

**PERÚ**Ministerio
del AmbienteOrganismo de Evaluación y
Fiscalización Ambiental - OEFASTEC: Subdirección
Técnica CientíficaDecenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

2022-101-011643

INFORME N° 00070-2022-OEFA/DEAM-STEC

A	:	FRANCISCO GARCÍA ARAGÓN Director de Evaluación Ambiental
DE	:	LÁZARO WALTHER FAJARDO VARGAS Ejecutivo de la Subdirección Técnica Científica MARIELA BERENICE CABALLERO DEL CASTILLO Especialista en Evaluaciones Ambientales
ASUNTO	:	Clasificación de coberturas y cambio de uso en la unidad fiscalizable Granja Sinchi II administrada por la empresa Redondos SA, en el distrito Humay, provincia Pisco, departamento Ica.
EXPEDIENTE DE SUPERVISIÓN	:	0010-2022-DSAP-CAGR
CÓDIGO DE ACCIÓN	:	No aplica
REFERENCIA	:	Memorando N.° 00548-2022-OEFA/DSAP
FECHA	:	Lima, 29 de abril de 2022

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

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

a.	Zona supervisada	Unidad Fiscalizable Granja Sinchi II
b.	Unidades fiscalizables en la zona de estudio o actividades económicas	Unidad Fiscalizable Granja Sinchi II administrada por la empresa Redondos SA.
c.	Problemática identificada	Necesidad de identificar coberturas para el año 2016, 2017, 2018, 2019, 2020, 2021 y 2022 como apoyo en la supervisión ambiental de la unidad fiscalizable Granja Sinchi II.
d.	Motivo de la actividad	Memorando N.° 00548-2022-OEFA/DSAP
e.	Tipo de supervisión	Regular
f.	Periodo de ejecución	Abril de 2022

Profesionales que aportaron a este documento:

Tabla 1.2. Listado de profesionales

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

2. ANTECEDENTES

Mediante el Memorando N.º 00548-2022-OEFA/DSAP la Dirección de Supervisión Ambiental en Actividades Productivas (en adelante, DSAP) solicitó a la Dirección de Evaluación Ambiental (en adelante, DEAM) la colaboración técnica para realizar un estudio



PERÚ

Ministerio
del Ambiente

Organismo de Evaluación y
Fiscalización Ambiental - OEFA

STEC: Subdirección
Técnica Científica

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

que determine el dimensionamiento estimado del área impactada, producto del vertimiento y acumulación de aguas residuales industriales inadecuadamente tratadas, así como determinar la afectación de dicho vertimiento mediante el análisis multitemporal de imágenes satelitales en la unidad fiscalizable Granjas Sinchi II, ubicado en el distrito Humay, provincia Pisco, departamento Ica.

En el acta N.º AI-011-2022-ITEGI se precisó que se generará el análisis de acuerdo con la disponibilidad de imágenes satelitales del mismo sensor para su correcto análisis espectral y espacial para su posterior estimación el dimensionamiento de áreas de vertimientos y acumulación de residuos industriales inadecuadamente tratadas en el área de estudio de la unidad fiscalizable Granja Sinchi II administrada por la empresa Redondos SA (Anexo 1).

Luego de realizar la búsqueda de imágenes satelitales para determinar las clases de cobertura, se encontró disponibilidad para los años 2016, 2017, 2018, 2019, 2020, 2021 y 2022, por ello los detalles de la planificación para determinar las clases de cobertura y estimar el dimensionamiento del área impactada, producto del vertimiento y acumulación de aguas residuales industriales inadecuadamente tratadas en el área de estudio de la unidad fiscalizable Granja Sinchi II, se detallaron en plan de estudio N.º PE-008-2022-ITEGI (Anexo 2).

3. OBJETIVOS

3.1 Objetivo general

Identificar clases de coberturas de uso de suelo en la unidad fiscalizable Granja Sinchi II para los años 2016, 2017, 2018, 2019, 2020, 2021 y 2022, mediante técnicas de teledetección espacial¹.

3.2 Objetivos específicos

- Estimar el área impactada producto de vertimientos, acumulación de aguas residuales industriales inadecuadamente tratadas e infraestructuras dentro de la UFGSII en seis (06) periodos de análisis (2016-2017, 2017-2018, 2018-2019, 2019-2020, 2020-2021 y 2021-2022) en la unidad fiscalizable Granja Sinchi II.
- Estimar la distancia a centros poblados más cercano en relación a las zonas de afectación producto de las actividades de la UFGSII.

4. ÁREA DE ESTUDIO

El área de estudio se ubica en el distrito Humay, provincia Pisco, departamento Ica, dentro de la cual se encuentra la unidad fiscalizable Granja Sinchi II (Figura 4.1).

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

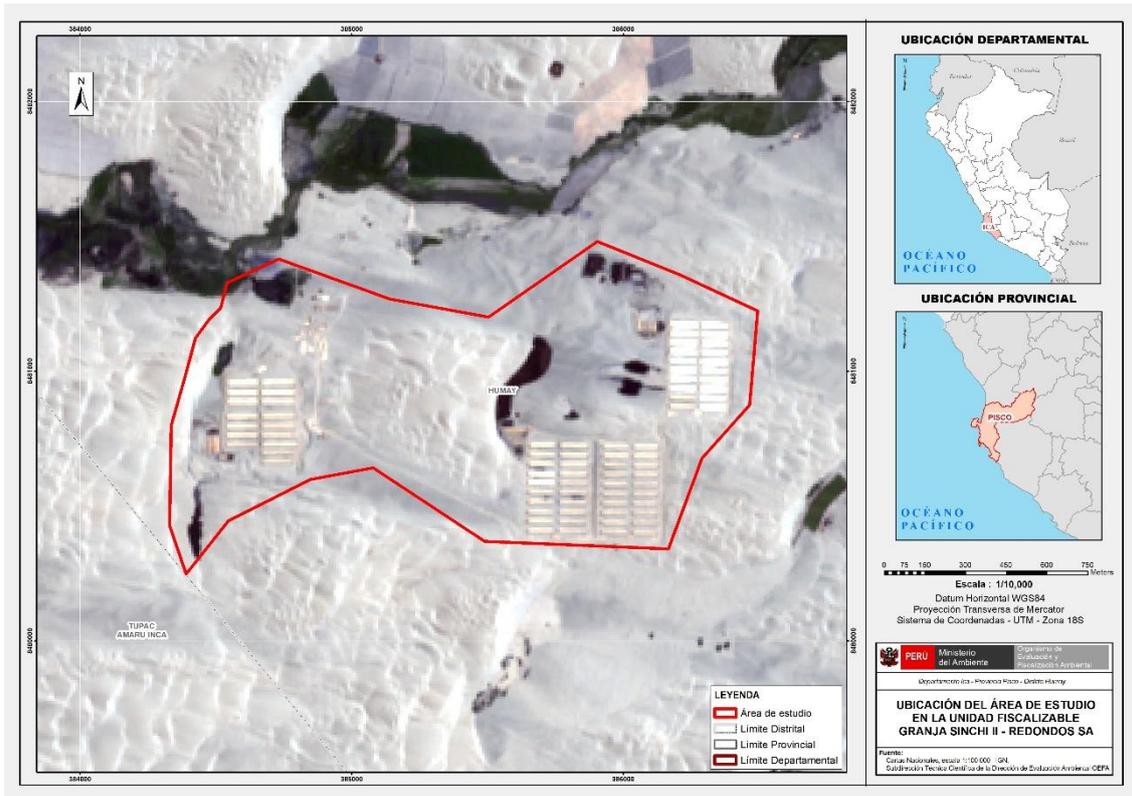


Figura 4.1. Ubicación del área de estudio y Unidad Fiscalizable Granja Sinchi II.

5. METODOLOGÍA

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

5.1. Guía utilizada para la supervisión ambiental

La guía utilizada para identificar clases de coberturas y determinar el cambio de uso en el área de estudio de la unidad fiscalizable Granja Sinchi II se detalla en la Tabla 5.1.

Tabla 5.1. Referencias empleadas

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

5.2. Procedimiento metodológico para la supervisión ambiental

El procedimiento metodológico se realizó de manera semi-automatizada para identificar las clases de cobertura por año de análisis en el área de estudio de la unidad fiscalizable Granja Sinchi II. Se realizaron dos (2) etapas de procesamiento, la primera consistió en la clasificación de coberturas del año 2016 (año base), y la segunda en la detección y clasificación sólo de los segmentos de cambio, manteniendo las demás áreas constantes en los periodos 2016-2017, 2017-2018, 2018-2019, 2019-2020, 2021-2022 y 2021-2022. (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.

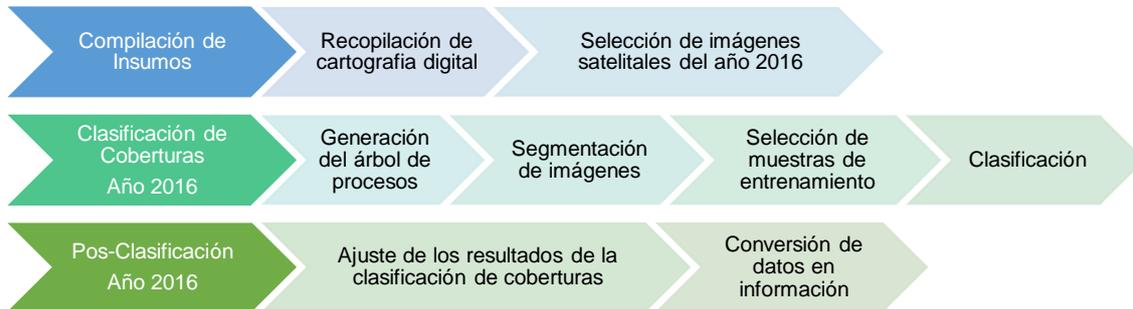


Figura 5.1. Esquema de la metodología semi-automatizada para la clasificación de coberturas para el año 2016.



Figura 5.2. Esquema de la metodología semi-automatizada para la detección y clasificación de cambios de cobertura para los periodos 2016-2017, 2017-2018, 2018-2019, 2019-2020, 2020-2021 y 2021-2022.

5.3. Clasificación de coberturas del año 2016

5.3.1. Compilación de insumos

a. Recopilación de cartografía digital

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

Tabla 5.2. Cartografía digital utilizada como insumo para la clasificación

Institución	Cartografía Digital
Redondos SA	Límites de la unidad fiscalizable Granja Sinchi II

b. Selección de imágenes satelitales

Para la selección de imágenes satelitales disponibles para el área de estudio se empleó la plataforma de *Google Earth Engine*² 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 tres (3) criterios: El primer criterio es la fecha en la que fue tomada la imagen satelital, siendo de prioridad la más reciente; el segundo criterio es que la imagen satelital sea de nivel 2A (imagen ortorectificada y corregida atmosféricamente); por último, el tercer criterio es que la imagen satelital tenga el menor porcentaje de cobertura de nubes sobre el área de interés, en la medida que se pueda disponer de la mayor cantidad de datos en el área de estudio.

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

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),  
    geometry =  
    /* color: #d63000 */  
    /* shown: false */  
    /* displayProperties: [  
    {  
      "type": "rectangle"  
    }  
    ]*/  
    ee.Geometry.Polygon(  
    [[[-76.11656776639333, -13.6992732065504],  
      [-76.11656776639333, -13.79665132045887],  
      [-76.0104810354363, -13.79665132045887],  
      [-76.0104810354363, -13.6992732065504]]], null, false);
```

² 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)

```
//Imagen para SENTINEL 2A
var IMGsSentinel= ee.ImageCollection ('COPERNICUS/S2')
  .filterBounds (geometry)
  .filterDate ('2016-03-26','2016-03-28')
  .filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);
var SentinelFiltro = ee.Image(IMGsSentinel.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: '2016_granja_TOA_03',
  scale: 10, region: geometry});
```

5.3.2. Clasificación de coberturas del año 2016

a. Generación del árbol de procesos

Para la generación del árbol de procesos se empleó el *software eCognition Developer 10.1 Trial*³ (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*⁴.
- Clasificación con los algoritmos de *Classifier* utilizando el método de *Random Forest*.

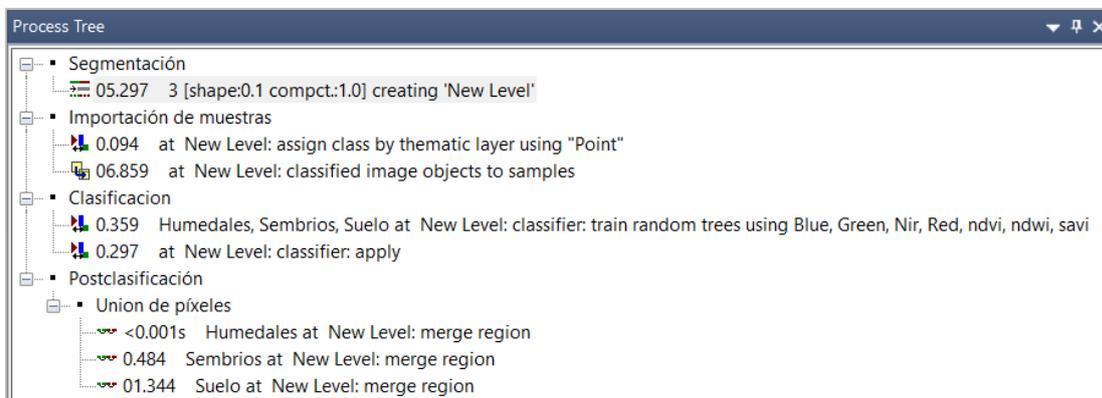


Figura 5.3. Regla de procesos para la clasificación de coberturas en el *software eCognition Developer 10.1 Trial*.

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

³ Programa especializado para la clasificación de objetos.

⁴ Programa especializado en geoprocementos

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 refleja un valor bajo en el NDVI.

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

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

Dónde:

NDVI = Índice Normalizado de Vegetación

NIR = Reflectancia en la banda del infrarrojo cercano

RED = Reflectancia en la banda roja del visible

Índice diferencial de agua normalizado

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

b. Segmentación de imágenes

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

- Desviación estándar y mediana.
- Textura (muchos tipos).
- Extensión (por ejemplo: área, longitud, ancho, etc.).

- Forma (por ejemplo: redondo, asimétrico, compacto, etc.).
- Relaciones con los segmentos vecinos (diferencia media con los vecinos).

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

- Pesos de las bandas de la imagen; el cual ajusta la cantidad de influencia que tiene cada banda de la imagen en la segmentación. Para ello se utilizaron las bandas B4-RED y B8-NIR, colocándole los valores de 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* = 3, *Shape* = 0,1 y *Compactness* = 1 (Figura 5.4).

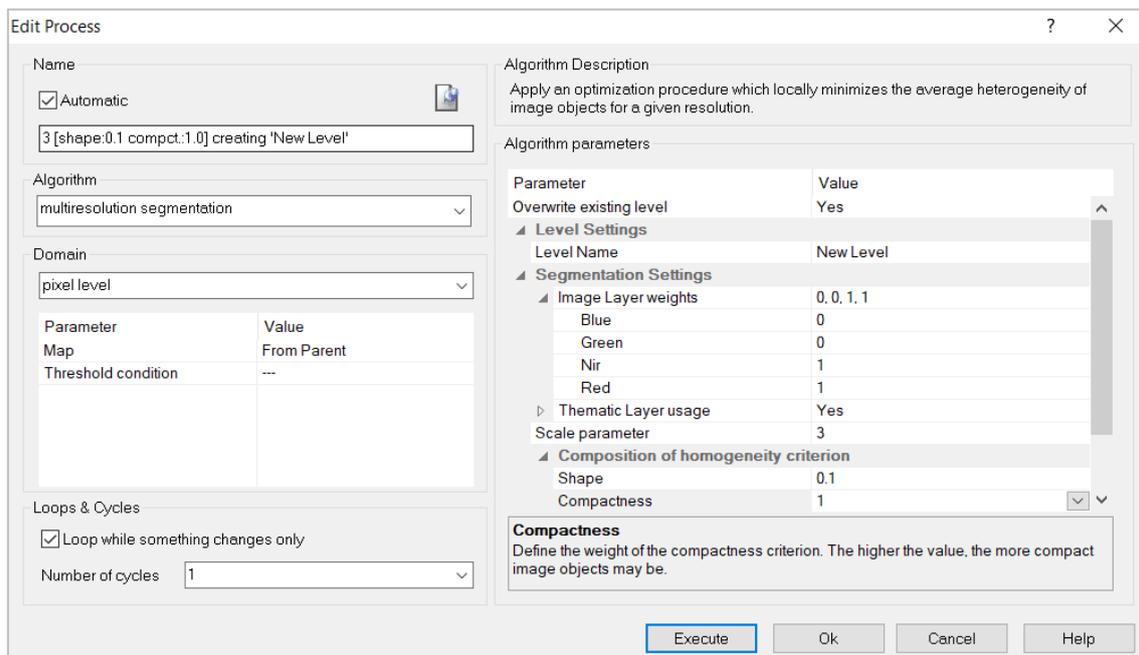


Figura 5.4. Resultado de la configuración de parámetros para la segmentación en *eCognition Developer 10.1 Trial*.

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 cuatro (4) clases de cobertura: Humedales, suelo, sembríos y pozo (humedal).

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 5.3⁵ se verificó que las muestras seleccionadas cuentan con la firma espectral característica de cada clase de cobertura, como se detalla en la Figura 5.5. Luego se procedió con la importación del archivo *Shapefile* de las muestras de entrenamiento al inicio de la configuración de las reglas de proceso.

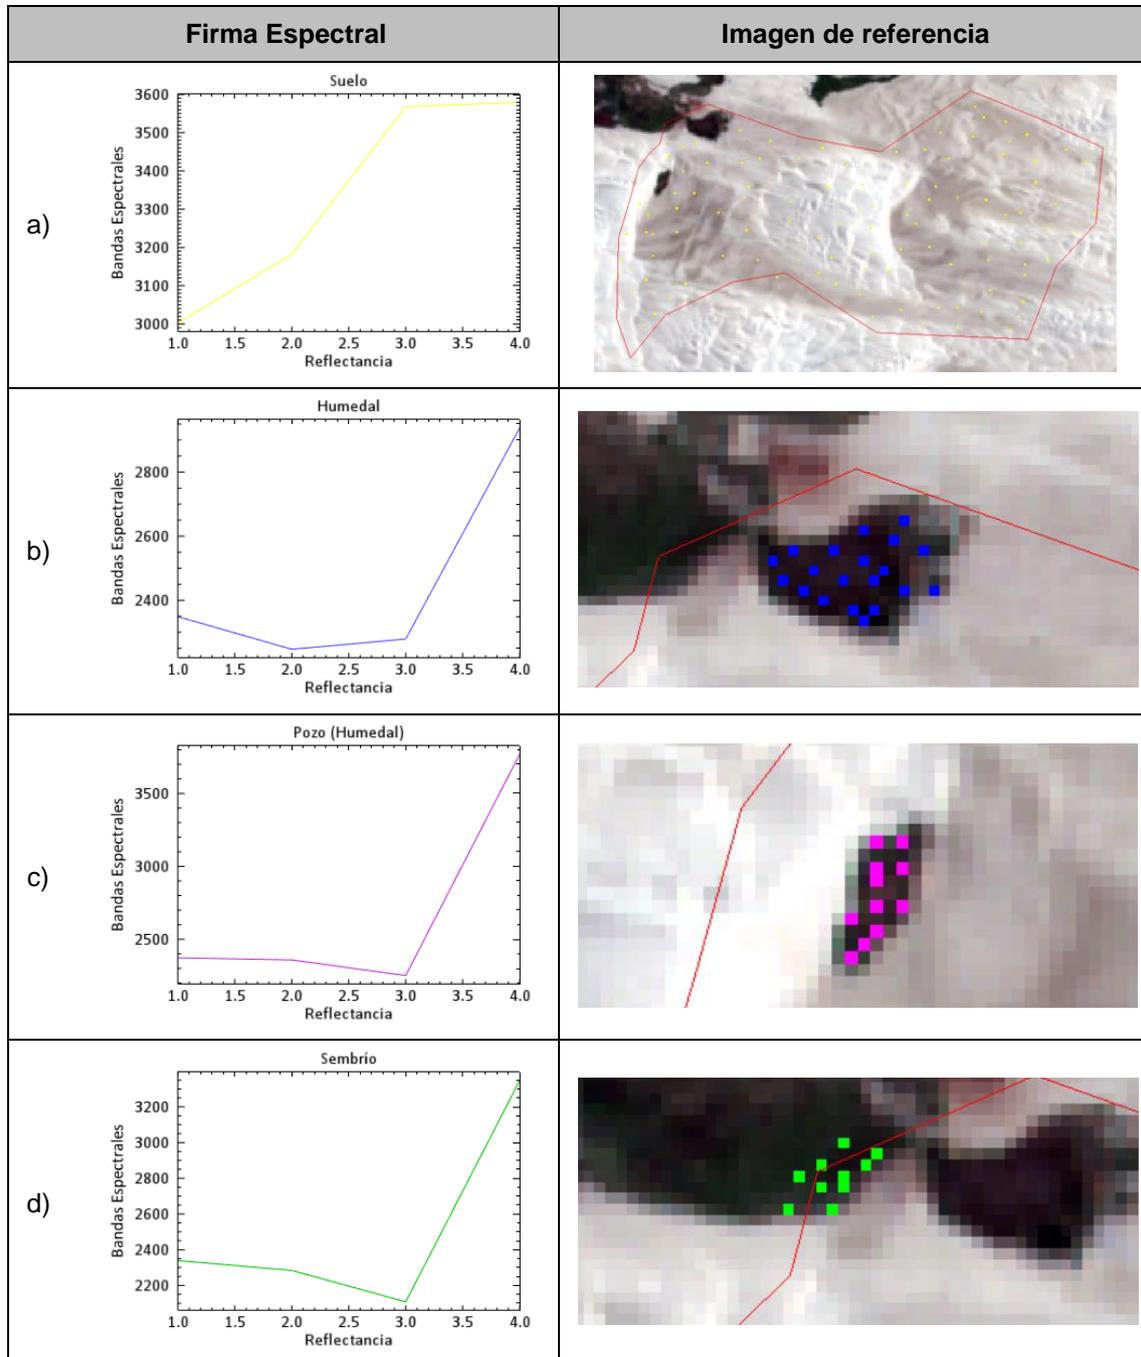


Figura 5.5. Firmas espectrales de las clases identificadas: a) Suelo, b) Humedal, c) Pozo (humedal) y d) Sembrió

d. Clasificación de coberturas

⁵ Programa especializado para el tratamiento digital de imágenes satelitales.

En el Árbol de Procesos⁶ se configuraron los parámetros del algoritmo de clasificación que permitieron interactuar con las muestras de entrenamiento. Se introdujeron los índices y ratios, así como las medianas de las bandas B4-RED y B8-NIR con la finalidad de aportar en la discriminación de las coberturas y obtener mejores resultados en la clasificación.

i. Creación de clases:

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

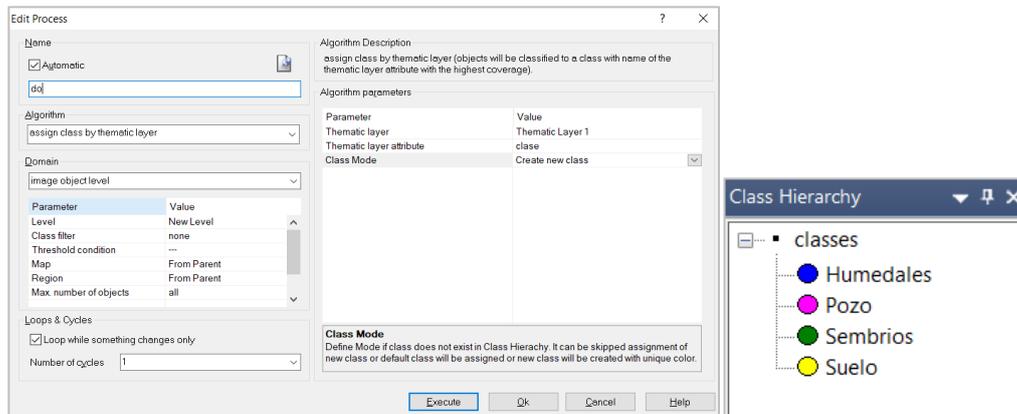


Figura 5.6. Relación de atributos y creación de clases

ii. Asignación de clases a los segmentos:

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

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

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

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

⁶ 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.

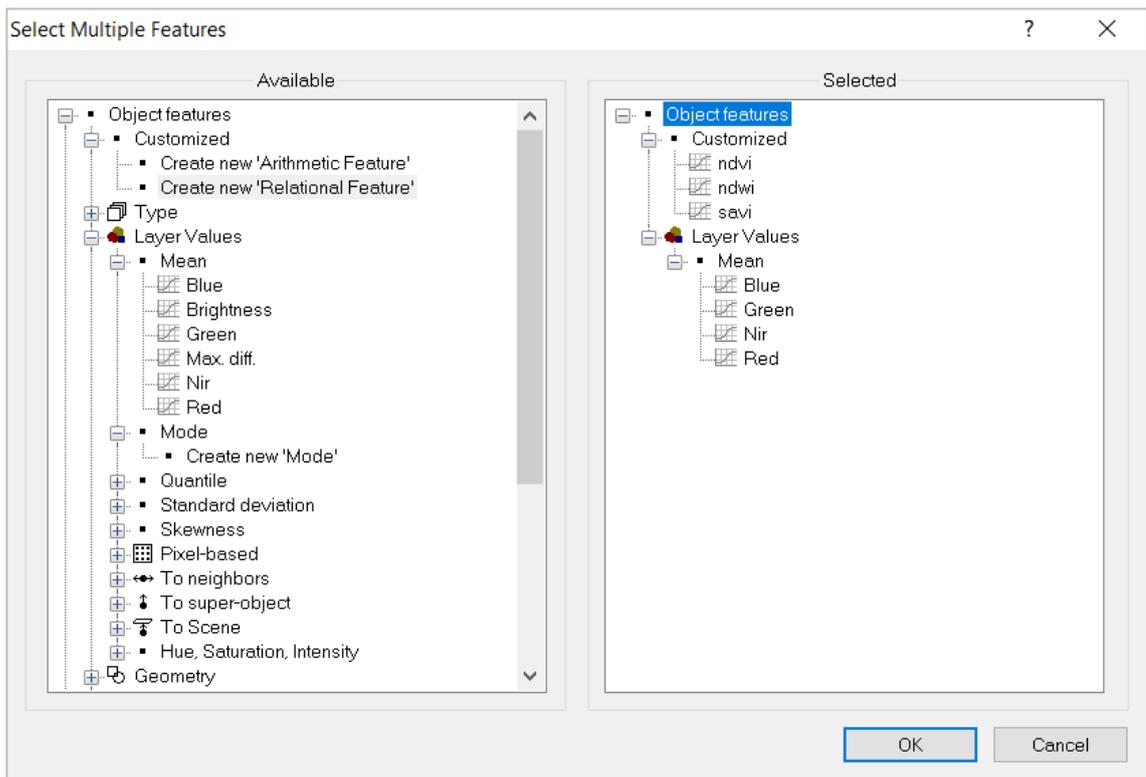


Figura 5.7. Ventana de *Select Múltiple Feature*, permite agregar parámetros e índices a la clasificación

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

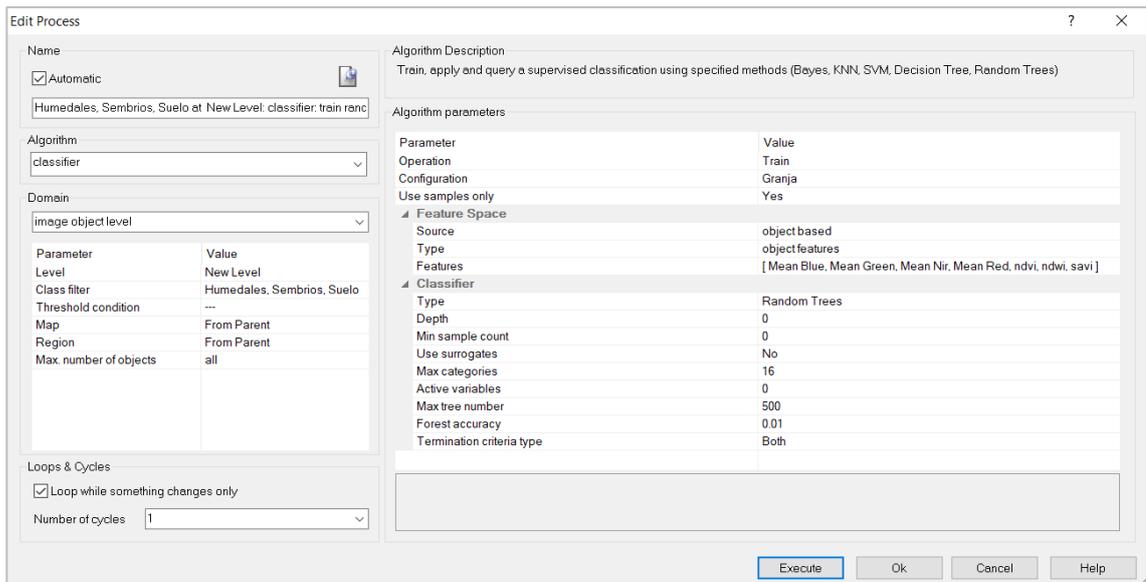


Figura 5.8. Configuración del clasificador del algoritmo *Random Forest*

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

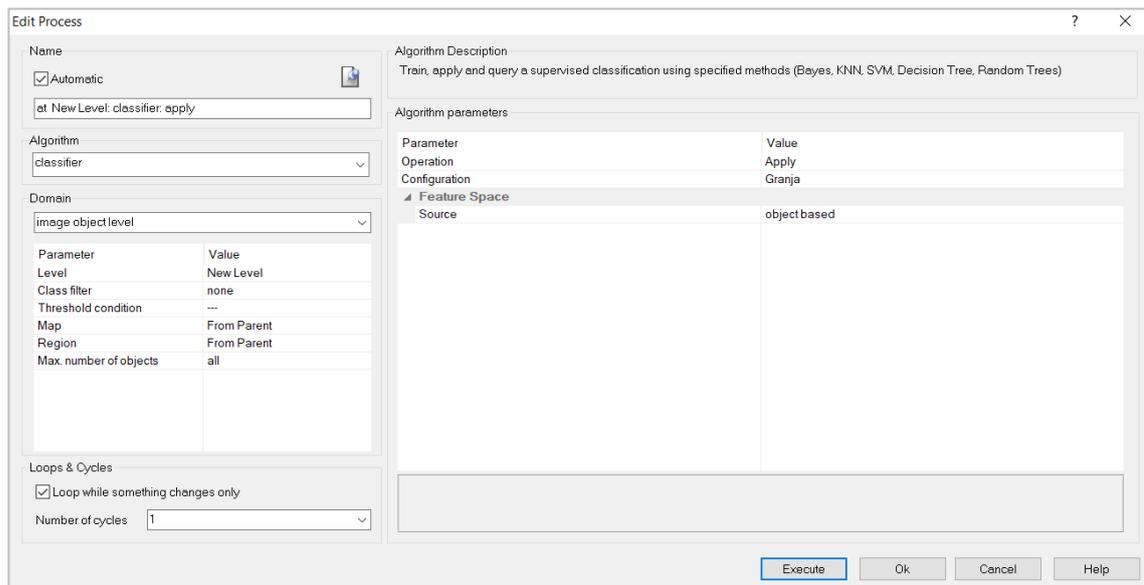


Figura 5.9. Configuración de la aplicación del algoritmo Classifier

5.3.3. Pos-Clasificación del año 2016

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 foteointerpretación. 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*.

5.4. Detección y clasificación de cambios de coberturas para los periodos 2016-2017, 2017-2018, 2018-2019, 2019-2020, 2020-2021 y 2021-2022

5.4.1. Compilación de insumos

a. Selección de imágenes satelitales

En esta sección se describe la selección de imágenes satelitales para los años 2017, 2018, 2019, 2020, 2021 y 2022, ya que la imagen satelital seleccionada para el año 2016 se encuentra descrita en la sección b del subtítulo 5.3.1.

Para los años 2017, 2018, 2019, 2020, 2021 y 2022, se trabajó con escenas de imágenes satelitales de la misión Sentinel 2A, las cuales están disponibles de forma gratuita.

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

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

- Para el año 2017;

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

ee.Geometry.Polygon(
[[[-76.11656776639333, -13.6992732065504],
  [-76.11656776639333, -13.79665132045887],
  [-76.0104810354363, -13.79665132045887],
  [-76.0104810354363, -13.6992732065504]]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')
    .filterBounds (geometry)
    .filterDate ('2017-03-12','2017-03-14')
    .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);
```



PERÚ

Ministerio
del Ambiente

Organismo de Evaluación y
Fiscalización Ambiental - OEFA

STEC: Subdirección
Técnica Científica

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

```
//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: '2017_granja_TOA_03',  
  scale: 10,  
  region: geometry});
```

- Para el año 2018;

```
//Definición de "geometry"
```

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

```
ee.Geometry.Polygon(  
  [[[-76.11656776639333, -13.6992732065504],  
    [-76.11656776639333, -13.79665132045887],  
    [-76.0104810354363, -13.79665132045887],  
    [-76.0104810354363, -13.6992732065504]]], null, false);
```

```
//Imagen para SENTINEL 2A
```

```
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')  
  .filterBounds (geometry)  
  .filterDate ('201-03-21','2018-03-23')  
  .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: '2018_granja_TOA_03',  
  scale: 10,  
  region: geometry});
```

- Para el año 2019;

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/OEFA_DSAP_GRANJA_SINCHI_II"),  
  geometry =  
  /* color: #d63000 */  
  /* shown: false */  
  /* displayProperties: [  
    {  
      "type": "rectangle"  
    }  
  ] */  
  ee.Geometry.Polygon(  
    [[[-76.11656776639333, -13.6992732065504],  
      [-76.11656776639333, -13.79665132045887],  
      [-76.0104810354363, -13.79665132045887],  
      [-76.0104810354363, -13.6992732065504]]], null, false);  
  
//Imagen para SENTINEL 2A  
var IMGSentinel= ee.ImageCollection('COPERNICUS/S2')  
  .filterBounds(geometry)  
  .filterDate('2019-03-21','2019-03-23')  
  .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({
```



PERÚ

Ministerio
del Ambiente

Organismo de Evaluación y
Fiscalización Ambiental - OEFA

STEC: Subdirección
Técnica Científica

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

```
image: SentinelClip.select("B2", "B3", "B4", "B8"),  
description: '2019_granja_TOA_03',  
scale: 10,  
region: geometry});
```

- Para el año 2020;

```
//Definición de "geometry"  
var table = ee.FeatureCollection("users/ OEFA_DSAP_GRANJA_SINCHI_II"),  
  geometry =  
  /* color: #d63000 */  
  /* shown: false */  
  /* displayProperties: [  
    {  
      "type": "rectangle"  
    }  
  ] */  
  
  ee.Geometry.Polygon(  
  [[[-76.11656776639333, -13.6992732065504],  
    [-76.11656776639333, -13.79665132045887],  
    [-76.0104810354363, -13.79665132045887],  
    [-76.0104810354363, -13.6992732065504]]], null, false);  
  
//Imagen para SENTINEL 2A  
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')  
  .filterBounds (geometry)  
  .filterDate ('2020-03-21','2020-03-23')  
  .filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);  
var SentinelFiltro = ee.Image(IMGSentinel.median());  
var SentinelClip = SentinelFiltro.clip (geometry);  
  
//Imprimimos la lista de imágenes disponibles en la pestaña de Console  
print (SentinelFiltro);  
  
//Añadimos la imagen a la vista haciendo una composición de colores y asignando un nombre de etiqueta  
en la vista  
Map.addLayer (SentinelClip, {  
  max: 5000.0,  
  min: 0.0,  
  gamma: 1.2,  
  bands: ['B4','B3','B2'],  
  'Capa Sentinel');  
  
// exportar  
Export.image.toDrive({  
  image: SentinelClip.select("B2", "B3", "B4", "B8"),  
  description: '2020_granja_TOA_03',  
  scale: 10,  
  region: geometry});
```

- Para el año 2021;



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

ee.Geometry.Polygon(
[[[-76.11656776639333, -13.6992732065504],
  [-76.11656776639333, -13.79665132045887],
  [-76.0104810354363, -13.79665132045887],
  [-76.0104810354363, -13.6992732065504]]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')
  .filterBounds (geometry)
  .filterDate ('2021-03-21','2021-03-23')
  .filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);
var SentinelFiltro = ee.Image(IMGSentinel.median());
var SentinelClip = SentinelFiltro.clip (geometry);

//Imprimimos la lista de imágenes disponibles en la pestaña de Console
print (SentinelFiltro);

//Añadimos la imagen a la vista haciendo una composición de colores y asignando un nombre de etiqueta
en la vista
Map.addLayer (SentinelClip, {
  max: 5000.0,
  min: 0.0,
  gamma: 1.2,
  bands: ['B4','B3','B2'],
  'Capa Sentinel');

// exportar
Export.image.toDrive({
  image: SentinelClip.select("B2", "B3", "B4", "B8"),
  description: '2021_granja_TOA_03',
  scale: 10,
  region: geometry});
```

- Para el año 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(
[[[-76.11656776639333, -13.6992732065504],
  [-76.11656776639333, -13.79665132045887],
  [-76.0104810354363, -13.79665132045887],
  [-76.0104810354363, -13.6992732065504]]], null, false);

//Imagen para SENTINEL 2A
var IMGSentinel= ee.ImageCollection ('COPERNICUS/S2')
  .filterBounds (geometry)
  .filterDate ('2022-03-21','2022-03-23')
  .filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 30);
var SentinelFiltro = ee.Image(IMGSentinel.median());
var SentinelClip = SentinelFiltro.clip (geometry);

//Imprimimos la lista de imágenes disponibles en la pestaña de Console
print (SentinelFiltro);

//Añadimos la imagen a la vista haciendo una composición de colores y asignando un nombre de etiqueta
en la vista
Map.addLayer (SentinelClip, {
  max: 5000.0,
  min: 0.0,
  gamma: 1.2,
  bands: ['B4', 'B3', 'B2'],
  'Capa Sentinel');

// exportar
Export.image.toDrive({
  image: SentinelClip.select("B2", "B3", "B4", "B8"),
  description: '2022_granja_TOA_03',
  scale: 10,
  region: geometry});

```

En la Tabla 5.10 se enlista un resumen de las imágenes satelitales usadas para el presente estudio.

Tabla 5.10. Resumen de imágenes satelitales usadas

Año	Sensor	Fecha de captura	Tipo de descarga	Nivel de tratamiento
2017	Sentinel 2A	2017-03-12 / 2018-03-14	Mosaico de imágenes	Reflectancia TOA
2018	Sentinel 2A	2018-03-21 / 2018-03-23	Mosaico de imágenes	Reflectancia TOA
2019	Sentinel 2A	2019-03-21 / 2019-03-23	Mosaico de imágenes	Reflectancia TOA
2020	Sentinel 2A	2020-03-21 / 2020-03-23	Mosaico de imágenes	Reflectancia TOA
2021	Sentinel 2A	2021-03-21 / 2021-03-23	Mosaico de imágenes	Reflectancia TOA
2022	Sentinel 2A	2022-03-21 / 2022-03-23	Mosaico de imágenes	Reflectancia TOA

5.4.1 Detección de cambios

a. Generación del árbol de procesos

Para la generación del árbol de procesos se empleó el software *eCognition Developer 10.1 Trial* (Figura 5.10), 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.

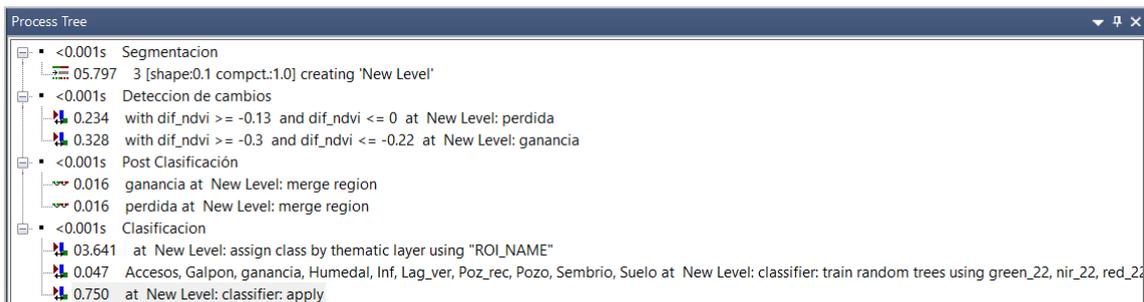


Figura 5.10. Regla de procesos para la detección y clasificación de coberturas en *eCognition Developer 10.1 Trial*.

b. Segmentación del cambio

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

El proceso de segmentación se configuró utilizando los siguientes criterios:

- Los pesos correspondientes a la banda *RED* y *NIR* de ambos años tengan valores a 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* = 3, *Shape* = 0,1 y *Compactness* = 1 (Figura 5.11).

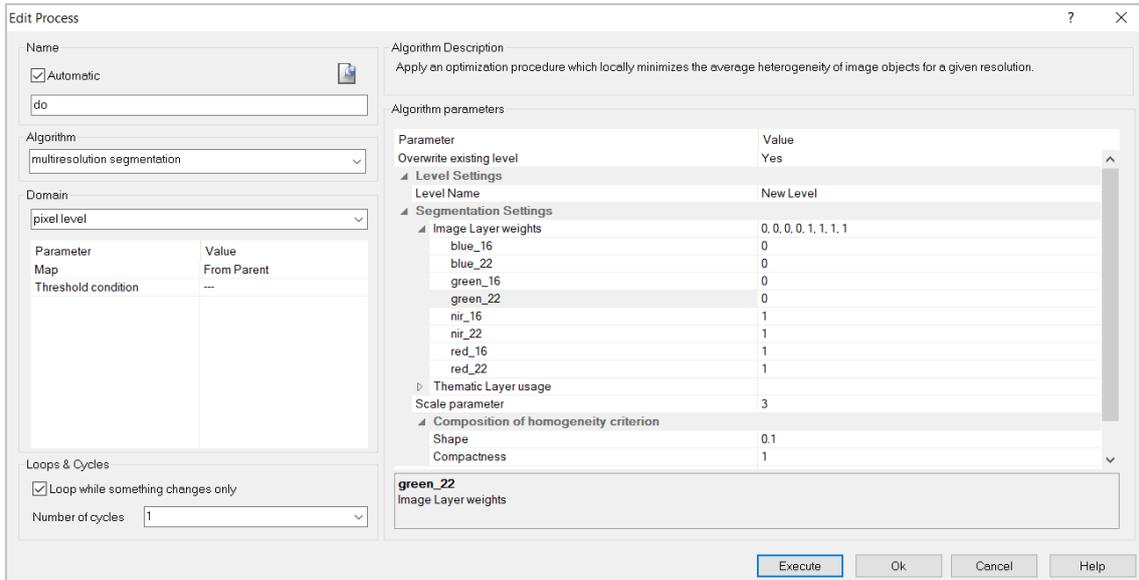


Figura 5.11. Resultado de la configuración de parámetros para la segmentación en *eCognition Developer 10.1 Trial*.

c. Generación del Índice de Vegetación Normalizada (NDVI)

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

Esta diferencia de 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 revegetación de una zona que ha sido intervenido en el Año 1, a lo que uno puede interpretar como una ganancia de la cobertura vegetal.

d. Detección de Umbrales del NDVI

La detección de cambios se realizó en base a Umbrales del NDVI, para ello se utilizó el algoritmo *assign class* configurando los umbrales que cubren todos los sectores de pérdida 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 -0,13 y menores a 0, y aquellos valores que representan la ganancia son mayores a -0,3 y menores a -0,22.

5.4.2 Clasificación de coberturas de cambio

a. Selección de muestras de entrenamiento

La segmentación y detección del cambio generaron muestras de entrenamiento (puntos) con sus respectivos atributos (nombre de clases) con apoyo de la fotointerpretación de las imágenes satelitales. Se definieron clases de cobertura por cada periodo de años analizados considerando que cada año se integraron nuevas coberturas. Cabe precisar que la clase de Suelo escarificado fue clasificado de manera manual.

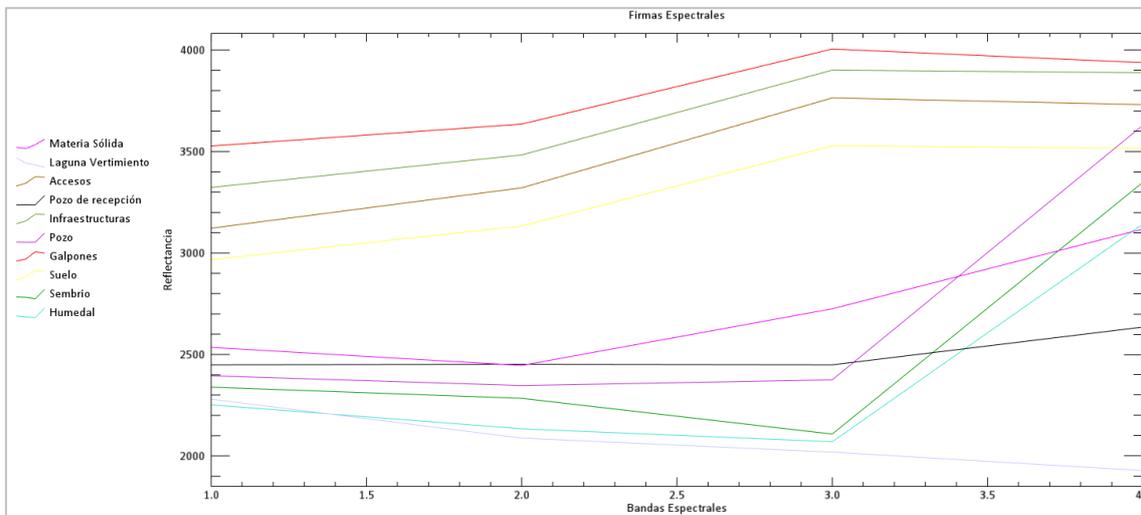


Figura 5.12. Firmas espectrales de las clases identificadas: Materia sólida, laguna de vertimientos, accesos, pozo de recepción, infraestructura, pozo (humedal), galpones, suelo, sembrío y humedal.

b. Clasificación de coberturas

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

i. Creación de clases:

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

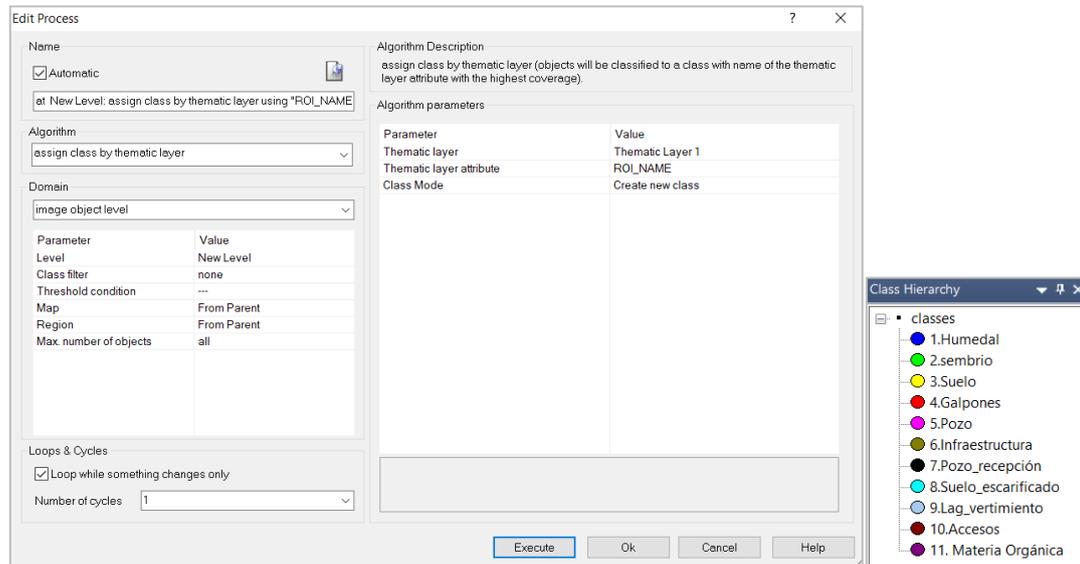


Figura 5.13. Relación de atributos y creación de clases

ii. Asignación de clases a los segmentos:

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

iii. Clasificación usando el algoritmo *Random Forest*

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

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

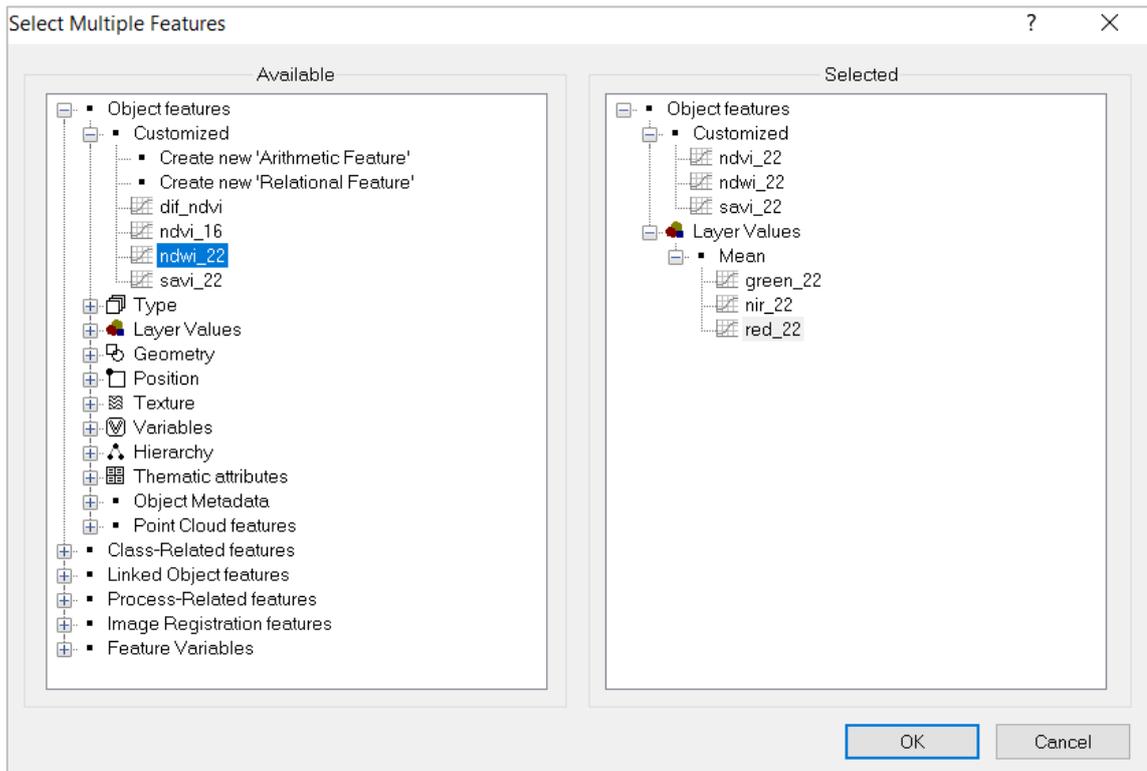


Figura 5.14. Ventana de Select Múltiple Feature, que permite agregar parámetros e índices a la clasificación

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.

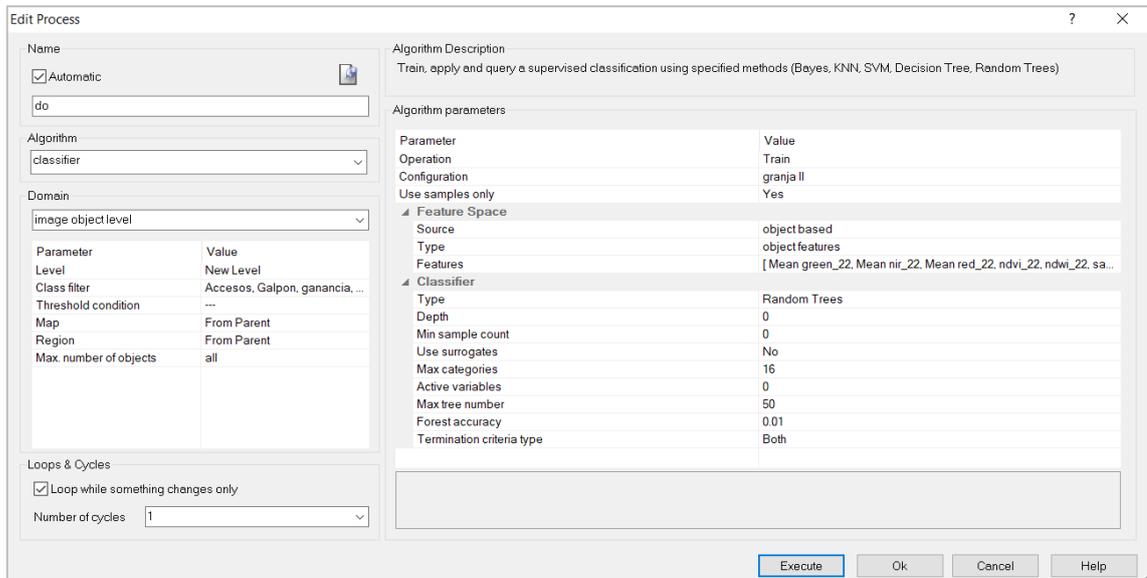


Figura 5.15. Configuración del clasificador del algoritmo *Random Forest*

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.

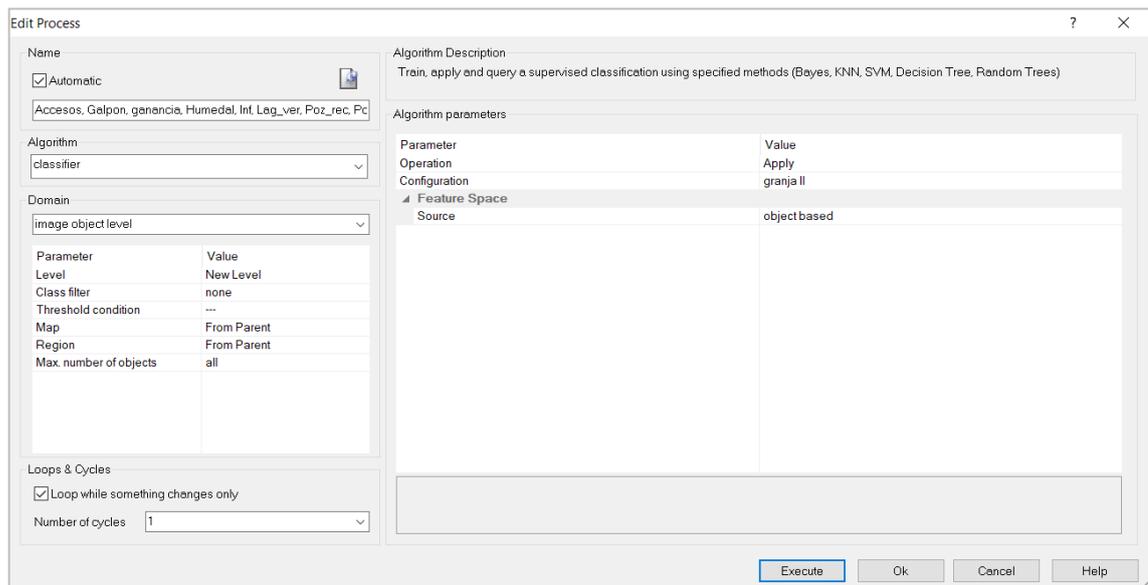


Figura 5.16. Configuración de la aplicación del algoritmo Classifier

5.4.3 Pos-Clasificación

a. Ajuste de los resultados de la clasificación de coberturas

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

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

A continuación, se presentan los resultados de la identificación de clases de coberturas y la estimación de la extensión del área impactada producto de vertimientos, acumulación de aguas residuales inadecuadas tratadas e infraestructuras en el área de estudio de la unidad fiscalizable Granja Sinchi II administrada por la empresa Redondos SA.

a. Identificar clases de coberturas de uso de suelo en la Unidad Fiscalizable Granja Sinchi II para los años 2016, 2017, 2018, 2019, 2020, 2021 y 2022.

Para el año 2016 se identificaron cuatro (4) clases de coberturas: Suelo con una extensión de 174,43 ha, humedal con una extensión de 2,11 ha, sembríos con una extensión de 0,31 ha y pozo (humedal) con una extensión 0,58 ha. (Figura 6.1 y Figura 6.2)

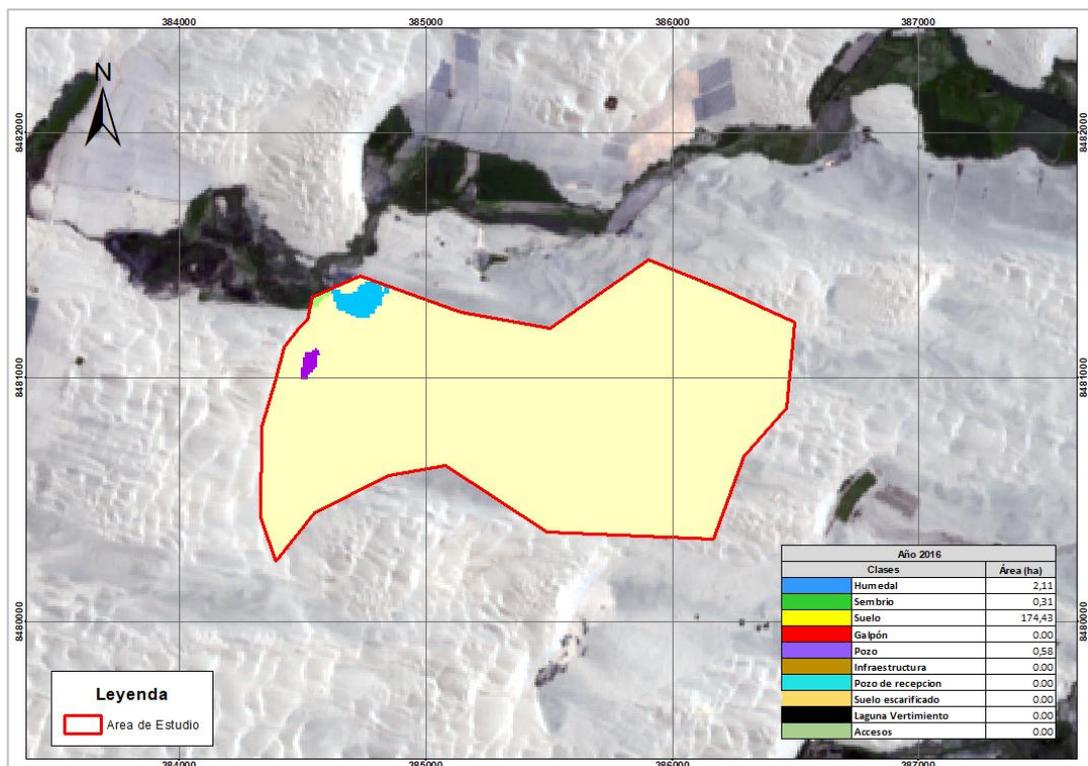


Figura 6.1. Clases de cobertura del año 2016 en el área de estudio de la unidad fiscalizable Granja Sinchi II

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

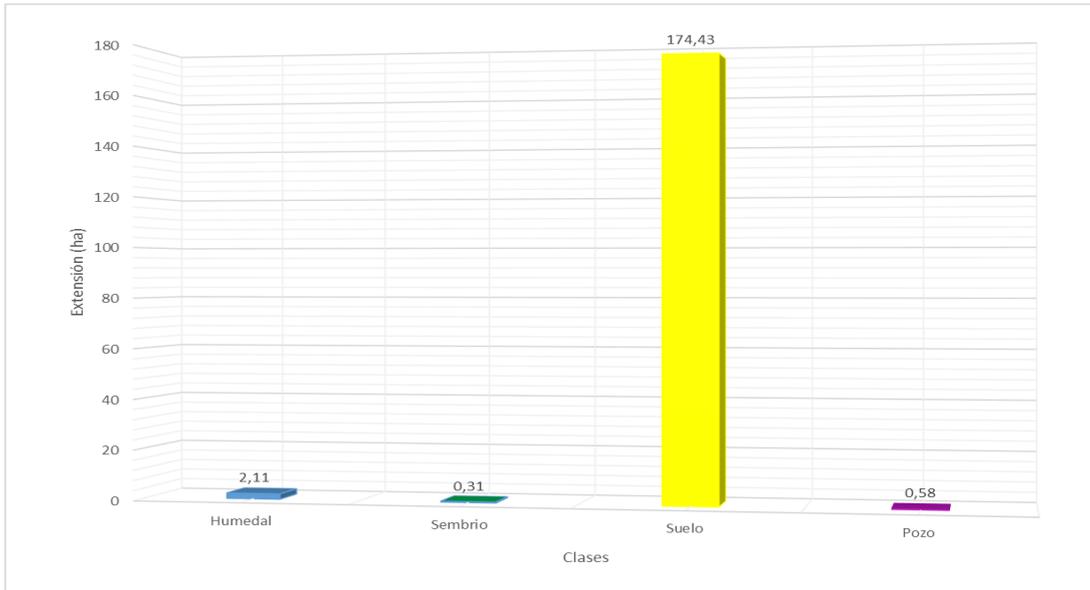


Figura 6.2. Extensión de cobertura para el año 2016

Para el año 2017 se identificaron cinco (5) clases de coberturas: Suelo con una extensión de 173,92 ha, humedal con una extensión de 2,11 ha, sembríos con una extensión de 0,31 ha, pozo (humedal) con una extensión 0,58 ha y el inicio de actividades de las granjas con galpones de extensión 0,51 ha. (Figura 6.3 y Figura 6.4).

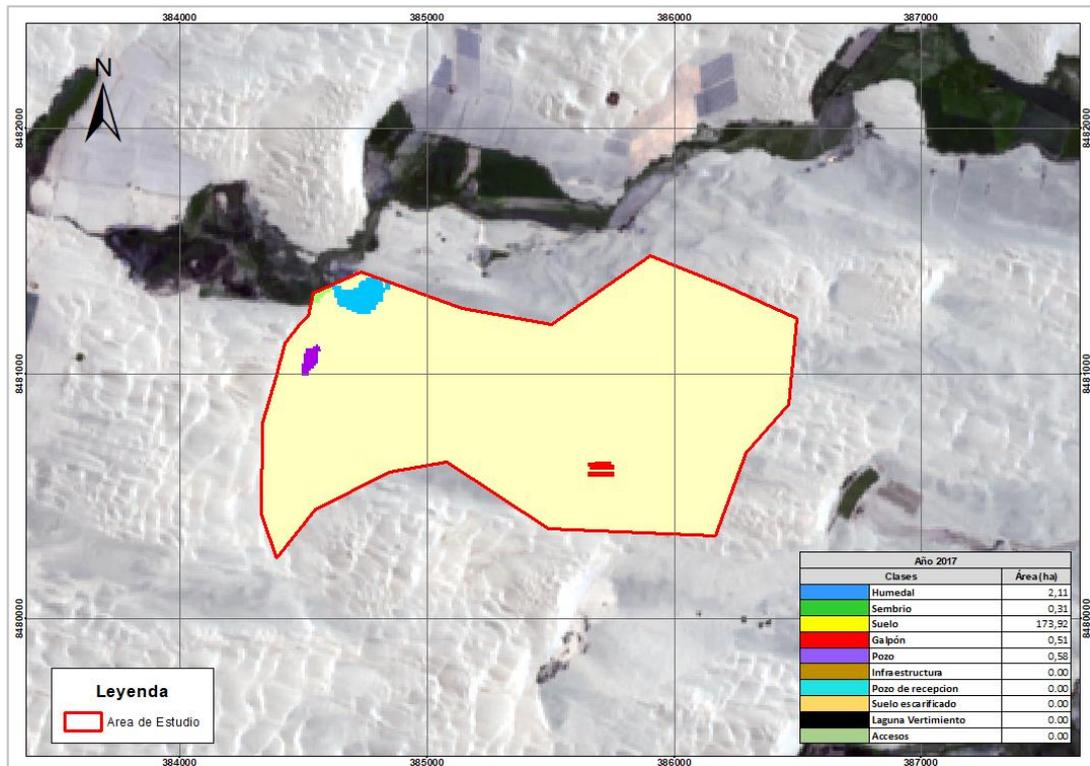


Figura 6.3. Clases de cobertura del año 2017 en el área de estudio de la unidad fiscalizable Granja Sinchi II

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

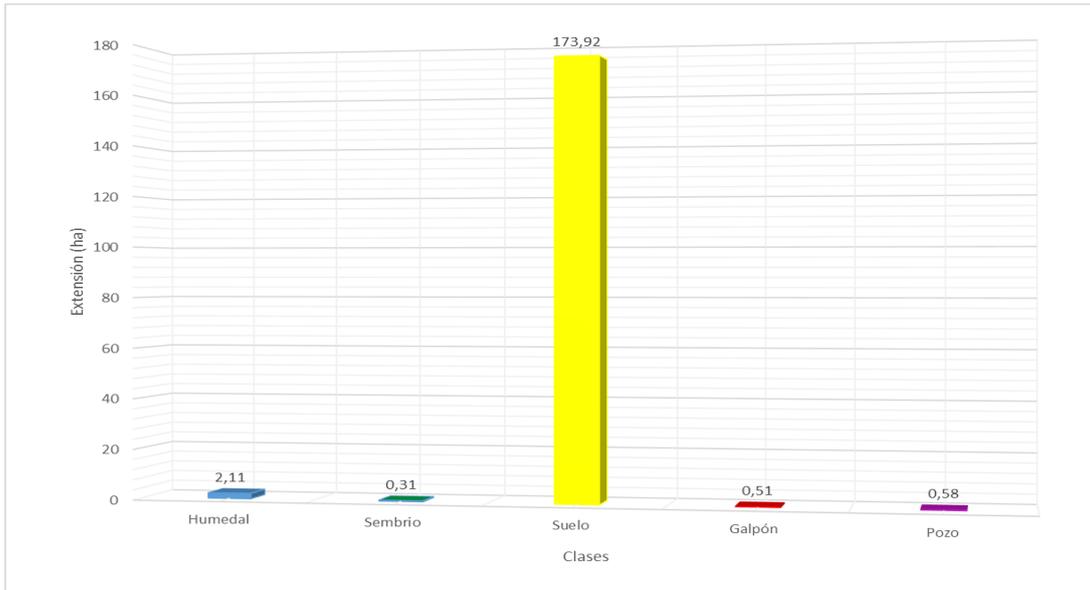


Figura 6.4. Extensión de cobertura para el año 2017

Para el año 2018 se identificaron ocho (8) clases de coberturas: Suelo con una extensión de 165,49 ha, humedal con una extensión de 2,3 ha, sembríos con una extensión de 0,46 ha, pozo (humedal) con una extensión 0,72 ha, galpones con una extensión 5,92 ha y la construcción de infraestructuras con una extensión de 0,82 ha, pozos de recepción con una extensión de 0,22 ha y suelos escarificados (suelos que se preparan para la construcción de galpones) con una extensión de 1,48 ha. (Figura 6.5 y Figura 6.6).

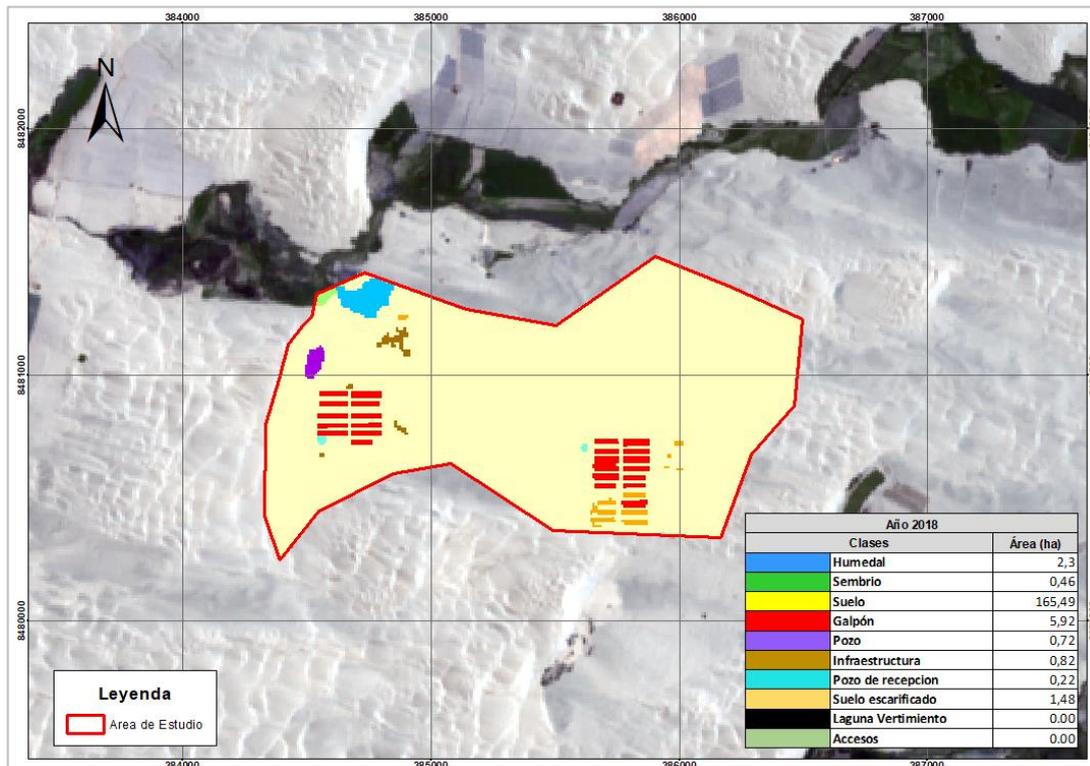


Figura 6.5. Clases de cobertura del año 2018 en el área de estudio de la unidad fiscalizable Granja Sinchi II

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

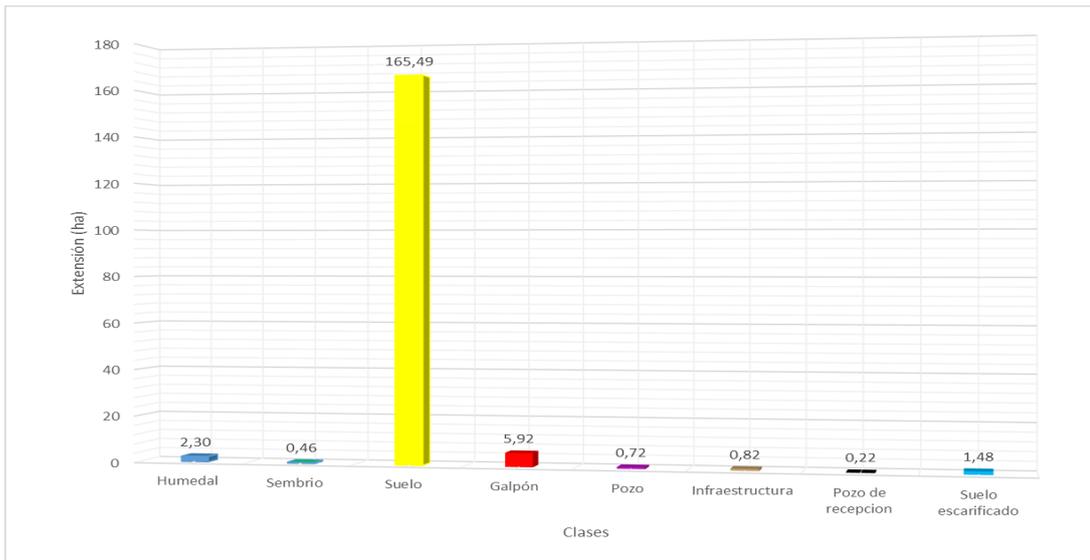


Figura 6.6. Extensión de cobertura para el año 2018

Para el año 2019 se identificaron once (11) clases de coberturas: Suelo con una extensión de 159,12 ha, humedal con una extensión de 2,3 ha, sembríos con una extensión de 0,46 ha, pozo (humedal) con una extensión 0,72 ha, galpones con una extensión 10,77 ha, infraestructuras con una extensión de 1,73 ha, pozos de recepción con una extensión de 0,09 ha y suelos escarificados (suelos que se preparan para la construcción de galpones) con una extensión de 0,20 ha y nuevas coberturas como accesos con una extensión de 1,06 ha y el inicio de vertimiento de aguas con una extensión de 0,88 ha y acumulación de materia orgánica con una extensión de 0,08 ha. (Figura 6.7 y Figura 6.8).

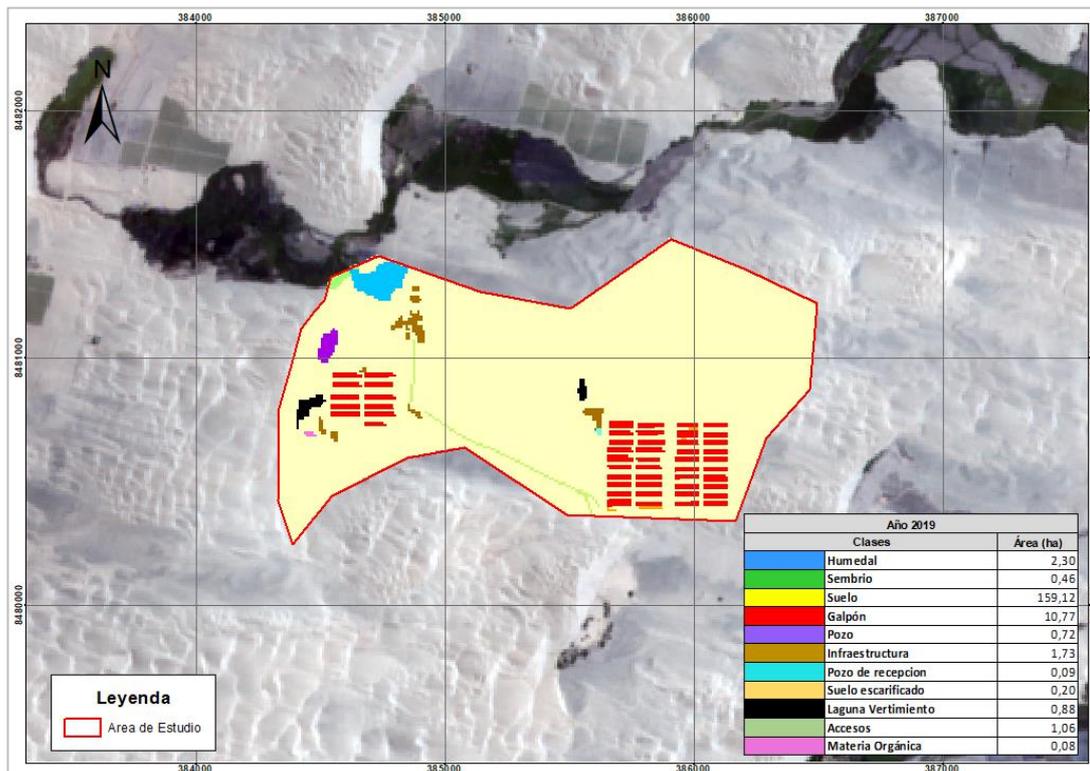


Figura 6.7. Clases de cobertura del año 2019 en el área de estudio de la unidad fiscalizable Granja Sinchi II

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

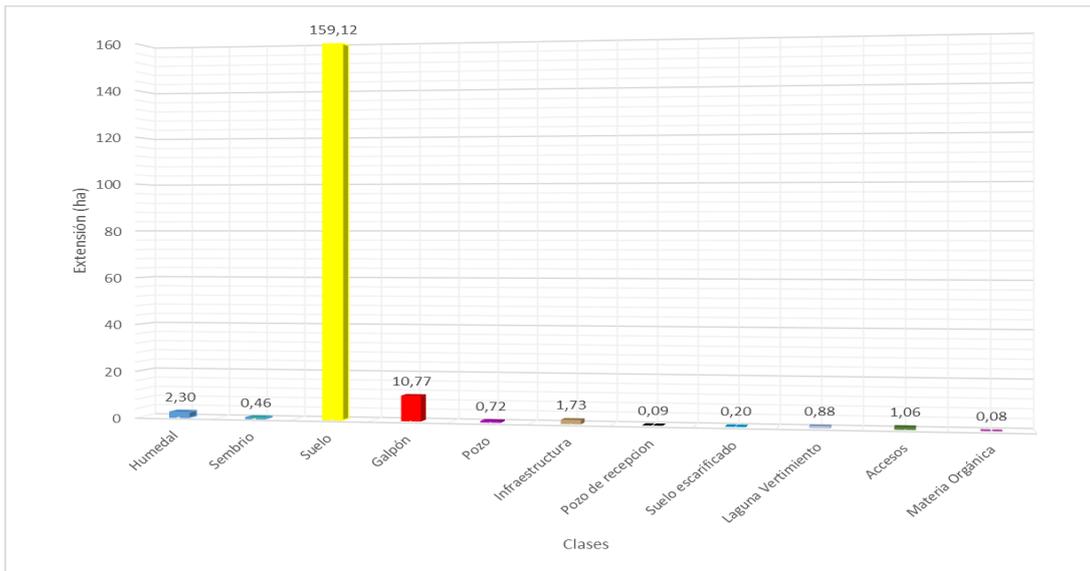


Figura 6.8. Extensión de cobertura para el año 2019

Para el año 2020 se identificaron once (11) clases de coberturas; Suelo con una extensión de 147,87 ha, humedal con una extensión de 2,3 ha, sembríos con una extensión de 0,50 ha, pozo (humedal) con una extensión 0,72 ha, galpones con una extensión 18,54 ha, infraestructuras con una extensión de 2,07 ha, pozos de recepción con una extensión de 0,25 ha y suelos escarificados (suelos que se preparan para la construcción de galpones) con una extensión de 0,32 ha, accesos con una extensión de 1,26 ha, vertimiento de aguas con una extensión de 1,96 ha y acumulación de materia orgánica con una extensión de 1,63 ha. (Figura 6.9 y Figura 6.10).

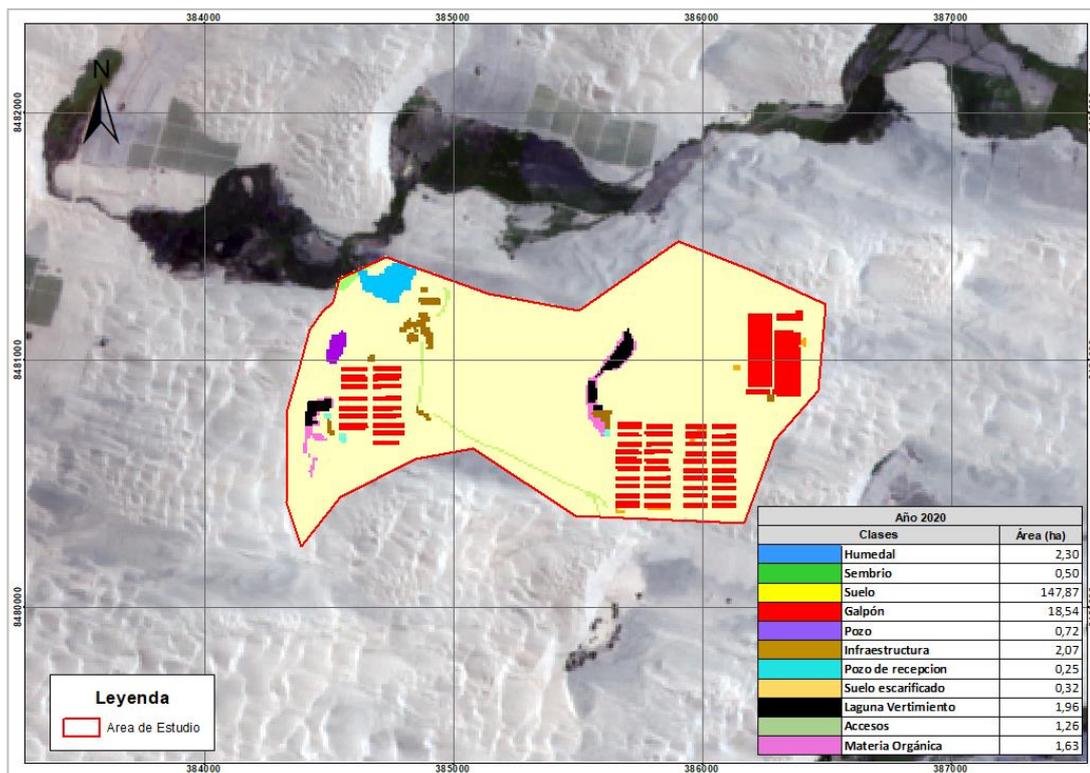


Figura 6.9. Clases de cobertura del año 2020 en el área de estudio de la unidad fiscalizable Granja Sinchi II

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

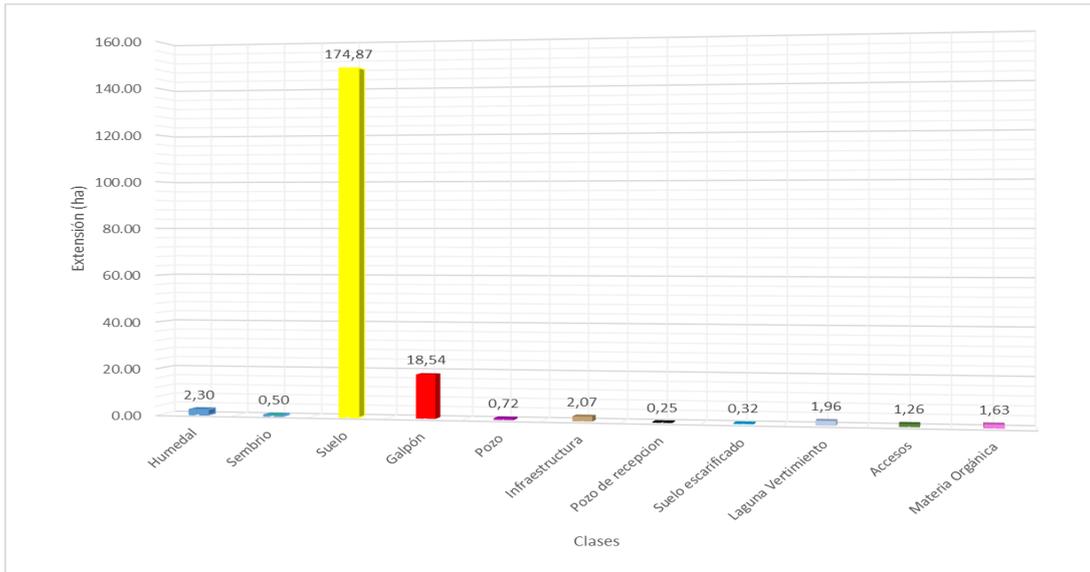


Figura 6.10. Extensión de cobertura para el año 2020

Para el año 2021 se identificaron once (11) clases de coberturas: Suelo con una extensión de 143,68 ha, humedal con una extensión de 2,3 ha, sembríos con una extensión de 0,50 ha, pozo (humedal) con una extensión 0,72 ha, galpones con una extensión 19,00 ha, infraestructuras con una extensión de 2,48 ha, pozos de recepción con una extensión de 0,25 ha y suelos escarificados (suelos que se preparan para la construcción de galpones) con una extensión de 0,32 ha, accesos con una extensión de 1,26 ha, vertimiento de aguas con una extensión de 3,92 ha y acumulación de materia orgánica con una extensión de 2,97 ha. (Figura 6.11 y Figura 6.12).

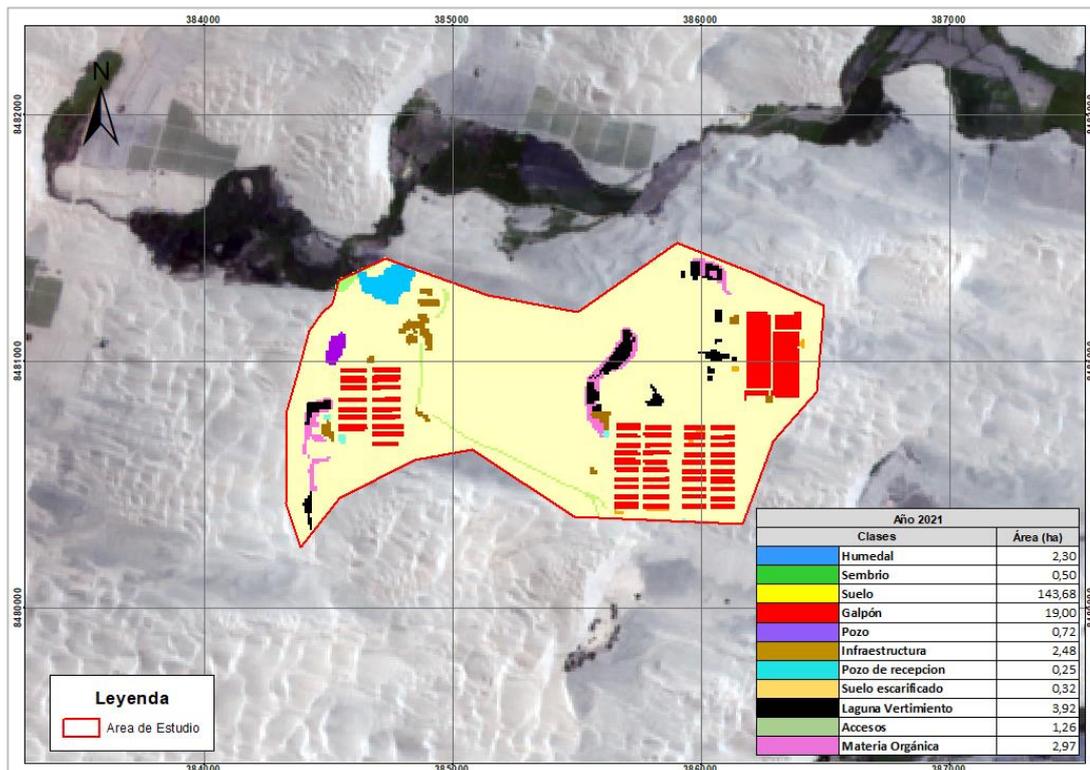


Figura 6.11. Clases de cobertura del año 2021 en el área de estudio de la unidad fiscalizable Granja Sinchi II

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

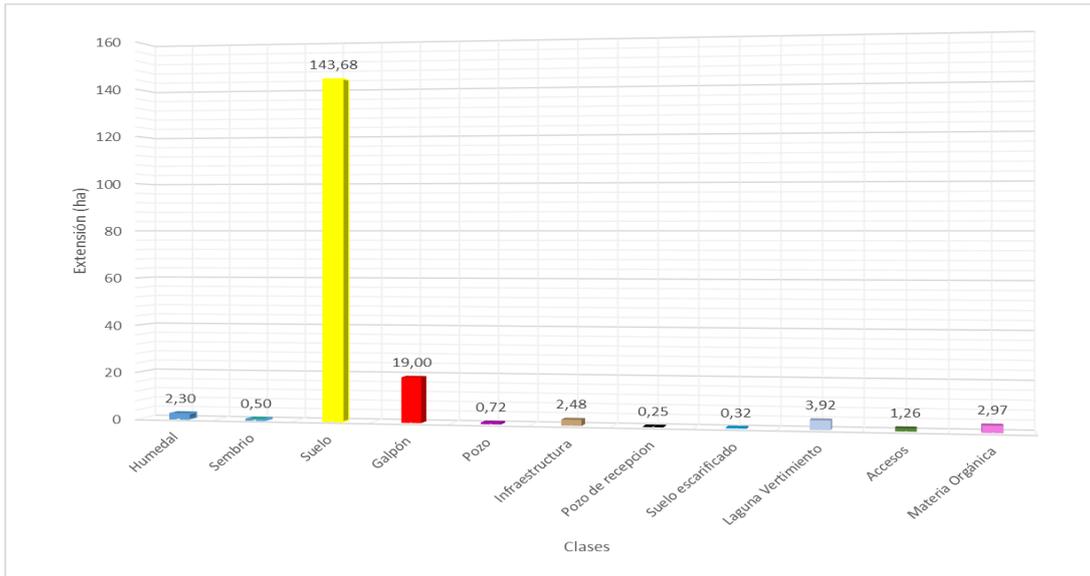


Figura 6.12. Extensión de cobertura para el año 2021

Para el año 2022 se identificaron once (11) clases de coberturas: Suelo con una extensión de 139,84 ha, humedal con una extensión de 2,3 ha, sembríos con una extensión de 0,50 ha, pozo (humedal) con una extensión 0,72 ha, galpones con una extensión 19,00 ha, infraestructuras con una extensión de 3,04 ha, pozos de recepción con una extensión de 0,42 ha y suelos escarificados (suelos que se preparan para la construcción de galpones) con una extensión de 0,32 ha, accesos con una extensión de 1,26 ha, vertimiento de aguas con una extensión de 6,16 ha y acumulación de materia orgánica con una extensión de 3,86 ha. (Figura 6.13 y Figura 6.14).

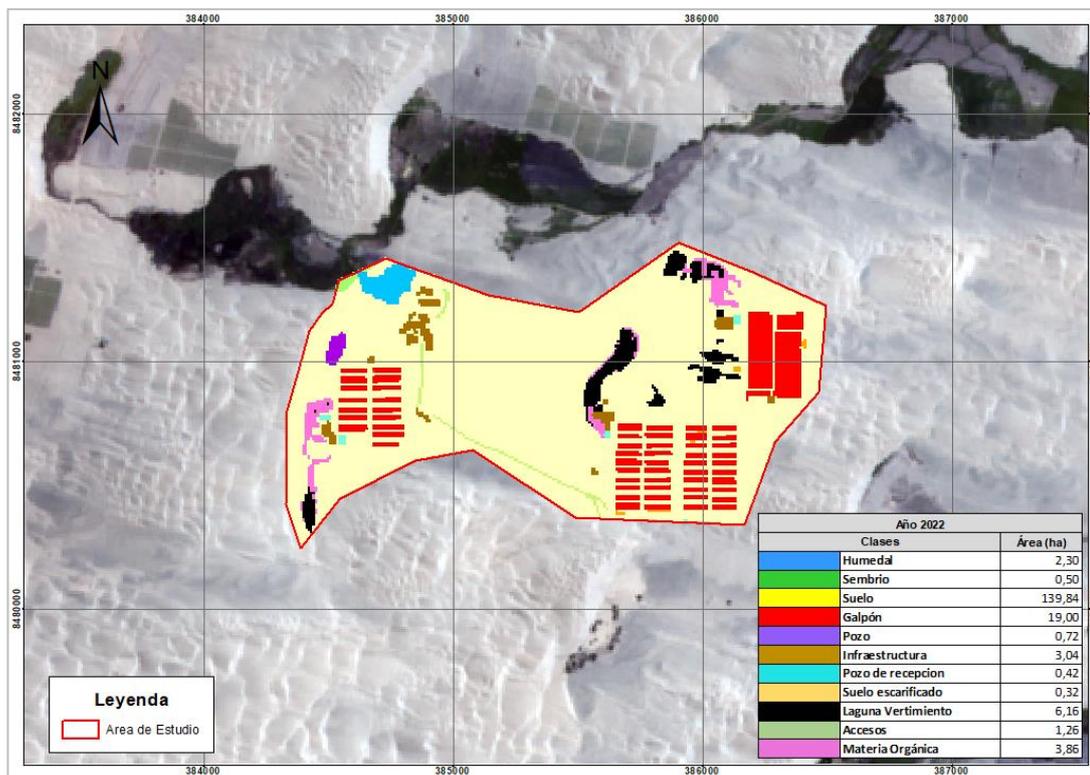
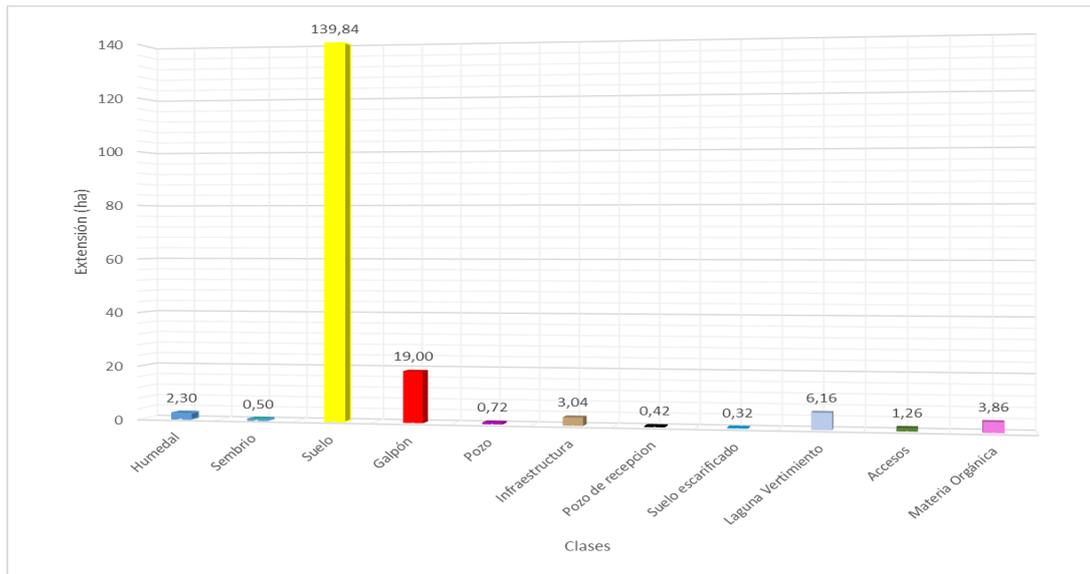


Figura 6.13. Clases de cobertura del año 2022 en el área de estudio de la unidad fiscalizable Granja Sinchi II

**Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional**

Figura 6.14. Extensión de cobertura para el año 2022

- b. Estimar el área impactada producto de vertimientos, acumulación de aguas residuales industriales inadecuadamente tratadas e infraestructuras dentro de la UFGSII en siete (06) periodos de análisis (2016-2017 2017-2018, 2018-2019, 2019-2020, 2020-2021 y 2021-2022) en la unidad fiscalizable Granja Sinchi II.

Del análisis general desde al año 2016 al 2022 (Tabla 6.1 y Figura 6.15), se tiene que el Suelo ha tenido una pérdida de cobertura de 34,59 ha (equivalente al 19,8% de su cobertura inicial), asimismo los galpones iniciaron sus instalaciones en el año 2017 con 0,51 ha y para el año 2022 incrementó a 19 ha. Las infraestructuras iniciaron actividad en el año 2018 con 0,82 ha y se incrementaron a 3,04 ha para el año 2022. Los pozos de recepción de vertimientos iniciaron en el 2018 con 0,22 ha y para el año 2022 se incrementó en 0,42 ha. Los accesos iniciaron actividades en el año 2019 con 1,06 ha y se extendió a 1,26 ha para el año 2022. Las lagunas de vertimientos se evidenciaron para el año 2019 con una extensión de 0,96 ha y se incrementó para el año 2022 a 10 ha. Alrededor de las lagunas se acumulan materia orgánica, el cual para el año 2019 contaba con un área de 0,08 ha y para el 2022 incrementó hasta 3,86 ha.

Clases	Año 2016	Año 2017	Año 2018	Año 2019	Año 2020	Año 2021	Año 2022
Humedal	2,11	2,11	2,30	2,30	2,30	2,30	2,30
Sembrío	0,31	0,31	0,46	0,46	0,50	0,50	0,50
Suelo	174,43	173,92	165,49	159,12	147,87	143,68	139,84
Galpón	0,00	0,51	5,92	10,77	18,54	19,00	19,00
Pozo (humedal)	0,58	0,58	0,72	0,72	0,72	0,72	0,72
Infraestructura	0,00	0,00	0,82	1,73	2,07	2,48	3,04
Pozo de recepción	0,00	0,00	0,22	0,09	0,25	0,25	0,42
Suelo escarificado	0,00	0,00	1,48	0,20	0,32	0,32	0,32
Laguna de Vertimiento	0,00	0,00	0,00	0,88	1,96	3,92	6,16
Accesos	0,00	0,00	0,00	1,06	1,26	1,26	1,26
Materia Orgánica	0,00	0,00	0,00	0,08	1,63	2,97	3,86

Tabla 6.2. Superficie de coberturas por año clasificado

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

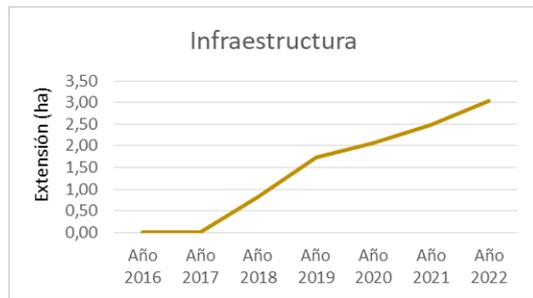
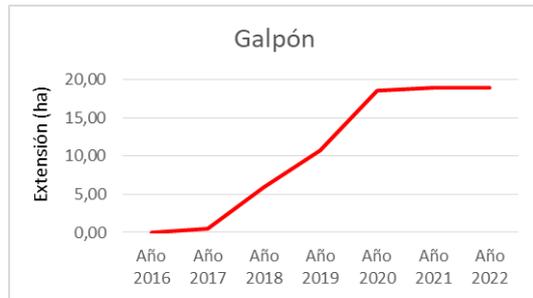
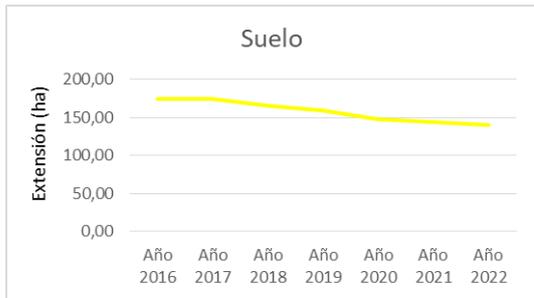
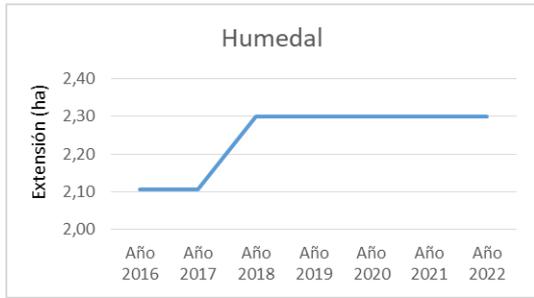




Figura 6.15. Análisis multitemporal (2016-2022) de coberturas

c. Estimar la distancia a centros poblados más cercano en relación a las zonas de afectación producto de las actividades de la UFGSII.

En base al Centroides de la Unidad Fiscalizable se calcularon las distancias más cercanas a los centros poblados circundantes, siendo el CP Cuchilla Nueva la más cercana con una distancia de 2,78 km, el CP Cuchilla Vieja a una distancia de 3,59 km, el CP Huarangal a una distancia de 3,67 km, el CP Los Paracas L3 a una distancia de 3,74 km, el CP Los Paracas L4 a una distancia de 4,65 km y el CP Costa Rica la más lejana a 5,68 km.

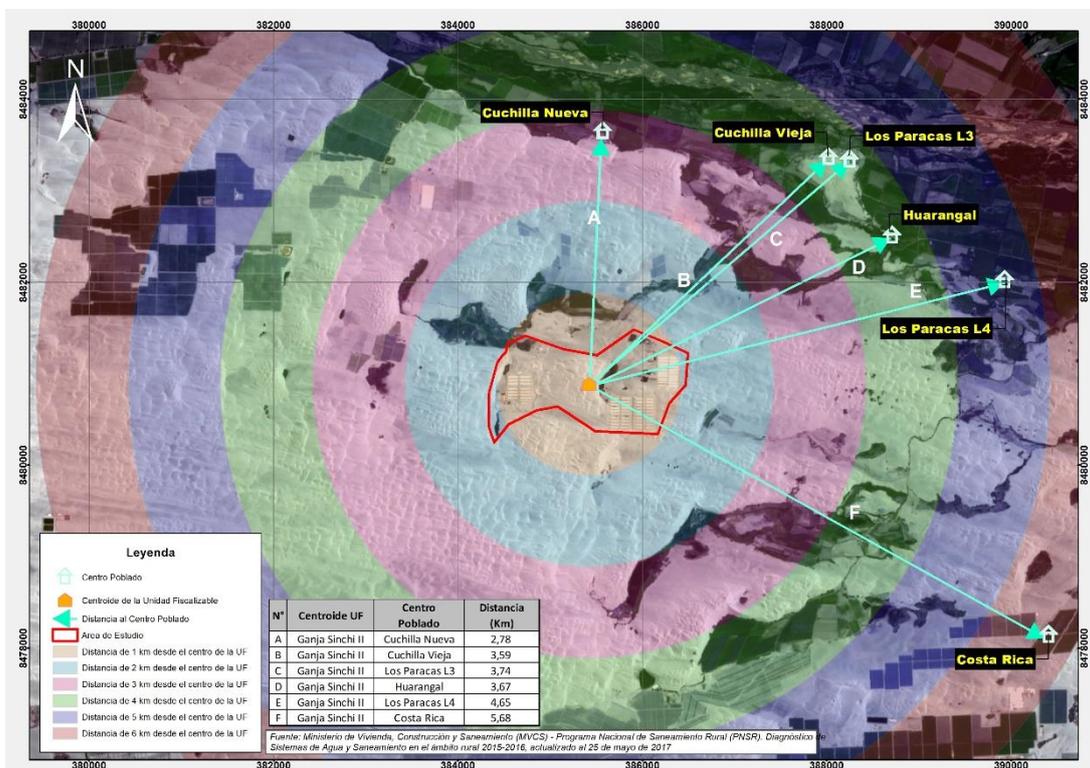


Figura 6.16. Distancia de la UFGSII a centro poblados más cercanos.

7. CONCLUSIONES

- i. Se identificaron cuatro (4) clases de cobertura para el año 2016: Suelo, humedales, sembríos y pozo (humedal); para el año 2017 se identificaron cinco (5) clases de coberturas incluyendo el galpón; asimismo para el año 2018 se identificaron ocho (8) clases incluyendo infraestructuras, pozos de recepción y suelos escarificados; y para el año 2019 al 2022 se identificaron once (11) clases de coberturas, el cual incluyen



PERÚ

Ministerio
del Ambiente

Organismo de Evaluación y
Fiscalización Ambiental - OEFA

STEC: Subdirección
Técnica Científica

Decenio de la Igualdad de Oportunidades para Mujeres y Hombres
Año del Fortalecimiento de la Soberanía Nacional

las lagunas de vertimientos, materia orgánica y accesos en el área de estudio de la unidad fiscalizable Granja Sinchi II.

- ii. Se estimaron las extensiones de las áreas de cobertura para cada año de análisis (2016, 2017, 2018, 2019, 2020, 2021 y 2022) en el área de estudio de la unidad fiscalizable Granja Sinchi II, el cual en relación al año 2016 la clase suelo ha tenido una alteración de su condición inicial, perdiendo 34,59 ha y las clases humedal, sembrío, galpón, infraestructura, pozo de recepción, suelo escarificado, accesos, laguna de vertimiento y materia orgánica incrementaron sus instalaciones en 0,19 ha, 0,19 ha, 19,00 ha, 0,14 ha, 3,04 ha, 0,42 ha, 0,32 ha, 1,26 ha, 6,16 ha y 3,86 ha respectivamente para el año 2022.
- iii. Se estimaron las distancias desde el Centroides de la Unidad Fiscalizable hacia los centros poblados más cercanos, siendo estos centros poblados Cuchilla Nueva, Cuchilla Vieja, Huarangal, Los Paracas L3, Los Paracas L4 y Costa Rica con una distancia de 2,78 km, 3,59 km, 3,67 km, 3,74 km, 4,65 km y 5,68 km respectivamente.

8. RECOMENDACIONES

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

9. ANEXOS

Anexo 1: Acta de Inicio

Anexo 2: Plan de Estudio

Anexo 3: Mapa de clasificación de coberturas de los años 2016, 2017, 2018, 2019, 2021 y 2022 en la unidad fiscalizable Granja Sinchi II.

Atentamente:

[LFAJARDO]

[MCABALLERO]

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

Atentamente:

[FGARCIA]



"Esta es una copia auténtica imprimible de un documento electrónico archivado por el OEFA, aplicando lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. N° 026-2016-PCM. Su autenticidad e integridad pueden ser contrastadas a través de la siguiente dirección web: <https://sistemas.oefa.gob.pe/verifica> e ingresando la siguiente clave: 05619020"



05619020