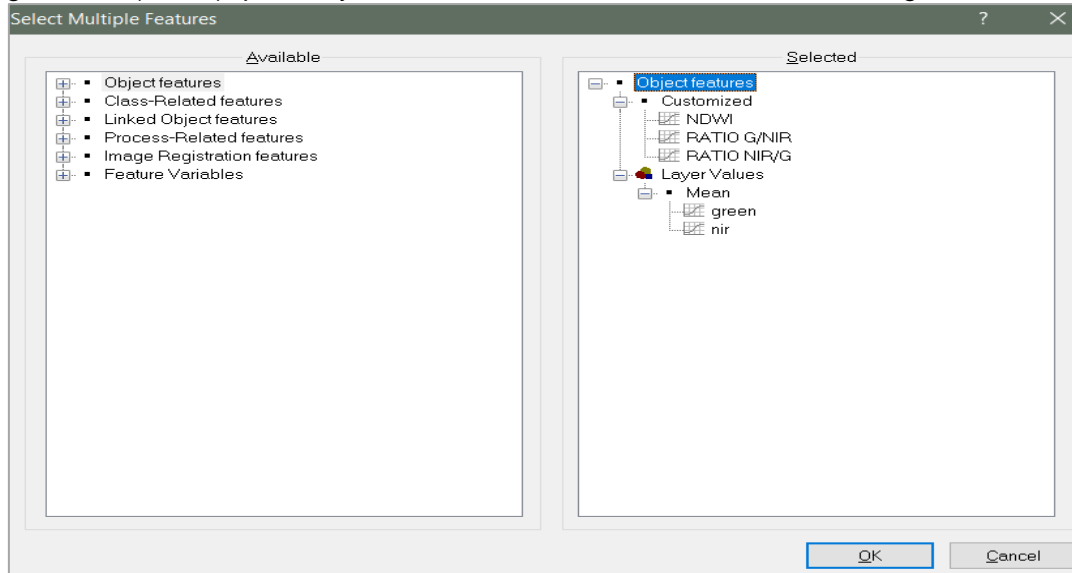
<sup>7</sup> Es la ventana creada por *eCognition Developer 10.1 Trial* donde se escriben conjuntos de reglas en base a funciones. Los conjuntos de reglas son una combinación de procesos individuales, que se muestran en el árbol de procesos y se crean mediante el cuadro de diálogo.



### 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 (green y Nir) y del índice generado (NDWI) que influyen en la clasificación, tal como muestra la Figura 5.7.



**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.



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

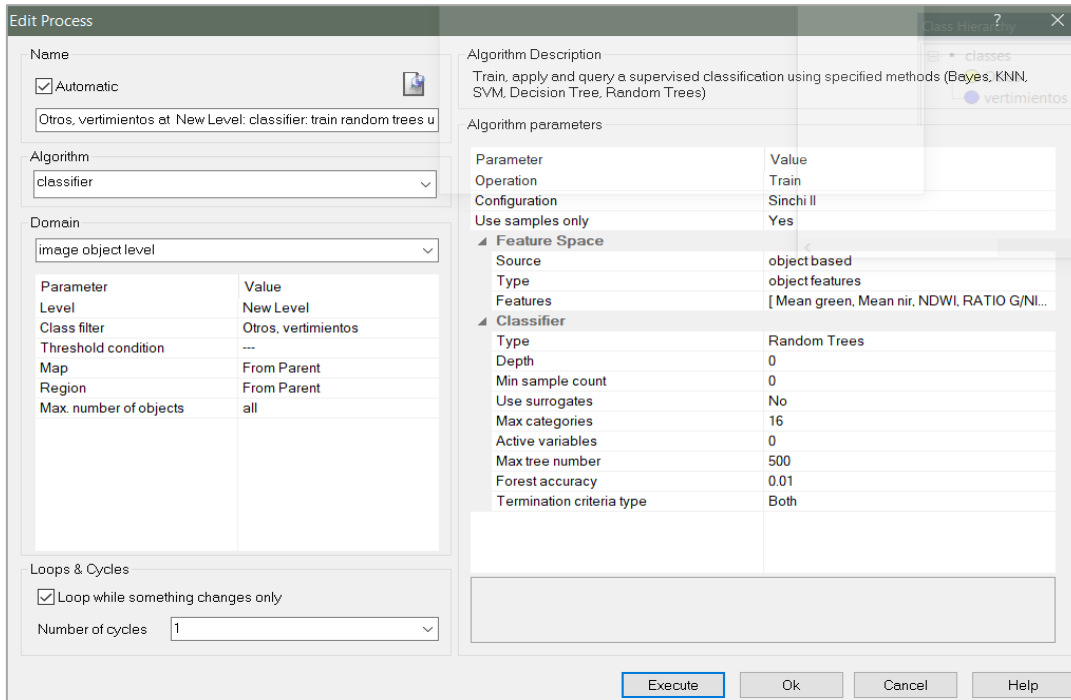


Figura 5.8. Configuración del clasificador del algoritmo *Random Forest*

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

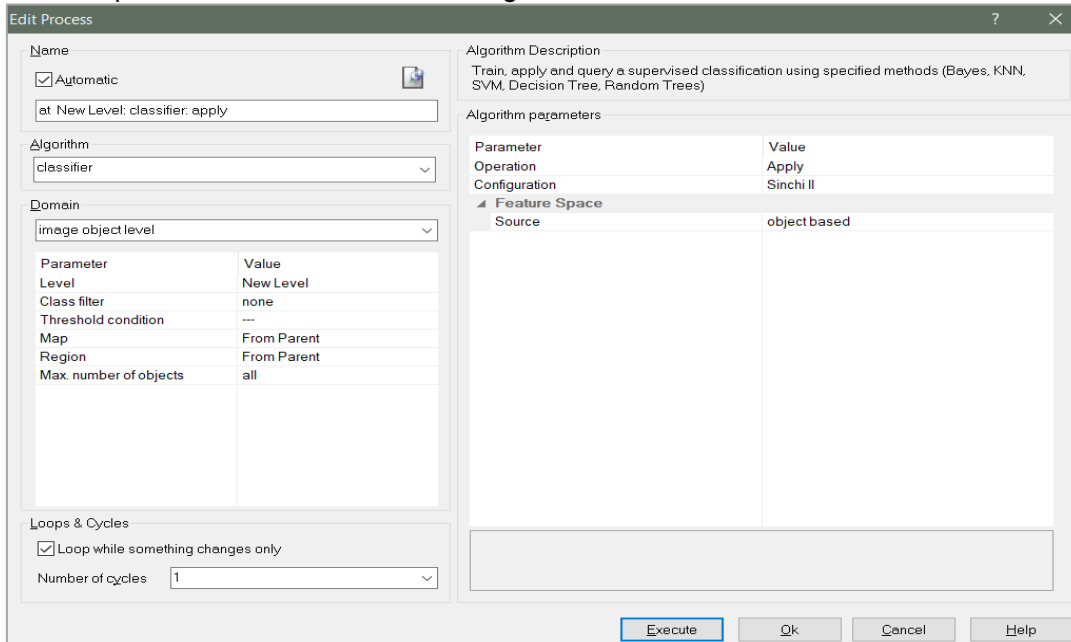


Figura 5.9. Configuración de la aplicación del algoritmo *Classifier*



### 5.1.3. Post Clasificación de la fecha 05 de mayo de 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*.

### 5.2. Detección y clasificación de cambios de coberturas para los cinco (5) periodos de análisis

#### 5.2.1. Compilación de insumos

##### a. Selección de imágenes satelitales

Para la selección de imágenes satelitales disponibles para las fechas 19 de junio, 14 de julio, 01 de diciembre de 2022 y 31 de marzo, 15 de mayo 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 05 de mayo de 2022 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 19 de junio de 2022

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),  
    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_SR')  
    .filterBounds(geometry)  
    .filterDate('2022-06-18','2022-06-20')  
    .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: '20220619_BOA',  
  scale: 10,  
  region: geometry});
```

- Para el 14 de julio de 2022

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),  
    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_SR')  
  .filterBounds (geometry)  
  .filterDate ('2022-07-13','2022-07-15')  
  .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: '20220714_BOA',  
  scale: 10,  
  region: geometry});
```

- Para el 01 de diciembre de 2022

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),  
  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_SR')  
  .filterBounds (geometry)  
  .filterDate ('2022-11-30','2022-12-02')  
  .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'],
```



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

```
'Capa Sentinel');  
// exportar  
Export.image.toDrive({  
  image: SentinelClip.select("B2","B3", "B4", "B8"),  
  description: '20221201_BOA',  
  scale: 10,  
  region: geometry});
```

- Para el 31 de marzo de 2023

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),  
  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_SR')  
  .filterBounds (geometry)  
  .filterDate ('2023-03-30','2023-04-01')  
  .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: '20230331_BOA',  
  scale: 10,  
  region: geometry});
```

- Para el 15 de mayo de 2023

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),  
  geometry =  
  /* color: #d63000 */  
  /* shown: false */  
  /* displayProperties: [  
    {  
      "type": "rectangle"  
    }  
  ] */
```



```

    "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_SR')
  .filterBounds (geometry)
  .filterDate ('2023-05-14','2023-05-16')
  .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: '20230515_BOA',
  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
19/06/2022	Sentinel 2A	2022-06-18 / 2022-06-20	Mosaico de imágenes	Reflectancia BOA
14/07/2022	Sentinel 2A	2022-07-13 / 2022-07-15	Mosaico de imágenes	Reflectancia BOA
01/12/2022	Sentinel 2A	2022-11-30 / 2022-12-02	Mosaico de imágenes	Reflectancia BOA
31/03/2023	Sentinel 2A	2023-03-30 / 2023-04-01	Mosaico de imágenes	Reflectancia BOA
15/05/2023	Sentinel 2A	2023-05-14 / 2023-05-16	Mosaico de imágenes	Reflectancia BOA

### 5.2.2. Detección de cambios

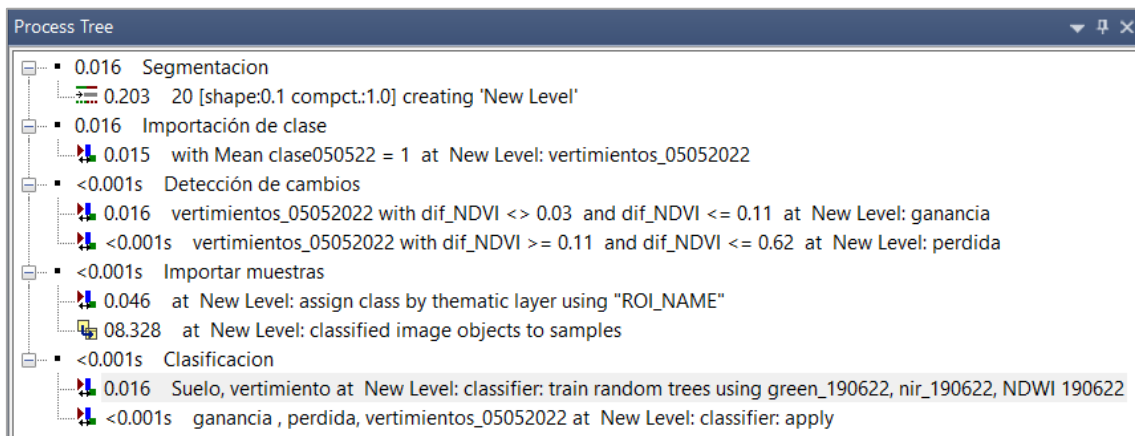
#### a. Generación del árbol de procesos

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 NDWI 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 de la fecha 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 GREEN y NIR (insumos para el NDWI) 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 *GREEN* 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* = 20, *Shape* = 0,1 y *Compactness* = 1 (Figura 5.11).

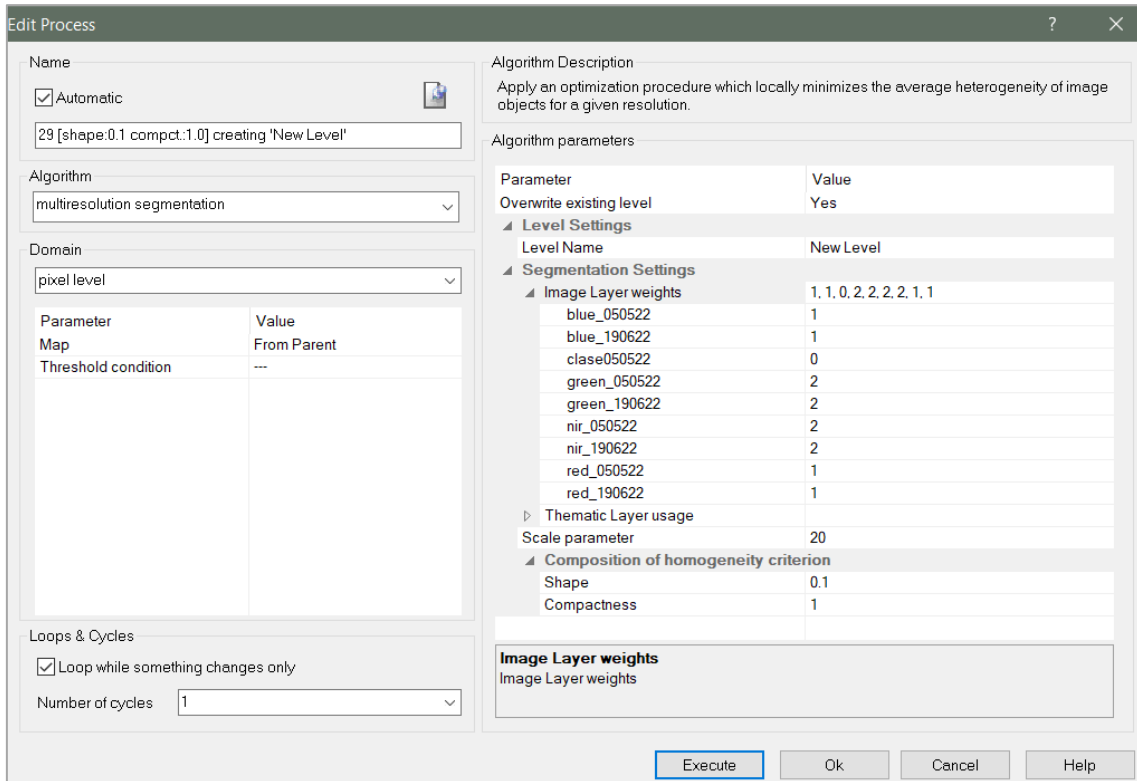


Figura 5.11. Resultado de la configuración de parámetros para la segmentación en eCognition Developer 10.1 Trial.

### c. Generación del Índice diferencial de agua normalizado (NDWI)

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

Esta diferencia de NDWIs, permitió reconocer donde hubo cambios suscitados en las áreas de vertimientos.

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 de reflectancia 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 la fecha 1.

### d. Detección de Umbrales del NDWI

La detección de cambios se realizó en base a Umbrales del NDWI, 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 0,03 y menores a 0,11, y aquellos valores que representan la ganancia son mayores a 0,11 y menores a 0,62.

### 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.

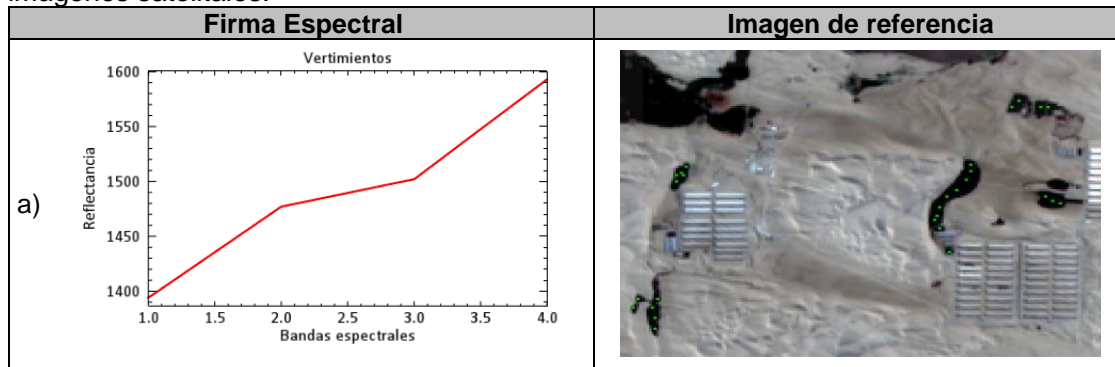


Figura 5.12. Firmas espectrales de la clase identificada: a) Vertimientos

#### 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 GREEN 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.

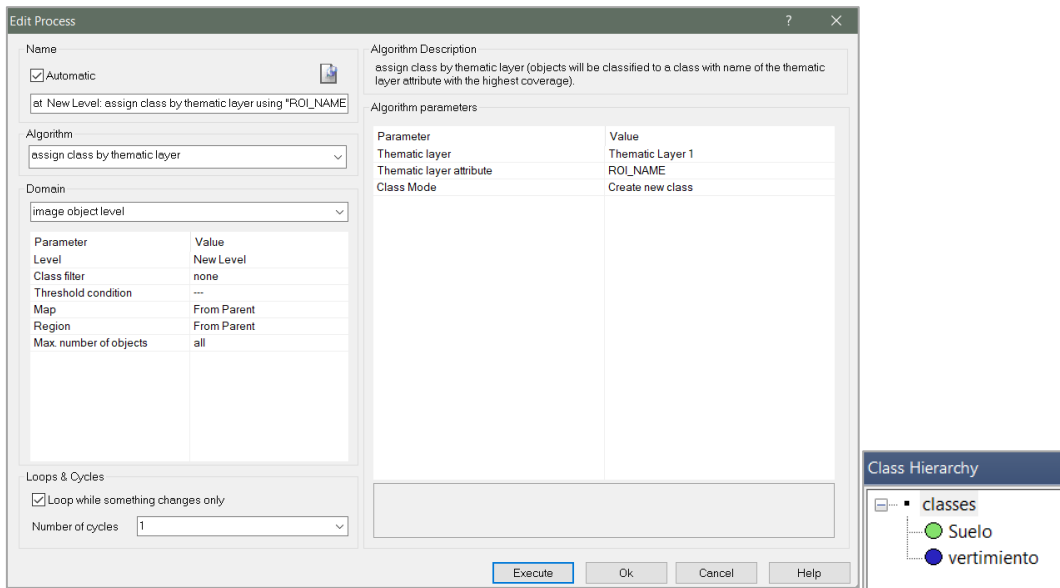


Figura 5.13. Relación de atributos y creación de clases

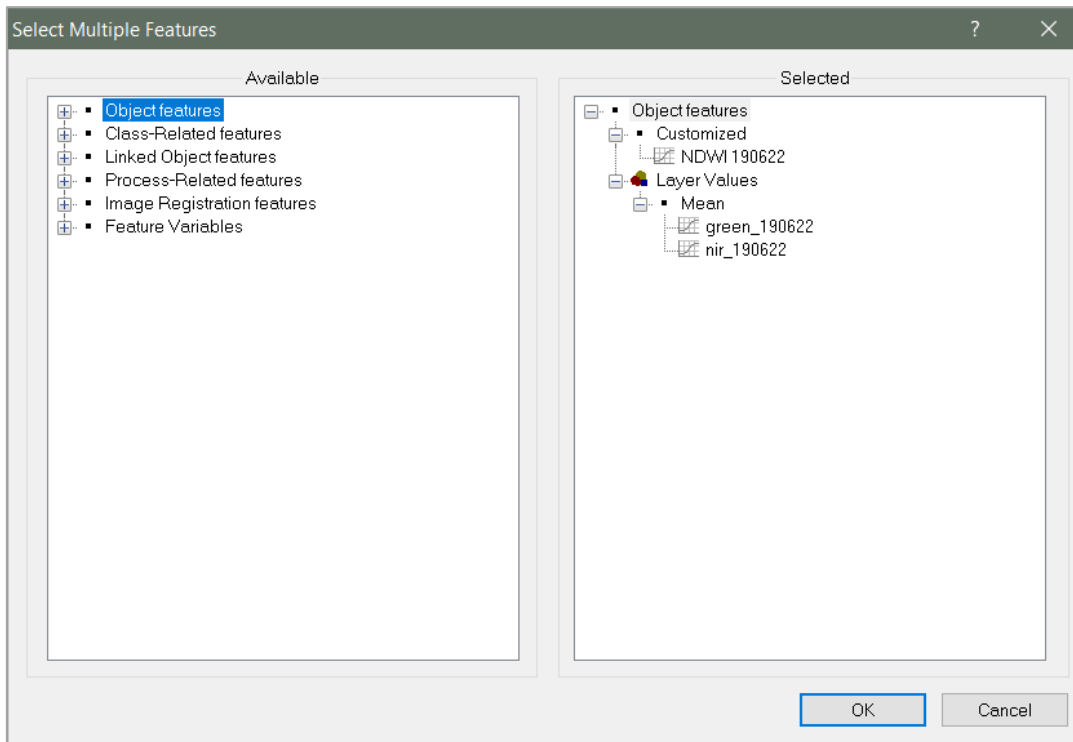
## ii. Asignación de clases a los segmentos:

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*

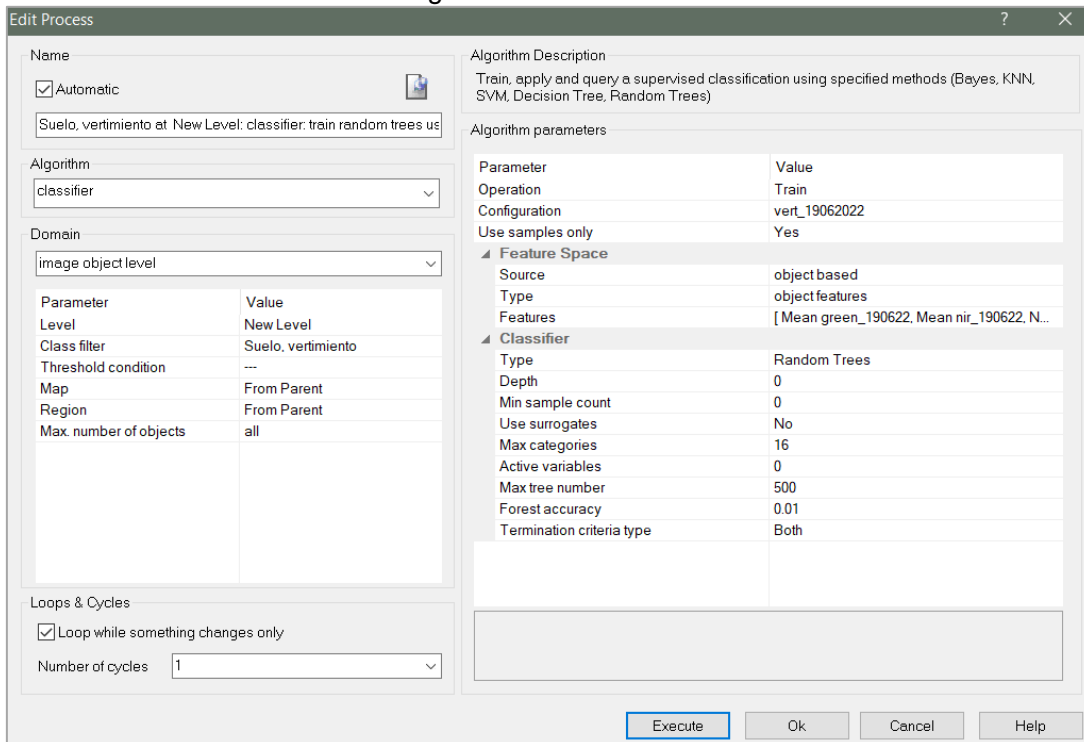
Para la clasificación de imágenes se utilizó el algoritmo *Random Forest* el cual es un clasificador que produce múltiples árboles de decisiones. Estos árboles se crean en base a la selección aleatoria de un subconjunto de muestras y variables de entrenamiento mediante un enfoque de *bagging*. Esto quiere 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 (*GREEN* y *NIR*), índice *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.



**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.

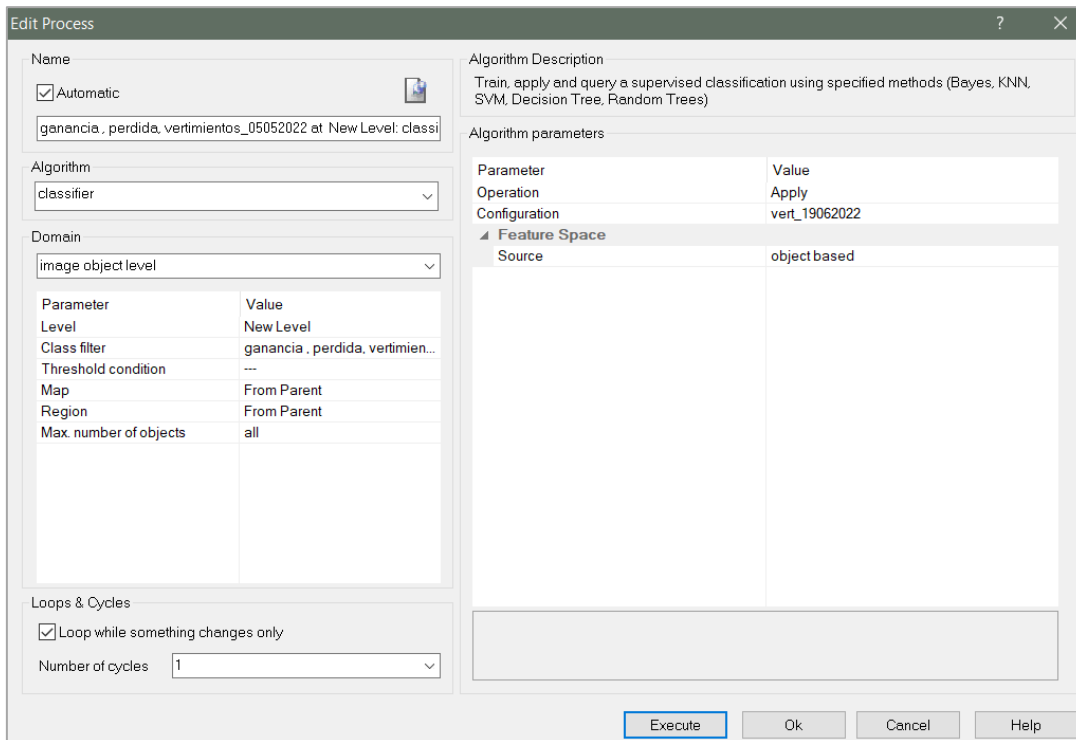


Figura 5.16. Configuración de la aplicación del algoritmo Classifier

#### 5.2.4. Post-Clasificación para los cinco (5) periodos de análisis

##### 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 zonas de vertimientos de aguas residuales industriales inadecuadamente tratadas (lagunas de biosol) para las fechas 05 de mayo de 2022, 19 de junio de 2022, 14 de julio de 2022, 01 de diciembre de 2022, 31 de marzo de 2023 y 15 de mayo de 2023.

Para el 05 de mayo de 2022 se identificaron zonas de vertimientos de aguas residuales industriales con una extensión de 9,73 ha. (Figura 6.1)




Figura 6.1. Zonas de vertimientos para el 05 de mayo de 2022 en el área de estudio de la UF Granja Sinchi II

Para el 19 de junio de 2022 se identificaron zonas de vertimientos de aguas residuales industriales con una extensión de 9,04 ha. (Figura 6.2)




Figura 6.2. Zonas de vertimientos para el 19 de junio de 2022 en el área de estudio de la UF Granja Sinchi II



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”

Para el 14 de julio de 2022 se identificaron zonas de vertimientos de aguas residuales industriales con una extensión de 7,57 ha. (Figura 6.3)




Figura 6.3. Zonas de vertimientos para el 14 de julio de 2022 en el área de estudio de la UF Granja Sinchi II

Para el 01 de diciembre de 2022 se identificaron zonas de vertimientos de aguas residuales industriales con una extensión de 5,30 ha. (Figura 6.4)




Figura 6.4. Zonas de vertimientos para el 01 de diciembre de 2022 en el área de estudio de la UF Granja Sinchi II



Para el 31 de marzo de 2023 se identificaron zonas de vertimientos de aguas residuales industriales con una extensión de 1,34 ha. (Figura 6.5)




Figura 6.5. Zonas de vertimientos para el 31 de marzo de 2023 en el área de estudio de la UF Granja Sinchi II

Para la el 15 de mayo de 2023 se identificaron zonas de vertimientos de aguas residuales industriales con una extensión de 1,01 ha. (Figura 6.6)




Figura 6.6. Zonas de vertimientos para el 15 de mayo de 2023 en el área de estudio de la UF Granja Sinchi II



De la estimación del área impactada producto de los vertimientos, acumulación de aguas residuales industriales (lagunas de biosol) en la UF Granja Sinchi II en cinco (5) periodos (Tabla 6.1 y Figura 6.7), se observa que se han ido reduciendo por cada fecha de análisis con imágenes satelitales, teniendo una reducción de 8,72 ha equivalente al 89,6% desde el 05 de mayo de 2022 hasta el 15 de mayo de 2023.

Tabla 6.1. Superficie de vertimientos por fecha analizada

Clase	Área (ha)
Vertimientos 05/05/2022	9,73
Vertimientos 19/06/2022	9,04
Vertimientos 14/07/2022	7,57
Vertimientos 01/12/2022	5,3
Vertimientos 31/03/2023	1,34
Vertimientos 15/05/2023	1,01

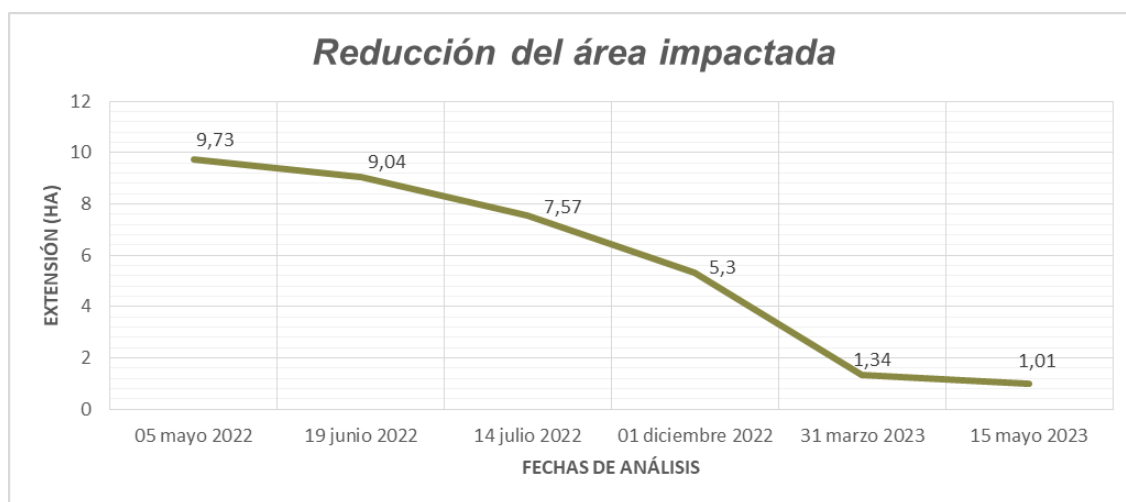


Figura 6.7. Reducción del área impactada producto de vertimientos

### 7. CONCLUSIONES

- i. Se identificaron seis (6) áreas afectadas por las aguas residuales industriales de la UF Granja Sinchi II como resultado del análisis de las imágenes satelitales del 05 de mayo de 2022, 19 de junio de 2022, 14 de julio de 2022, 01 de diciembre de 2022, 31 de marzo de 2023 y 15 de mayo de 2023.
- ii. Se estimaron las extensiones de las áreas de vertimientos por cada fecha de análisis observándose una reducción de 9,73 ha a 1,01 ha, el cual representa el 89,6% de área reducida desde el 05 de mayo de 2022 hasta el 15 de mayo de 2023.

### 8. RECOMENDACIONES

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



**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"

## **9. ANEXOS**

Anexo 1: Acta de inicio N.º AI-021-2023-ITEGI

Anexo 2: Plan de evaluación ambiental focal aprobado mediante informe N.º 00120-2023-OEFA/DEAM-STEC.

Anexo 3: Ficha de almacenamiento de productos

Atentamente:

**[SVASQUEZ]**

**[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: 00940901"



00940901