UNIVERSIDAD
NACIONAL
DE COLOMBIA

Semiautomatización del cambio en la cobertura de la tierra con software y datos de libre acceso

Sergio Andrés Rubiano Sosa

Universidad Nacional de Colombia
Facultad de Ciencias Agrarias, Departamento de Geomática
Bogotá D.C., Colombia
2025

Semiautomatización del cambio en la cobertura de la tierra con software y datos de libre acceso

Sergio Andrés Rubiano Sosa

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Magister en Geomática

Director (a):

Ph.D. Jaime Humberto Bernal Riobo

Codirector (a):

Ph.D. Yolanda Rubiano Sanabria

Línea de Investigación:

Geoinformación para el uso sostenible de los recursos naturales

Grupo de Investigación

Universidad Nacional de Colombia

Facultad de Ciencias Agrarias, Departamento de Geomática

Bogotá D.C., Colombia

2025

Declaración de obra original

Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.

_____

Sergio Andres Rubiano Sosa

04/21/2025

Resumen

Semiautomatización del cambio en la cobertura de la tierra con software y datos de libre acceso

El cambio en la cobertura de la tierra es un proceso dinámico espacial y temporal, por lo tanto, es necesario generar métodos semiautomáticos en software libre que faciliten el tiempo de procesamiento y disminuyan los costos. La integración de aplicaciones, plataformas y software de libre acceso para el procesamiento de imágenes satelitales sin costo se ha identificado como una alternativa efectiva para el progreso en el desarrollo de soluciones para efectuar la clasificación y el monitoreo del cambio de coberturas de la tierra. Este estudio generó una metodología semiautomática en la plataforma Google Earth Engine (GEE) y QGIS para monitorear el cambio de las coberturas de la tierra utilizando imágenes de la misión Sentinel-2 (S-2). El trabajo se desarrolló en el área correspondiente a la subzona hidrográfica Rio Yucao que se encuentra en Puerto López y Puerto Gaitán, Meta, Colombia. Se estudiaron 13 tipos de coberturas. Se utilizó un método de clasificación basado en pixeles y aprendizaje de máquina (ML) el cual fue el clasificador de Bosques Aleatorios (RF) en GEE. En la cual se obtuvo una exactitud general con un 84% aunque al realizar una evaluación visual a detalle se encontraron ciertas imprecisiones en la clasificación de clases como caucho, cultivos forestales y bosques de galería. Adicionalmente, para la detección del cambio se realizó un análisis de tabulación cruzada píxel por píxel. Esta metodología permite mejorar la clasificación de coberturas en los trópicos, ya que la plataforma tiene un amplio repositorio de imágenes de la misión Sentinel-2. Estas imágenes tienen alta resolución espectral (12 bandas) y frecuente resolución temporal (5 días), por lo cual, es posible mejorar la calidad de la clasificación y aumentar la posibilidad de identificar escenas con menor nubosidad de manera más eficiente. Entonces, la metodología desarrollada en este estudio permite filtrar imágenes

de mayor calidad, reduciendo tiempo y costos de hardware y software al usar servidores en la nube y plataformas que no requieren licencia.

Palabras clave: *Semiautomatización, Sentinel-2, GEE, Arboles aleatorios, Clasificación de la Cobertura de la Tierra, Datos de Libre Acceso.*

Abstract

Semiautomated Analysis of Land Cover Change Using Open-Access Tools and Datasets

Land cover change is a spatially and temporally dynamic process, therefore, it is necessary to generate semi-automatic methods in free software that facilitate processing time and reduce costs. The integration of freely available applications, platforms and software for processing satellite images at no cost has been identified as an effective alternative for progress in the development of solutions to perform land cover change classification and monitoring. This study generated a semi-automated methodology in Google Earth Engine (GEE) and QGIS platform to monitor land cover change using Sentinel-2 (S-2) mission imagery. The work was developed in the area corresponding to the Rio Yucao hydrographic subzone located in Puerto Lopez and Puerto Gaitan, Meta, Colombia. Thirteen cover types were studied. A classification method based on pixels and machine learning (ML) was used, which was the Random Forest (RF) classifier in GEE. In which a general accuracy of 84% was obtained, although a detailed visual evaluation found certain inaccuracies in the classification of classes such as rubber, forest crops and gallery forests. Additionally, for change detection, a pixel-by-pixel cross-tabulation analysis was performed. This methodology allows for improved land cover classification in the tropics, since the platform has a large repository of images from the Sentinel-2 mission. These images have high spectral resolution (12 bands) and frequent temporal resolution (5 days), so it is possible to improve the quality of the classification and increase the possibility of identifying scenes with less cloud cover more efficiently. Thus, the methodology developed in this study allows filtering higher quality images, reducing time and hardware and software costs by using cloud servers and license-free platforms.

Keywords: *Semi-automation, GEE, Sentinel-2, Land Cover Classification, Random Forest, Open Data.*

Contenido

Pág.

Resumen ..... **VII**

Lista de figuras ..... **XIII**

Lista de tablas ..... **XVI**

1. Introducción **17**
1.1 Formulación del problema 22
1.2 Aproximación conceptual 23
1.3 Pregunta de investigación 24
1.4 Objetivos 24
1.4.1 Objetivo general 24
1.4.2 Objetivos específicos 24
1.5 Importancia de la investigación 24

2. Marco Teórico **27**
2.1 Percepción remota en el monitoreo de coberturas de la tierra 27
2.1.1 Los sensores remotos en el mapeo de coberturas agrícolas 28
2.1.2 Métodos de mapeo de coberturas 31
2.2 Semiautomatización y percepción remota 34
2.3 Datos de libre acceso y procesamiento en la nube 35

3. Metodología **39**
3.1 Área de estudio 40
3.2 Datos 41
3.2.1 Selección de imágenes y preprocesamiento 41
3.3 Esquema de clasificación 42
3.3.1 Definición de clases 42
3.4 Datos de referencia 43
3.4.1 Fuente de datos 43
3.4.2 Puntos de entrenamiento y validación 43
3.5 Método de clasificación 43
3.5.1 Algoritmo de clasificación 43
3.6 Validación 44
3.6.1 Matriz de confusión 44
3.6.2 Exactitud general 44
3.7 Método de detección de cambio de cobertura 45

4. Resultados **47**
4.1 Metodología propuesta para la semiautomatización del cambio de cobertura 47

4.2 Metodología aplicada en la zona de estudio 63

5. Discusión..... 72

6. Conclusiones 76

A. Anexo: Script para el monitoreo del cambio de la cobertura en GEE..... 77

Bibliografía 95

Lista de figuras

Pág.

Figura 2.1. Estructura de la hoja celular y su interacción con la energía electromagnética de la región del RGB y NIR. Tomada de Curtis (2001). 30
Figura 2.2. Base fisiológica para desarrollar índices de vegetación. Características típicas de reflectancia espectral para pasto verde saludable y suelo seco desnudo para el intervalo de longitud de onda de 250 ± 2500 nm (Jensen, 2016)..... 31
Figura 2.3. Número creciente de documentos de investigación publicados anualmente entre 2004 y 2022.Tema: ("Land cover" OR "LULC") AND ("Classification") AND "Random forest". 34
Figura 3.1. Metodología general para el desarrollo de la investigación..... 39
Figura 3.2. Ubicación de la zona de estudio. 40
Figura 4.1. Filtrado de las imágenes por fecha y área de interés. ... **Error! Bookmark not defined.**
Figura 4.2. Arreglo ordenado dependiente del menor porcentaje de nubosidad. ..... **Error! Bookmark not defined.**
Figura 4.3. Obtención de las imágenes con menor cobertura de nubes y creación del mosaico..... 53
Figura 4.4. Calculo de desviación estándar del NDVI como textura..... **Error! Bookmark not defined.**
Figura 4.5. Calculo de la entropía del NDVI y NIR como textura y obtención del contraste a partir del GLCM. ..... **Error! Bookmark not defined.**
Figura 4.6. Adición del NDVI y bandas de textura a la imagen previa, redimensionamiento de la imagen resultante a 20m..... **Error! Bookmark not defined.**
Figura 4.7. Creación de los puntos de entrenamiento y validación. **Error! Bookmark not defined.**
Figura 4.8. División de los datos para entrenamiento y validación. . **Error! Bookmark not defined.**

Figura 4.9. Creación de la variable para entrenamiento con los valores de cobertura. ..... **Error! Bookmark not defined.**
Figura 4.10. Clasificación usando Arboles Aleatorios. ..... **Error! Bookmark not defined.**
Figura 4.11. Paleta de colores para la visualización de la clasificación de coberturas. ..... **Error! Bookmark not defined.**
Figura 4.12. Calculo de la matriz de confusión y precisión general de la clasificación. ..... **Error! Bookmark not defined.**
Figura 4.13. Exportación de la matriz de confusión. ..... **Error! Bookmark not defined.**
Figura 4.14. Uso del complemento SCP para la detección del cambio de la cobertura de la tierra. 63
Figura 4.15. Puntaje de nubosidad para las imágenes encontradas en el primer trimestre de los años 2022 (a, c) y 2018 (b, d). 64
Figura 4.16. Clasificación de coberturas de la tierra 2022. 65
Figura 4.17. Clasificación de coberturas de la tierra 2018. 66
Figura 4.18. Firma espectral de las coberturas para los años 2022 (a) y 2018 (b). 69
Figura 4.19. NDVI y texturas calculadas de las coberturas para el año 2022 (a) y 2018 (b). 70
Figura 4.20. Matriz de cambio de cobertura de la tierra para la clasificación del año 2022. 71

Lista de tablas

Pág.

Tabla 3.1. Bandas espectrales y resolución del sensor Sentinel-2 MSI. 35
Tabla 3.2. Descripción general de texturas calculadas. 41
Tabla 3.3. Texturas calculadas. 42
Tabla 3.4. Resumen de hiperparámetros y variables de entrada del clasificador. 44
Tabla 4.1. Imágenes Sentinel-2 seleccionadas. 64
Tabla 4.2. Matriz de confusión para la clasificación 2022. 67

1. Introducción

Históricamente, el hombre ha necesitado explicar los fenómenos espaciales y temporales asociados al manejo de los recursos naturales (su extensión, clasificación, dinámica y cambio a través del tiempo, entre otras), para lograrlo invierte tiempo y recursos. Inicialmente, en procedimientos análogos de captura de datos, procesamiento, análisis, interpretación, almacenamiento y difusión de la información que son costosos, largos y dispendiosos (Selvaraj & Nagarajan, 2022). Con el surgimiento de las geociencias y el desarrollo vertiginoso de la computación y de las tecnologías de informática y comunicación se logró que las tareas de recolección, gestión, análisis y tratamiento de la información espacial sean más eficientes y económicas en la actualidad. La inversión en investigación en Sistemas de Información Geográfica (SIG) y Percepción Remota (PR) aceleraron los procesos de reconocimiento, caracterización, delimitación, en generar conocimiento del inventario de los recursos naturales, pero también han aportado a la comprensión de los fenómenos que alteran las condiciones inherentes por disturbios naturales o antrópicos que generan cambios en ellos (Selvam, Manisha, Vidhya & Venktraman, 2019).

El estudio de las coberturas de la tierra mediante procesos de clasificación de imágenes satelitales ha sido reconocido como una de las aplicaciones más frecuentes y prácticas de la PR. Al introducir ventajas comparativas con las técnicas tradicionales, en el aumento en la cobertura espacial, alta repetitividad, disponibilidad de imágenes con resolución en una amplia gama de ventanas del espectro electromagnético y un alto potencial de automatización (Mahdavi *et al*., 2019). Autores como Brodley & Friedl (1997), Zhu, Woodcock, & Olofsson (2012) enfatizan en la importancia del mapeo de las coberturas terrestres y de sus cambios a través del tiempo, las cuales son imprescindibles en el monitoreo de diversos tópicos del medio ambiente, son fuente principal de datos y de información para la planificación y ordenamiento territorial y en la zonificación agrícola sostenible para la seguridad alimentaria y nutricional de la población.

La automatización es definida como la tecnología mediante la cual se realiza un proceso, procedimiento, tarea o actividad con una mínima o nula asistencia humana, esta interacción puede implicar una pequeña acción o simplemente su supervisión (Groover, 2010). Sin embargo, muchos procesos no son automatizados, porque la automatización completa no es justificable dada la complejidad de la tarea a realizar o porque se puede requerir flexibilidad para adaptarse a pequeñas variaciones y es en estos casos que se implementa la semiautomatización, que se realiza mediante actividades combinadas del ser humano y la máquina alternando sus pasos mediante una interfaz que permite la retroalimentación del humano y su posterior respuesta por parte de la máquina (Moreno, 1999).

La PR ha desarrollado diversos procesos que buscan disminuir la subjetividad en las interpretaciones, el tiempo y el costo de operación. Tales procesos pueden ser completamente manuales, semiautomáticos o completamente automáticos. En la clasificación de coberturas, antes de los procesos asistidos por computadora, la información de cobertura implementada en los distintos métodos era extraída de mapas preexistentes generados mediante fotointerpretación y digitalización manual (Aber & Aber, 2017). No obstante, este tipo de información tiene varias limitaciones, ya que la naturaleza del suelo y la intervención humana hace que la cobertura de la tierra sea continua espacialmente y dinámica en el tiempo y espacio. Esta dinámica hace que procesos para la clasificación de coberturas que no sean eficientes en términos de tiempo, como los anteriormente mencionados, no sean la mejor opción, ya que los tiempos para generar los productos son amplios y desactualizados y por lo tanto dichos datos no se pueden tomar con cien por ciento de certeza en lugares donde las coberturas están cambiando con frecuencia (Kumar, 2006).

A pesar de sus ventajas, los procesos de automatización de la PR logrados con los SIG no estaban al alcance de todos los usuarios, por los costos de adquisición de programas licenciados. Con el paso del tiempo, se ha observado un aumento en el uso de *software* de libre acceso y la interacción de QGIS con R y Python o Google Earth Engine (GEE) con JavaScript y Python, aunado a la reciente disponibilidad de nuevas plataformas, misiones espaciales y sensores remotos acoplados a estas, lo que ha permitido la captura de datos

geoespaciales (Landsat, Sentinel y Meteosat, satélites SAOCOM, VRSS-1 o plataformas UAV (por sus siglas en inglés Unmanned Aerial Vehicle) y ha aumentado la oferta de datos abiertos con mejor resolución espacial, temporal y radiométrica (Gorelick *et al.,* 2017). Estos avances aportan y hacen posible el monitoreo de los recursos y particularmente, del cambio en la cobertura de la tierra a un menor costo con datos de calidad que aportan confianza a los resultados. Por ejemplo, las imágenes resultantes de la misión Sentinel-2, debido a su resolución espacial, temporal y espectral, se han posicionado como una herramienta de gran importancia en los estudios ambientales. Dada la capacidad de realizar un seguimiento y monitoreo de los cambios dinámicos en la cobertura, ya sea, por sucesos naturales o antrópicos (Segarra, Buchaillot, Araus & Kefauver, 2020).

La captura de información adquirida con sensores remotos multiespectrales es la principal fuente para mapear la cobertura del suelo a nivel global. Sin embargo, sigue siendo un reto la clasificación asistida por computadora, puesto que, con frecuencia se puede llegar a inconsistencias en los resultados. Esta inconsistencia se asocia con los datos de entrenamiento que al no ser los adecuados, puede llevar a una superposición parcial entre las clases al momento de hacer la clasificación, lo que significa que hay pixeles que hacen parte de dos o más clases diferentes de coberturas, generando dificultades al momento de realizar la clasificación (Wang, Wander, Mueller, Martin, Dunn, 2022). La ambigüedad espectral de algunas coberturas que poseen alta variabilidad intraclases y baja variabilidad entre clases, dificulta la definición de sus límites, por lo que imágenes con mayor resolución espectral aportan una mayor información que permite una mejor discriminación entre clases (Dronova, 2015; Henderson & Lewis, 2008).

La primera aproximación que se hizo en este tema fue la clasificación a escala global de la cobertura terrestre realizada por Defries & Townshend en 1994, utilizando el algoritmo de clasificación de máxima verosimilitud con base en los valores mensuales del índice de vegetación de diferencia normalizada (NDVI) con resolución espacial de 1x1 grado. La clasificación más conocida y usada, "*Land Cover Type/Dynamics*" de MODIS (Por sus siglas en inglés, Moderate Resolution Imaging Spectroradiometer) tiene una resolución temporal de un año, dos opciones de resolución espacial una de 500 m y otra 0.05 grados (≈ 5.6 km) para el tipo de cobertura y para su producto de dinámica de coberturas posee una RE de 1 km. Sin embargo, debido a la existencia de varios métodos para la clasificación de la cobertura y uso de la tierra, es decisión del analista escoger el más

apropiado para la zona de estudio y los requerimientos de los usuarios finales (Bovolo, Bruzzone, & Solano-Correa, 2017).

Debido al creciente volumen y complejidad de los datos capturados y a la necesidad de procesarlos y analizarlos, los algoritmos de Aprendizaje Automático (ML por sus siglas en ingles Machine Learning) han cobrado importancia , los cuales, son alimentados con datos de calidad que permiten identificar el comportamiento o tendencia de estos y generar modelos de manera que la computadora aprenda y este en la capacidad de realizar el mismo proceso en el futuro sin ser programado explícitamente o con datos similares o adicionales, proporcionando resultados rápidos y precisos sin mayor intervención humana. De esta manera generar predicciones de alto valor para la toma de decisiones acertadas y en menor tiempo (Gamanya, De Maeyer, & De Dapper, 2007; Garcia-Gutierrez, Gonalves-Seco, & Riquelme-Santos, 2011; Grekousis, 2019; Neapolitan & Jiang, 2018; Rebala, Ravi, & Churiwala, 2019).

La inteligencia artificial aplicada al mapeo de la cobertura y uso del suelo, puede verse aplicada en un sin número de métodos como los árboles de decisión que son una clase de modelos de predicción que requieren una etapa supervisada y tienen una variable objetivo, la cual es predefinida por el usuario, este tipo de algoritmos se utilizan con frecuencia en estudios de clasificación de cambio de uso de suelo por su capacidad de identificar la variable más significativa y encontrar su valor o el mejor grupo de datos homogéneos (Arvor, Durieux, Andrés, & Laporte, 2013; Champion, Boldo, Pierrot-Deseilligny, & Stamon, 2010; Gamanya *et al*., 2007; Knox, 2018; Müller & Guido, 2016). Un conjunto de estos árboles de decisión conforma lo que se conoce como algoritmo de bosques aleatorios (Random Forest) que puede definirse como un método de aprendizaje automático, versátil e inteligente el cual permite realizar tanto clasificaciones como tareas de regresión. Así mismo, este método cuenta con algoritmos de reducción dimensional, valores atípicos, tratar valores perdidos y otros pasos de exploración de datos. Es considerada como una solución experta ante varios de los problemas que se pueden presentar en tareas de clasificación (Sullivan, 2017).

En la clasificación de coberturas, si el entrenamiento es “*supervisado*”, en cada paso iterativo de prueba y perfeccionamiento del modelo se compara con datos de validación la

cobertura asignada por el entrenador con el valor asignado por el programa, determinando si ha identificado correctamente o no. El entrenamiento supervisado es relativamente rápido y necesita recursos computacionales considerables. Sin embargo, necesita de la intervención humana y grandes cantidades de información para el entrenamiento y una clasificación precisa (Cheng & Han, 2016; Grekousis, 2019; Knox, 2018; Mahdavi *et al*., 2019; Müller & Guido, 2016; Noi & Kappas, 2018; Rebala *et al*., 2019; Sullivan, 2017). Los mapas de coberturas que surgen de la clasificación supervisada son el principal insumo para muchos métodos que permiten monitorear el cambio entre dos fechas distintas (Zhou, 2021). La detección manual de cambios puede ser larga y costosa, por lo que se requiere introducir un cierto grado de automatización en el paso de detección de cambios. Es decir, desarrollar sistemas expertos que puedan centrar la atención del operador en posibles áreas de cambio. Este monitoreo puede ser bitemporal si se trata de solo dos fechas en el tiempo o multitemporal si se tienen en cuenta más de dos fechas (Eastman, 2001).

Existen dos tipos de datos sobre los cuales se puede efectuar el monitoreo del cambio, los datos categóricos que se utilizan cuando la información empleada es temática como por ejemplo mapas de clases de cobertura y por otro lado, los datos continuos que se obtienen a partir de la respuesta espectral (reflectancia) capturada por el sensor acoplado a los satélites y que generan las imágenes satelitales (Jiménez, González, Escalona, Valdez, & Aguirre, 2011). Los métodos que se usan frecuentemente para el monitoreo del cambio de cobertura de la tierra pueden agruparse bajo tres criterios principales. El primero, basado en la técnica empleada para detectar el cambio, el cual puede relacionarse con el cambio de la textura o reflectividad de las imágenes (Lu, Mausel, Brondízio, & Moran, 2004), e incluye los métodos de álgebra de mapas, transformaciones matemáticas, post-clasificación; y modelación (evaluación multicriterio y autómatas celulares). El segundo, fundamentado en la temporalidad de los datos (Eastman, 2001) comprende análisis bitemporal, análisis multitemporal y predicción de cambios a futuro y el tercero se basa en el tipo de datos empleados (Chuvieco, 2010). Estos datos pueden ser continuos o categóricos; para los primeros se encuentran los métodos de álgebra de mapas, transformaciones matemáticas y modelación; por otro lado, los datos categóricos se basan en una post-clasificación con matrices de cambio o a través de cadenas de Markov (Jiménez *et al*., 2011).

1.1 Formulación del problema

El cambio de la cobertura de la tierra es un proceso dinámico en el tiempo y espacio. Dada esta dinámica espacio temporal, es necesario desarrollar una metodología de análisis que permita a usuarios no expertos una mayor facilidad de la cuantificación de los cambios que ocurren en el territorio, en menor tiempo y con el uso de plataformas, softwares y datos de libre acceso que disminuyan los costos.

Para esta metodología las dos principales limitaciones en la clasificación de coberturas de la tierra, están asociadas a la Resolución Espacial (RE), Temporal (RT), Espectral (RS) y la accesibilidad de las imágenes utilizadas. La mayoría de los estudios reportados por la literatura utilizan imágenes de la misión Landsat 8 las cuales son de libre acceso, pero que tienen una RE de 30 m, RT de 16 días, RS de 9 bandas con el sensor OLI. En otras ocasiones, la limitación se ve asociada al costo de las imágenes de alta o muy alta resolución espacial como PlanetScope y/o de los softwares que se utilizan en el procesamiento de las imágenes como ERDAS, ILWIS, ENVI, ArcGIS, entre otros. Adicionalmente, dependiendo de ubicación geográfica y condiciones climatológicas, es posible identificar otras limitaciones. Por ejemplo, en el trópico, la mayoría del año se presenta una alta nubosidad, llevando a errores en la clasificación que de excluirse, genera vacíos de información. Por tanto, una menor RT disminuye la probabilidad de obtener una imagen con poca o nula cobertura de nubes.

En la actualidad es de suma importancia contar con una herramienta que permita el monitoreo y verificación del cambio de la tierra a escalas semidetalladas para la toma de decisiones en procesos de análisis, gestión y planificación del territorio (Jiménez *et al*., 2011; Kumar, 2006. Para dar solución a la problemática de mejorar la resolución de los mapas de cobertura de la tierra y disminuir la problemática de la nubosidad se propuso utilizar imágenes ópticas de la misión espacial Sentinel-2, que además de ser de libre acceso, tienen buena resolución espacial, espectral y temporal. Las dos primeras mejoran la discriminación e identificación de las coberturas de la tierra, y la última da mayor probabilidad de obtener una imagen o un conjunto de estas en la cual el porcentaje de nubosidad en la escena sea mínimo. Utilizar estas imágenes junto a las capacidades de la plataforma GEE de ser una plataforma de libre acceso, tener a su disposición repositorios

online y procesamiento en la nube, dan solución a las problemáticas causadas por nubosidad en el trópico y al costo de acceso a imágenes, software y hardware para su procesamiento; permitiendo mejorar la calidad de clasificación y monitoreo del cambio de la cobertura de la tierra en un menor tiempo.

1.2 Aproximación conceptual

Se realizó una revisión de las metodologías más utilizadas para monitoreo de la cobertura de la tierra con sensores remotos y se escogió el método de clasificación de Bosques Aleatorios (RF, por sus siglas en inglés, Random Forest), así como el método de cuantificación del cambio de álgebra de mapas (análisis de tabulación cruzada píxel por píxel). La validación de los métodos para el monitoreo del cambio de la cobertura y uso de la tierra se realizó en conjunto con AGROSAVIA La Libertad mediante una validación con base en información de las coberturas más representativas de la zona. Esta información fue recolectada en campo y se comparó con información suministrada por AGROSAVIA, que permitió cuantificar el error y valorar la aplicación operativa de la información capturada con sensores remotos para el monitoreo de cambio de la cobertura de la tierra.

La programación para la semiautomatización del método para el monitoreo del cambio de la cobertura de la tierra se realizó de manera interactiva usando la plataforma Google Earth Engine mediante el lenguaje de programación JavaScript y el software QGIS y su complemento SCP. Con el fin de aplicar la metodología ajustada para imágenes satelitales de la misión espacial Sentinel-2 y monitorear el cambio de la cobertura de la tierra en los municipios de Puerto López y Puerto Gaitán dentro del área correspondiente a la subzona hidrográfica del Rio Yucao en el departamento del Meta, a escala semidetallada, de la cual parte de esta, hace parte de la posición fisiográfica "*Altillanura plana*" de los municipios mencionados. Esta posición fisiográfica fue delimitada por Rodríguez *et al*. (2013) y corresponde a las unidades de suelo del paisaje de Altillanura plana en los municipios objeto de estudio con pendientes menores al 7%, la cual es de gran importancia para el sector agropecuario por su potencial productivo, considerada como la última gran frontera agrícola de Colombia.

1.3 Pregunta de investigación

Teniendo en cuenta las problemáticas anteriormente mencionadas surge la pregunta: ¿Cómo puede la semiautomatización del monitoreo del cambio en la cobertura de la tierra con el uso de software de libre acceso y las imágenes satelitales Sentinel 2 mejorar la planificación y gestión del territorio en áreas protegidas de Colombia?

1.4 Objetivos

1.4.1 Objetivo general

Implementar un proceso semiautomático para monitorear el cambio en la cobertura de la tierra con software y datos de libre acceso.

1.4.2 Objetivos específicos

- Generar un método semiautomático para detectar los cambios en la cobertura de la tierra.
- Detectar el cambio en la cobertura de la tierra en la cuenca del Rio Yucao, departamento del Meta, Colombia.

1.5 Importancia de la investigación

La investigación del monitoreo del cambio en la cobertura de la tierra es fundamental para entender cómo las actividades humanas afectan al medio ambiente y, por lo tanto, para

tomar decisiones informadas sobre la planificación y gestión del territorio. En este sentido, el uso de software de libre acceso y las imágenes satelitales Sentinel 2 son herramientas clave para llevar a cabo esta tarea de manera eficiente y accesible.

Gracias a la tecnología de imágenes satelitales Sentinel 2, es posible obtener una gran cantidad de datos y detalles sobre la cobertura de la tierra. Esto permite detectar y analizar los cambios que se producen en la cobertura de la tierra, como la deforestación, la urbanización o la expansión de cultivos, entre otros. Estos cambios pueden tener graves consecuencias en el medio ambiente, como la degradación del suelo, la pérdida de biodiversidad o la emisión de gases de efecto invernadero.

La disponibilidad de software de libre acceso para el procesamiento de estas imágenes y la generación de mapas temáticos permite que cualquier persona con conocimientos básicos en el manejo de herramientas informáticas pueda realizar análisis y estudios sobre las dinámicas de las coberturas de la tierra. Esto fomenta la democratización del acceso a la información y la transparencia en la toma de decisiones relacionadas con el medio ambiente.

Además, el monitoreo del cambio en la cobertura de la tierra permite no solo entender los patrones de la cobertura del suelo, sino también identificar áreas que requieren una gestión especial. Por ejemplo, áreas de conservación de la biodiversidad o áreas vulnerables a los efectos del cambio climático o procesos antrópicos pueden ser monitoreadas de manera efectiva con la tecnología Sentinel 2 y el software de libre acceso GEE.

En conclusión, la investigación del monitoreo del cambio en la cobertura de la tierra con software de libre acceso como GEE e imágenes Sentinel-2 es esencial para la planificación y gestión del territorio, la conservación de la biodiversidad y la mitigación de los efectos del cambio climático. La disponibilidad de estas herramientas contribuye a la democratización del acceso a la información y a una toma de decisiones más transparente y basada en datos. Razón por la cual La presente investigación contempló el método espacial para el monitoreo de la cobertura de la tierra compuesto por la clasificación de la cobertura en GEE y la detección del cambio en QGIS. Lo cual permitió distinguir con claridad las potencialidades que cada uno de estos métodos presentan para dar solución a problemas concretos en el proceso, como es el nivel de fiabilidad de la clasificación y sensibilidad ante

el cambio de la cobertura de la tierra (Jiménez *et al*., 2011). Además, permitió evidenciar para la zona de estudio, el aporte de las imágenes Sentinel-2 al monitoreo del cambio de la cobertura de la tierra y de esta manera definir un marco metodológico para este proceso que integró imágenes satelitales, plataformas y software de libre acceso. Permitiendo realizar un monitoreo continuo de los cambios de cobertura de la tierra anuales, bianuales o multitemporales a escalas de mayor detalle con una menor inversión en tiempo y costos para facilitar a los tomadores de decisiones en este caso el Centro de Investigación La Libertad de AGROSAVIA en sus labores que involucran este tipo de información (Kumar, 2006; Santana & Salas, 2007).

2. Marco Teórico

2.1 Percepción remota en el monitoreo de coberturas de la tierra

Hoy, son cada vez más frecuentes los sistemas que colectan datos de forma remota, tales como los sensores acoplados a plataformas aéreas UAVs o constelaciones de satélites (Colomina & Molina, 2014; Belward & Skoien, 2014), lo cual ha generado un aumento en volumen de datos (*big data*) y hace urgente la necesidad de herramientas que automaticen parte de su procesamiento, análisis y generación de información útiles para el usuario final (Suresh, 2020), diversos métodos pueden convertir estos datos en información temática valiosa (Homer *et al*., 2012; Jensen & Jensen, 2013; Pearson, 2015), en nuestro caso, para el monitoreo de coberturas a escala local, regional o nacional.

La información obtenida de los datos capturados con PR es de suma importancia en un sin número de estudios, tales como el monitoreo forestal (Asner *et al*., 2006,Gong *et al*., 2013, Hansen *et al*., 2008,Hansen *et al*., 2013,Myneni *et al*., 2007, Potapov *et al*., 2015, Townshend *et al*., 2012), biodiversidad (Asner *et al*., 2009, Mendenhall *et al*., 2011, Nagendra y Gadgil, 1999, Skidmore *et al*., 2015), agricultura, monitoreo de humedales y cuerpos de agua (Alcantara *et al*., 2012, Anderson *et al*., 2012, Hong *et al*., 2012, Ogilvie *et al*., 2015), además de su gran utilidad y potencial para la detección de cambios en coberturas y usos de la tierra (Giustarini *et al*., 2013, Grekousis *et al*., 2015, Hussain *et al*., 2013, Lambin y Meyfroidt, 2011 , Rindfuss *et al*., 2004). Se evidencia entonces, el aporte de la PR en el monitoreo ambiental, por su capacidad de explorar áreas asociadas al tamaño de píxel de cada plataforma, periodicidad en la adquisición de datos, de una o muchas bandas espectrales, que se adaptan a las necesidades de monitoreo a diversas

escalas dependientes del objeto de estudio. En este caso surten las necesidades de detectar los cambios en la cobertura de la tierra.

2.1.1 Los sensores remotos en el mapeo de coberturas agrícolas

Los sensores remotos proporcionan datos de los cuales es posible extraer información temática relacionada a los patrones espectrales y espaciales de los datos capturados (Nalli & Kalluri, 2023), que corresponden a la respuesta espectral de los diferentes tipos de cobertura del suelo. El término reconocimiento de patrones se usa comúnmente para describir este proceso analítico (Jensen, 2016). Las imágenes ópticas, comúnmente empleadas en el mapeo de coberturas, provienen de sensores que captan la radiación reflejada por las coberturas presentes en el área objeto de estudio, esta información (reflectancia) que es capturada por los sensores acoplados a las plataformas como los satélites, dependerá del número y ancho de las bandas (Srivastava *et al.*, 2022). La mayoría de los sensores multiespectrales comparten bandas en regiones comunes del espectro que cubren, el visible (RGB por sus siglas en ingles Red, Green, Blue), el borde del rojo (*Red- Edge*), infrarrojo cercano (NIR por sus siglas en ingles *Near-infrared*) y el infrarrojo de onda corta (SWIR por sus siglas en ingles *Short-wave infrared*).

La radiación proveniente del sensor y que es registrada para la generación de la imagen es denomina valor de brillo original (BV, por sus siglas en inglés *Brightness value*) también conocida como valor de nivel digital (DN, por sus siglas en ingles *digital number*), la respuesta captada por el sensor está asociada a las características del objeto observado (textura, estructura y color de la cobertura) (Teodoro & Duarte, 2022). Cuando esta respuesta (reflectancia) es medida de manera continua y graficada en función de la longitud de onda se genera la firma espectral que es característica y única para cada cobertura. Si se analiza una cobertura con un sensor multiespectral se obtiene una única respuesta por cada banda que abarca una sección específica del espectro y al graficarla en función de la longitud de onda se obtiene el perfil espectral (Read, Chambers & Torrado, 2020).

La respuesta espectral está en función del tipo de objeto que constituye la cobertura. Así, la respuesta de la cobertura suelo desnudo, sería menos variable en áreas donde el color del suelo es pardo y por tanto su reflectancia es alta para la región RGB (DeFries, 2013). Sin embargo, la respuesta del suelo está ligada estrechamente a su contenido de humedad, a medida que esta disminuye la reflectancia aumenta en la región del infrarrojo de onda corta, de manera similar texturas arenosas (gruesas), aumentarán los valores de reflectancia, en tanto que suelos con textura arcillosa y alta materia orgánica superficial disminuirán estos valores. Además, se ha encontrado que la rugosidad superficial y los minerales constituyentes, también afectan la respuesta espectral de las coberturas con suelo desnudo (Duan, Song, Liu, Cui & Zhang, 2022).

Con PR las coberturas cuerpos de agua son reconocibles usando sensores ópticos con bandas en las regiones espectrales del infrarrojo cercano con longitudes de onda ≈ > 0.8 µm, en donde la absorbancia es muy alta. El factor que más influye en la respuesta de los cuerpos de agua es la turbidez, determinada por la cantidad y tipo de sedimentos presentes Li, Dang, Zhang & Du, 2022). Las coberturas con vegetación sana muestran una firma espectral característica, que tiene un patrón de baja reflectancia en la región del visible, en tanto valores de alta reflectancia en la región del NIR se ligan a la estructura de las hojas (Figura 2.1). La baja reflectancia en la franja del visible obedece a la fuerte absorbancia de esta región que se asocia al proceso de fotosíntesis por parte de la clorofila. No obstante, esta absorbancia no es uniforme, ya que los pigmentos del parénquima empalizada (Clorofilas a y b,el β-caroteno y carotenoides) en los cloroplastos y otros pigmentos como las antocianinas y flavonoides del citoplasma absorben mayor cantidad de luz azul, a longitudes de onda cercanas a 0.45 µm y roja 0.67 µm, por el contrario mayor cantidad de luz verde (0.51 µm) es reflejada (Figura 2.2) razón por la cual, las plantas son de color verde para el ojo humano (Jensen, 2016).

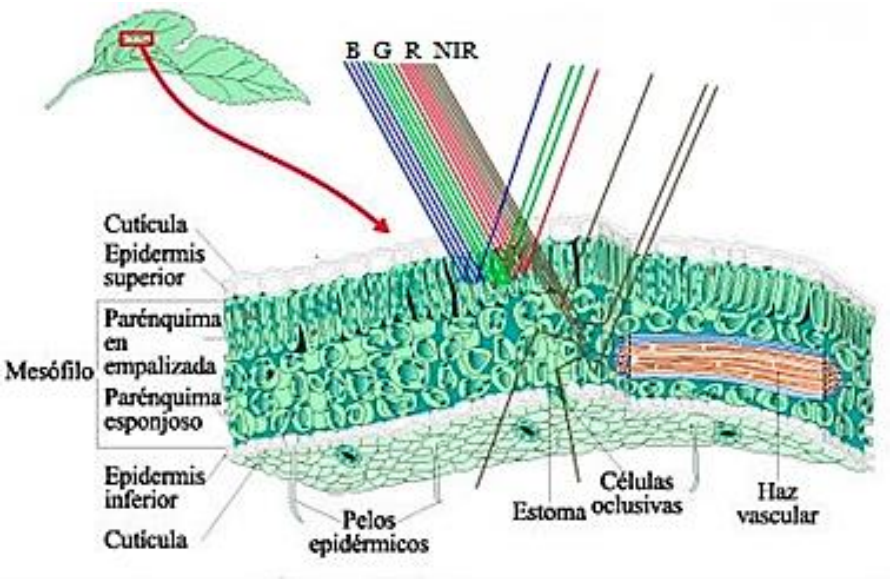

Figura 2.1. Estructura de la hoja celular y su interacción con la energía electromagnética de la región del RGB y NIR. Tomada de Curtis (2001).

La respuesta espectral que se encuentra en la transición de zona del rojo al infrarrojo cercano, presenta una pendiente positiva creciente, que se denomina borde del rojo (0.7 µm) también conocida como *red-edge*, en conjunto con la región del infrarrojo cercano está dada principalmente por la estructura interna del follaje (entre 0.7 y 1.3 µm), es esta región del espectro la que permite hacer una diferenciación entre especies, en tanto que en la zona del infrarrojo de onda corta, el factor que controla la respuesta es el contenido de agua en la hoja, su expresión en forma de valles en la curva espectral se da en las regiones de mayor absorbancia entre 1.4 , 1.9 y 2.6 µm (Jensen, 2016).

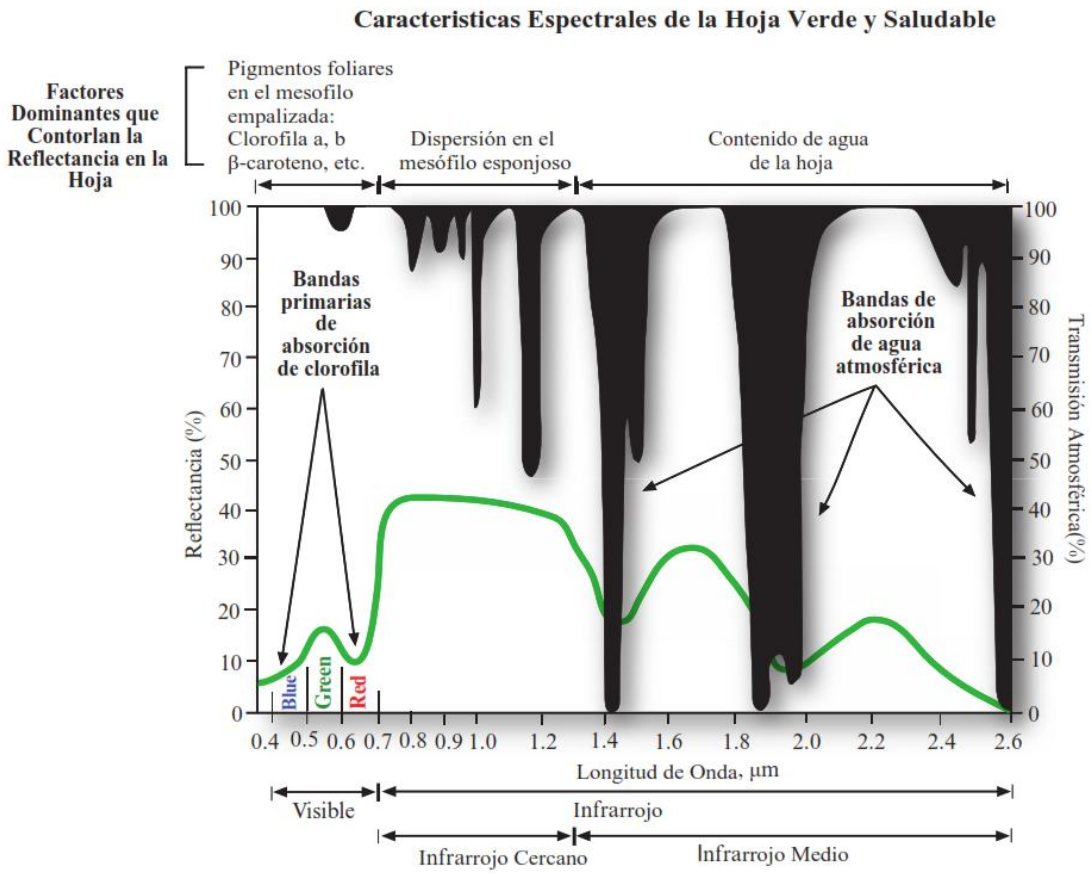

Figura 2.2. Características de la reflectancia espectral de la vegetación verde y saludable para el intervalo de longitud de onda de 0,4 ± 2,6 µm y sus principales factores que controlan la reflectancia de la hoja. Tomada y traducida de Jensen, 2016.

2.1.2 Métodos de mapeo de coberturas

En los últimos años los trabajos y aplicaciones con métodos que emplean imágenes satelitales para el mapeo de coberturas de la tierra han aumentado considerablemente, una de las principales razones de este crecimiento exponencial se atribuye a la reciente mejora en la cantidad, calidad, disponibilidad y accesibilidad de datos ofrecidos por diferentes fuentes útiles para este propósito (Yu *et al*., 2014), sin embargo, son muchos los factores que influencian y hacen complejo el proceso de monitoreo de la cobertura terrestre.

Lu & Weng (2007) y Weng (2012) centrados en los enfoques de clasificación de imágenes, el paso a paso empleado, las técnicas de mejoramiento de la precisión y rendimiento de la clasificación encontraron que es esencial para alcanzar una buena clasificación, la disponibilidad de imágenes y el acceso a datos auxiliares como índices de vegetación y texturas de alta calidad derivados de sensores remotos y el diseño de un procedimiento de clasificación adecuado. Sin embargo, reconocen que la habilidad y experiencia del analista son un factor clave.

Por su parte, Cihlar (2000) y Franklin & Wulder (2002) ahondaron en las estrategias de mapeo utilizadas para la clasificación de la cubierta terrestre de áreas extensas, entre los principales problemas que identificaron resaltan, el uso de imágenes de múltiples sensores con tiempo/ángulos variables y la alta demanda de recursos para el procesamiento de correcciones geométricas y radiométricas de grandes cantidades de imágenes.

Smits, Dellepiane & Schowengerdt (1999) introdujeron un protocolo de evaluación de calidad para el mapeo de la cobertura del suelo en el contexto de los requisitos del proyecto y el costo económico del error, encontrando que los basados en matrices de confusión y el análisis KHAT son los más adecuados si el interés se orienta a comparar clasificadores.

Yu *et al*. (2014) en cambio, usó diagramas de dispersión para investigar la relación entre la precisión de la clasificación y la fecha de publicación, el tamaño del área de estudio y la complejidad del sistema de clasificación e informar la precisión general promedio estimada y su error estándar para diferentes sensores y algoritmos de clasificación, el autor concluye que imágenes con más bandas espectrales o una combinación de tipos de datos dieron lugar a una mayor precisión de mapeo, a su vez resalta que las diferencias de precisión a causa del tipo de algoritmo de clasificación no son tan grandes como las asociadas a los distintos datos utilizados y adicionalmente, menciona que la complejidad de un sistema de clasificación disminuye su precisión de mapeo, por lo que se debe tener en cuenta que no siempre el método o algoritmo más complejo será sinónimo de precisión en el resultado.

Kathami (2016) encontró que con la inclusión de información de textura se logró mejorar la precisión general de la clasificación de la cobertura del suelo en un 12.1%. Coburn & Roberts (2004) afirmaron que la técnica utilizada, con mayor frecuencia, para derivar

medidas de textura es el uso de la matriz de co-ocurrencia de niveles de gris (GLCM por sus siglas en inglés grey-level co-occurrence matrix). Esta técnica emplea una matriz de co-ocurrencia espacial que calcula las relaciones de los valores de los píxeles y los utiliza para calcular las propiedades estadísticas de segundo orden de estas matrices. Varias de las medidas de textura de GLCM más utilizadas son el segundo momento angular, contraste, correlación, disimilitud, entropía y homogeneidad (Jensen, 2016). En la tabla 3.2, se presenta las fórmulas para el cálculo de las texturas que fueron empleadas en este estudio.

Kathami (2016) también afirmó, que el uso de información derivada de la respuesta espectral, índices espectrales (NDVI, NDWI, NDBI, entre otros) aportaron mejoras a la precisión de las clasificaciones. En cuanto al uso de algoritmos de clasificación, el uso del clasificador bosques aleatorios (RF, por sus siglas en inglés) tuvo un rendimiento considerablemente mejor que el clasificador tradicional de árbol de decisión, Este buen desempeño del algoritmo RF concuerda con lo reportado en varios estudios de clasificación de coberturas (Belgiu & Csillik, 2017; Chen *et al*., 2017; Dash *et al*., 2018; Zhao *et al*., 2019, Ramírez, 2020). Random Forest es un método de aprendizaje automático que se puede utilizar para clasificaciones supervisadas. Se basa en la construcción automática de múltiples árboles de decisión, donde cada árbol toma un subconjunto aleatorio de variables de entrada y objetos de entrenamiento para las clasificaciones. Para una decisión final sobre la clasificación de un objeto, cada árbol obtiene un "voto" en el resultado final. Random Forests ha demostrado su uso para clasificaciones con grandes cantidades de datos de imágenes satelitales (Wurm *et al*., 2017). Los bosques aleatorios superan los métodos de clasificación estándar para la cobertura del suelo, porque pueden manejar la gran diferenciación dentro de las clases de cobertura del suelo y los datos de ruido pueden neutralizarse (Rodríguez-Galiano*et al*., 2012).

Figura 2.3. Número creciente de documentos de investigación publicados anualmente entre 2004 y 2022.Tema: ("Land cover" OR "LULC") AND ("Classification") AND "Random forest".

2.2 Semiautomatización y percepción remota

Dentro del monitoreo del cambio de las coberturas de la tierra, una gran parte del aprendizaje automático se da en la clasificación, ya que permite conocer a qué clase de cobertura pertenece cada píxel que es procesado. La capacidad de clasificar con precisión las observaciones es valiosa para apoyar la toma de decisiones de entidades de ordenamiento territorial y temas ambientales, que de manera directa reduce el tiempo de clasificación comparado con los métodos manuales que se utilizaban anteriormente. Existen diferentes algoritmos que se han desarrollado en este proceso de automatización en el procesamiento de imágenes, uno de los algoritmos que ha ganado más popularidad es el bosque aleatorio que es un algoritmo de clasificación que consta de muchos árboles de decisiones que utiliza el embolsado y la aleatoriedad de las características al construir cada árbol individual para tratar de crear un bosque de árboles no correlacionado cuya predicción en conjunto es más precisa que la de cualquier árbol individual.

2.3 Datos de libre acceso y procesamiento en la nube

El lanzamiento de los satélites Sentinel-2 (S2) del programa Copernicus (ESA, 2011), anteriormente conocido como GMES (Global Monitoring for Environment and Security), abrió nuevas oportunidades en el mundo de la teledetección (Frampton *et al*. 2013). La operación en conjunto de S2A y S2B ofrece un período de revisita de hasta 5 días, ofreciendo una mayor disponibilidad para el monitoreo de varios procesos, especialmente aquellos que ocurren en breves períodos de tiempo y que no son registrados frecuentemente por el satélites Landsat 8 el cual posee un tiempo de revisita de 16 días, como la inundación de los campos de arroz en los humedales mediterráneos antes del crecimiento de los cultivos (Tourenq *et al*., 2001), el derretimiento de la nieve en zonas montañosas y/o incendios forestales. Además, esta mejor capacidad de monitoreo también aumenta la probabilidad de obtener imágenes sin nubes en el mismo período ya sea mensual, semestral o anual. Este aumento de la resolución espectral y temporal, junto con la mejora de la resolución espacial de hasta 10 m y 20 m para las principales bandas espectrales, brinda la oportunidad de avanzar significativamente en la capacidad de monitorear el cambio de las coberturas de la tierra de manera rutinaria y global sin costo, en especial en el área de las coberturas vegetales ya que con las bandas que posee este sensor en el borde del rojo se mejora la discriminación entre estas coberturas (Espinosa, 2019; Houborg *et al*., 2015).

Las imágenes satelitales empleadas fueron extraídas de la misión Sentinel-2 de la Agencia Espacial Europea, las cuales hacen parte del programa Copérnico que realiza monitoreo ambiental de las coberturas de la tierra utilizando dos satélites (Sentinel 2A y 2B) (Main-Knorn *et al*., 2017) que proveen imágenes con una resolución espacial de 10, 20 y 60 m resolución espectral de 13 bandas (Figura 3.3), y una resolución temporal de cinco días con los dos satélites (Astola *et al*., 2019). El primer satélite (Sentinel-2A) se lanzó en junio de 2015 y el segundo (Sentinel2B) en marzo de 2017 (Agencia Espacial Europea, 2018). Lo que significa que posterior al segundo lanzamiento hay una mayor densidad temporal. Los satélites Sentinel-2 están equipados con un sensor multiespectral, que captura 13 bandas espectrales en las regiones del espectro electromagnético más comunes de esta clase de sensores como lo son las regiones del visible, NIR y SWIR (Tabla 3.1.).

Tabla 2.1. Bandas espectrales y resolución del sensor Sentinel-2 MSI.

Numero de Banda	**Nombre de la Banda**	**Rango de longitud de onda**	**Ancho de Banda (nm)**	**Resolución Espacial (nm)**
B1	Costero y Aerosol	443	20	60
B2	Azul (B)	490	65	10
B3	Verde (G)	560	35	10
B4	Rojo (R)	665	30	10
B5	Borde del rojo 1	705	15	20
B6	Borde del rojo 2	740	15	20
B7	Borde del rojo 3	783	20	20
B8	Infrarrojo cercano	842	115	10
B8a	Infrarrojo cercano 2	865	20	20
B9	Vapor de agua	945	20	60
B10	Cirrus	1380	30	60
B11	Infrarrojo de onda corta 1	1910	90	20
B12	Infrarrojo de onda corta 2	2190	180	20

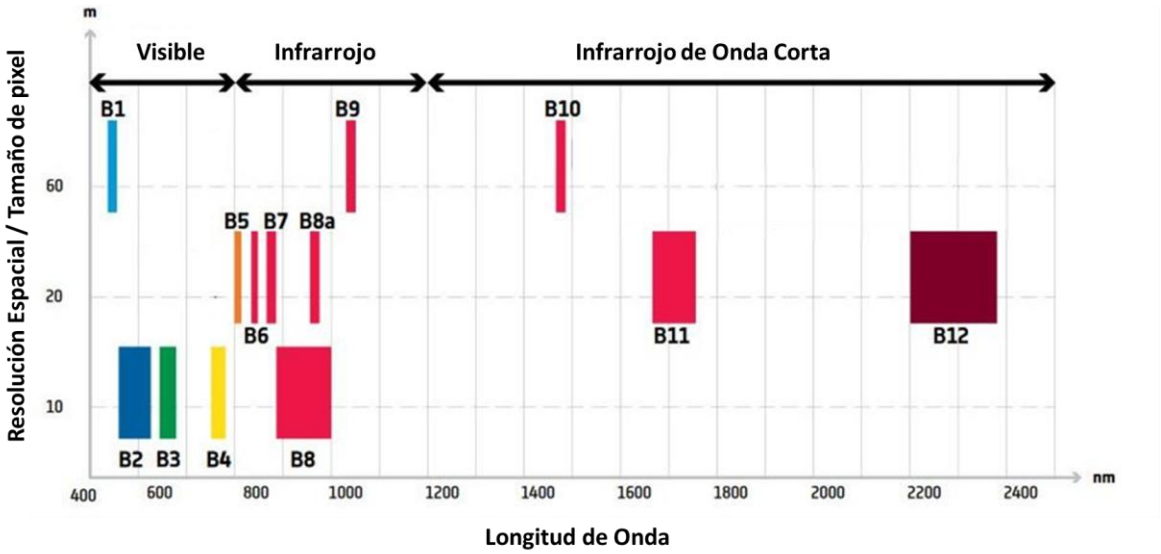

Figura 2.4. Resolución espacial frente a longitud de onda del sensor Sentinel-2 MSI. Tomada y traducida de (European Space Agency, 2015).

Los datos de Sentinel-2 se adquirieron y preprocesaron en GEE, donde las imágenes se proporcionan como un producto de Nivel 2A que representa la reflectancia de la parte superior de la atmósfera (TOA). Las imágenes se proporcionan con una resolución de 10 metros para las longitudes de onda más cortas y una resolución de 20 o 60 metros para longitudes de onda más largas.

El desarrollo de múltiples sensores se acompaña de nuevas formas de almacenamiento y procesamiento de grandes volúmenes de datos y por el uso de plataformas de gran capacidad como Google Earth Engine, que es una herramienta poderosa para el almacenamiento de grandes conjuntos de datos, pero también tiene grandes capacidades de procesamiento, esto hace posible ejecutar el algoritmo de clasificación en múltiples imágenes al mismo tiempo. Lo cual hace que al no ser necesario descargar las imágenes y el procesamiento sea rápido y en la nube haya un ahorro en tiempo y dinero. Google Earth Engine está equipado con diferentes clasificadores para diferentes algoritmos de clasificación, la mayoría de ellos en la categoría de aprendizaje automático, por ejemplo, máquina de vectores de soporte (SVM), árbol de clasificación y regresión (CART) y bosques aleatorios (RF). Hansen *et al.* (2008) evidencian las capacidades de GEE para procesar datos ópticos de Landsat 8 y que al igual que Tamiminia *et al*., (2020) encontraron

que el clasificador de bosques aleatorios genera buenos resultados de clasificación con imágenes espectrales de Landsat-8 en Google Earth Engine.

3. Metodología

En la Figura 3-1 se presenta un resumen del protocolo metodológico utilizado en este estudio.

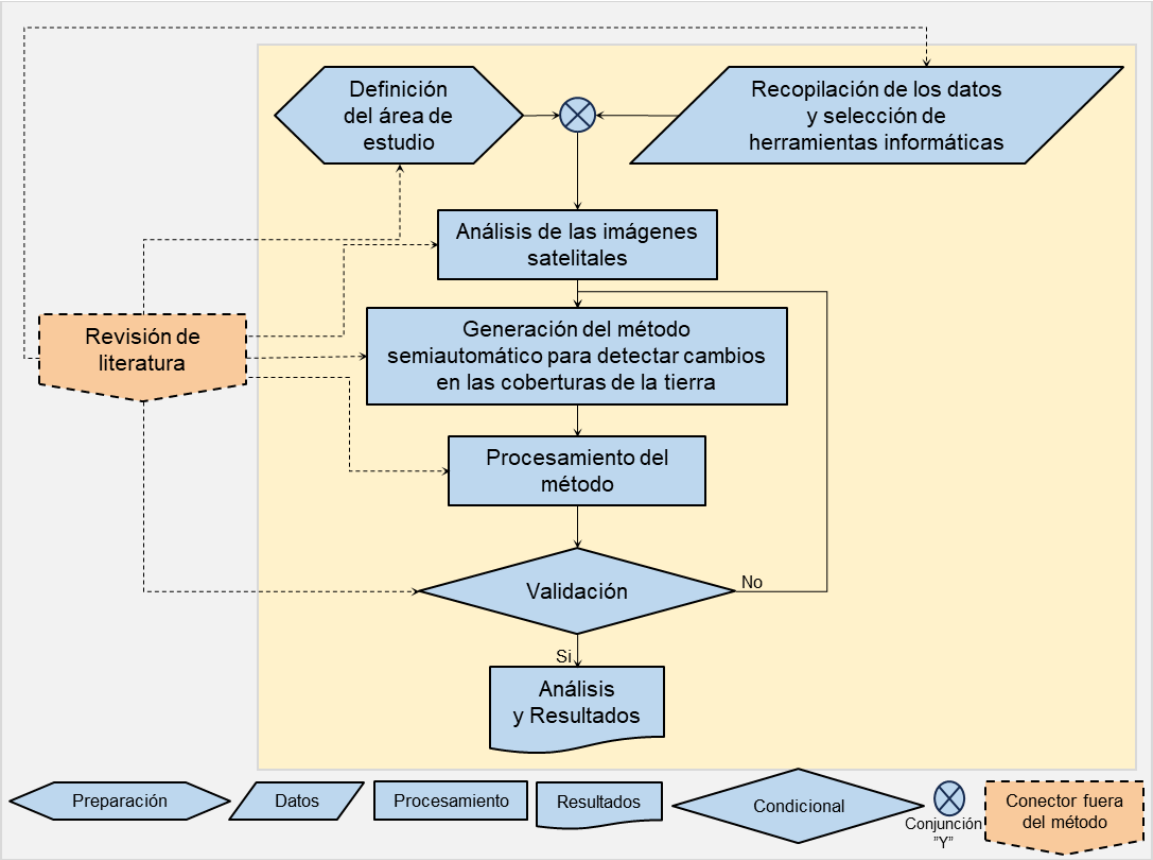

Figura 3.1. Metodología general para el desarrollo de la investigación.

3.1 Área de estudio

Con el fin de aplicar la metodología ajustada para imágenes satelitales de la misión espacial Sentinel-2 y monitorear el cambio de la cobertura de la tierra en los municipios de Puerto López y Puerto Gaitán en el departamento del Meta, a escala semidetallada, se utilizó el área correspondiente a la subzona hidrográfica Rio Yucao con 2441 km^2, la cual, se encuentra dentro de la zona hidrográfica Meta de la zonificación hidrográfica de Colombia área Orinoco del Instituto de Hidrología, Meteorología y estudios Ambientales (IDEAM, 2013) y que a su vez hace parte de la posición fisiográfica “Altillanura plana” de los municipios en mención, delimitada por Rodríguez *et al*. (2013) correspondiente a las unidades de suelo del paisaje de Altillanura plana en los municipios objeto de estudio con pendientes menores al 7%.

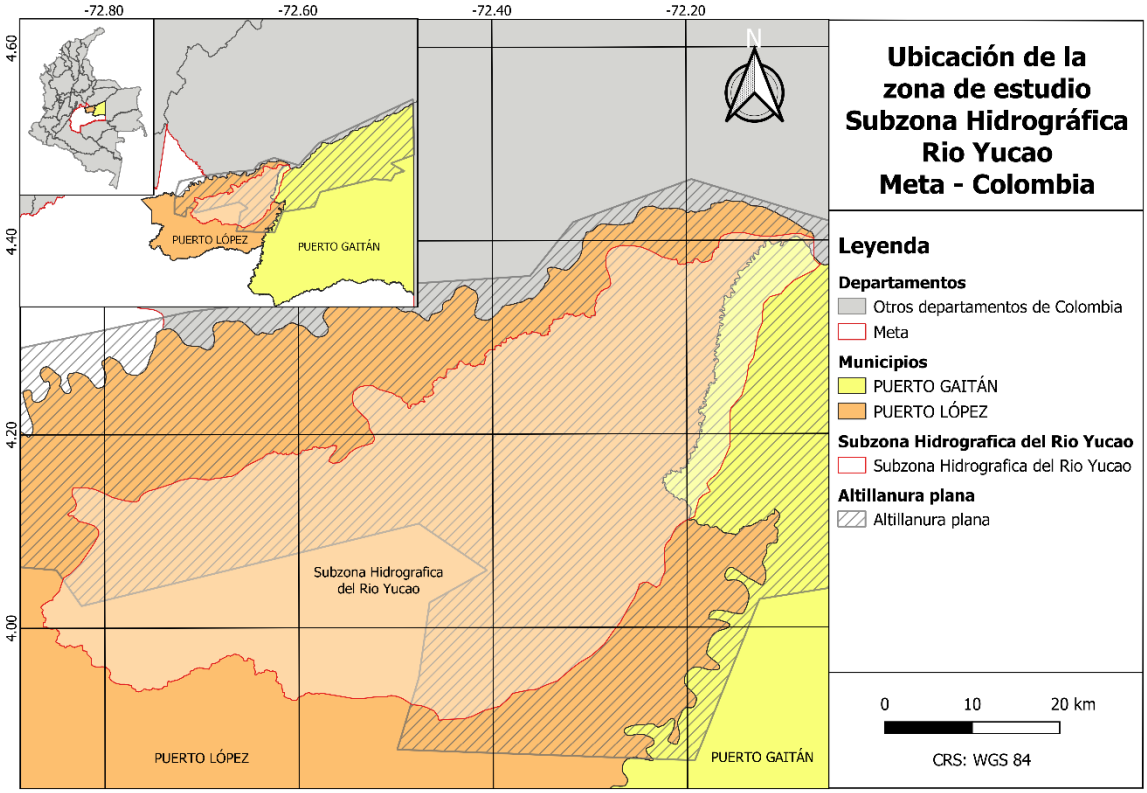

Figura 3.2. Ubicación de la zona de estudio Subzona Hidrográfica Rio Yucao Meta - Colombia.

3.2 Datos

3.2.1 Selección de imágenes y preprocesamiento

Para la selección de las imágenes a preprocesar, se hizo un filtrado de las imágenes por fecha y área de interés, posteriormente se realizó un filtrado por porcentaje de cobertura de nubes menor a 10% y se genera un listado de menor a mayor, donde se selecciona la primera imagen de la lista la cual es recortada por el área de estudio. Este proceso se ejecutó dos veces ya que el área abarcada cubría dos escenas diferentes de la misión Sentinel-2, las dos imágenes seleccionadas fueron unificadas en un mosaico final. Este proceso se realizó para dos fechas con una diferencia de 3 años entre estas (2019 y 2022), las cuales fueron seleccionadas en acuerdo con el financiador del proyecto AGROSAVIA la Libertad y teniendo en cuenta que fuera después del lanzamiento del segundo satélite de la misión S-2 en marzo de 2017, obteniendo dos mosaicos finalmente para la zona de estudio. Posterior mente se calculó el índice de Vegetación de Diferencia Normalizada y el índice de Vegetación Mejorado (NDVI y EVI, por sus siglas en inglés) para el mosaico creado.

Se calcularon 4 variables de descriptores de textura de naturaleza estadística para cada píxel, el primer descriptor es la desviación estándar del NDVI usando una ventana de 5x5 pixeles, el segundo y tercer descriptor es la entropía de la banda del NIR y del índice NDVI respectivamente, el cuarto descriptor se calculó con la Matriz de coocurrencia de niveles de gris GLCM por sus siglas en inglés (gray level co-occurrence matrix) de la banda del NIR y se extrajo el contraste. En la Tabla 3.2. se hace una descripción general de las texturas calculadas.

Tabla 3.1. Descripción general de texturas calculadas.

Medida estadística	Estadístico extraído	Índice o Banda espectral	Ecuación
1er orden	Desviación estándar	NDVI	$\sigma_{ij} = \sqrt{\sigma_{ij}{}^2}$
2do orden	Entropía	NIR	$H_{xy} = -\sum_{i=0}^{255}\sum_{j=0}^{255} p(i,j)\ log_2 p(i,j)$
2do orden	Entropía	NDVI	$H_{xy} = -\sum_{i=0}^{255}\sum_{j=0}^{255} p(i,j)\ log_2 p(i,j)$
2do orden	Contraste	NIR GLCM	$H_{xy} = -\sum_{i=0}^{255}\sum_{j=0}^{255} (i-j)^2\ p(i,j)$

Los índices de vegetación y los descriptores de textura calculados se añadieron a la imagen seleccionada como nuevas bandas, generando una nueva imagen con 19 bandas que se reproyectaron al sistema de referencia WGS 84 / UTM zone 17N (EPSG:32617) y se redimensionaron a una resolución de 20 m debido a la diferencia de resolución espacial entre las bandas de la misión (10m , 20m, 60m) y escogiendo 20m ya que la mayoría de las bandas con mayor importancia están en esta resolución (Nomura, 2018), esta imagen resultante fue empleada para la clasificación.

3.3 Esquema de clasificación

3.3.1 Definición de clases

Se definieron 14 clases para los diferentes tipos de cobertura de la tierra identificados en la zona, en la Tabla 3.3. se hace una descripción general de las coberturas identificadas.

Tabla 3.2. Coberturas de la tierra clasificadas.

ID de la clase	Tipo de cobertura	Descripción
1	Arbustos	Vegetación arbustiva
2	Palma	Cultivos de Palma de Aceite
3	Caucho	Cultivos de Caucho
4	Caña de azúcar	Cultivos de Caña de Azúcar
5	Cultivos Forestal	Cultivos Forestales industriales
6	Suelo desnudo	Zonas con suelo sin ningún tipo de cobertura y suelo visible
7	Pastos	Zonas con presencia de pastos cultivados o naturales
8	Zonas quemadas	Zonas que fueron quemadas
9	Bosque de galería	Áreas con presencia de Bosque de Galería

10	Zona urbana	Zonas con presencias de construcciones urbanas o industriales
11	Residuos de cosecha de caña	Zonas donde hay presencia de los restos de caña una vez es cosechada
12	Cuerpos de agua	Área constituida por un cuerpo de agua (Ríos, Quebradas, Lagos y lagunas)
13	Sombras	Sombras de las nubes
14	Nubes	Nubes

3.4 Datos de referencia

3.4.1 Fuente de datos, puntos de entrenamiento y validación

Los datos empleados para realizar el entrenamiento y validación del algoritmo fueron una combinación de puntos georreferenciados con una variable correspondiente a la cobertura, adquiridos mediante la captura de las coordenadas en campo por el investigador, otros adquiridos por el personal de AGROSAVIA que tiene conocimiento de la zona y a partir de esta base de puntos con el apoyo de los investigadores ampliamente conocedores de la zona se realizaron sesiones de identificación y verificación de la información con ayuda del software QGIS v3.16 donde fueron revisados y seleccionados aquellos puntos que coincidían con la cobertura actual mediante fotointerpretación de las imágenes Sentinel-2, PlanetScope y el mapa base del servicio web Bing Maps Aerial Imagery. Donde finalmente se seleccionaron 700 puntos en total que fueron exportados en formato shapefile (.shp) en archivos individuales para cada tipo de cobertura compuestos por 50 puntos cada uno y posteriormente fueron cargados en GEE**.** Para el entrenamiento del algoritmo se utilizó el 80% de los puntos de manera aleatoria y el 20% restante para la validación.

3.5 Clasificación de las coberturas

3.5.1 Algoritmo de clasificación

El método empleado para la clasificación de las coberturas de la tierra fue Arboles Aleatorios, los hiperparámetros ajustados en el clasificador fueron el número de árboles con un valor de 90 árboles, ya que a mayor número de árboles la tasa general de error disminuye se decidió no exceder este número por las limitaciones de procesamiento de la

plataforma GEE (Nomura, 2018, Breiman, 2001, Rodriguez-Galiano, 2012) y el número de variables de predicción por nodo que se ajustó en 4 ya que una medida para ajustar este parámetro es la raíz cuadrada del número de variables de entrada para la clasificación que en este caso corresponde a la raíz cuadrada de 19 (bandas, índices y texturas).

Tabla 3.3. Resumen de hiperparámetros y variables de entrada del clasificador.

Clasificador	Número de Arboles	Número de variables de predicción por nodo	Número de variables de entrada
Arboles Aleatorios	90	4	19

3.6 Validación de la clasificación

3.6.1 Matriz de confusión

En el campo de la inteligencia artificial una de las herramientas para visualizar el desempeño de un algoritmo de clasificación supervisada es la matriz de confusión la cual fue calculada para medir el desempeño del algoritmo de árboles aleatorios para la clasificación del año 2022 con los datos de validación. En esta matriz las filas representan las clases predichas por el clasificador escogido y las columnas las clases reales que son las etiquetas que se dan a las ubicaciones de muestra aleatorias que conforman los datos de referencia.

3.6.2 Exactitud general

La exactitud general (OA) por sus siglas en inglés Overall Accuracy, es una medida que se deriva de la matriz de confusión que indica el porcentaje de pixeles correctamente clasificados. Esta se calcula dividiendo la sumatoria de los puntos correctamente clasificados por el número total de puntos de validación.

La especificidad es una métrica de desempeño utilizada en la clasificación de imágenes que mide la capacidad del modelo para identificar correctamente los casos negativos. En otras palabras, indica la proporción de casos negativos que son correctamente clasificados como negativos. Un valor alto de especificidad indica que el modelo tiene una baja tasa de

falsos positivos, lo que es especialmente importante en escenarios donde la identificación correcta de los casos negativos es crítica.

3.6.3 Precisión

La precisión es una métrica que evalúa la exactitud de la clasificación realizada por el modelo. Mide la proporción de casos positivos correctamente identificados en relación con el total de casos clasificados como positivos. Una alta precisión indica que el modelo tiene una baja tasa de falsos positivos, es decir, que es capaz de identificar correctamente la mayoría de los casos positivos.

3.6.4 Sensibilidad

La sensibilidad, también conocida como tasa de verdaderos positivos o recall, es una métrica que evalúa la capacidad del modelo para identificar correctamente los casos positivos. Mide la proporción de casos positivos que son correctamente clasificados como positivos en relación con el total de casos positivos presentes en la muestra. Una alta sensibilidad indica que el modelo tiene una baja tasa de falsos negativos y es capaz de detectar la mayoría de los casos positivos.

3.6.5 F1-Score

El F1-Score es una métrica que combina la precisión y la sensibilidad en una única medida. Proporciona una evaluación más equilibrada del rendimiento del modelo al tener en cuenta tanto los falsos positivos como los falsos negativos. El F1-Score es especialmente útil cuando hay un desequilibrio en las clases de la muestra. Un valor alto de F1-Score indica que el modelo logra un equilibrio entre la precisión y la sensibilidad, lo que se considera una buena medida global del desempeño de la clasificación de imágenes.

3.7 Método de detección de cambio de cobertura

Para realizar la comparación de las clasificaciones entre las dos fechas, se empleó el software QGIS y el complemento Semi-Automatic Classification Plugin v.7.10.8 que posee la herramienta de postprocesamiento “*Land cover change*” que permite identificar los cambios entre dos capas raster y genera una nueva capa con los cambios entre clases,

además emite un reporte de las estadísticas de cambio en número de pixeles y área en m^2, en conjunto con una matriz de cambio de cobertura de la tierra en m^2.

4. Resultados

Los resultados se presentan en dos apartados que están alineados a los dos objetivos específicos, el primer apartado 4.1 correspondiente a la Metodología propuesta para la segmentación del cambio de la cobertura de la tierra explicando el script generado para que pueda ser replicado y modificado por diferentes usuarios. El segundo apartado 4.2 muestra los resultados de aplicar el método a la zona de estudio en la subzona hidrográfica Rio Yucao, Meta, Colombia.

4.1 Método para la semiautomatización del cambio de la cobertura de la tierra

La Figura 4.1 ilustra de forma esquemática el método propuesto para la clasificación de coberturas, la visualización y la cuantificación de los cambios utilizando datos y software de acceso libre. El diagrama resume los distintos procesos utilizados para determinar los cambios ocurridos en las coberturas de la tierra en un periodo de 3 años en la subzona hidrográfica Rio Yucao, Meta, Colombia, los cuales se describen en detalle a continuación.

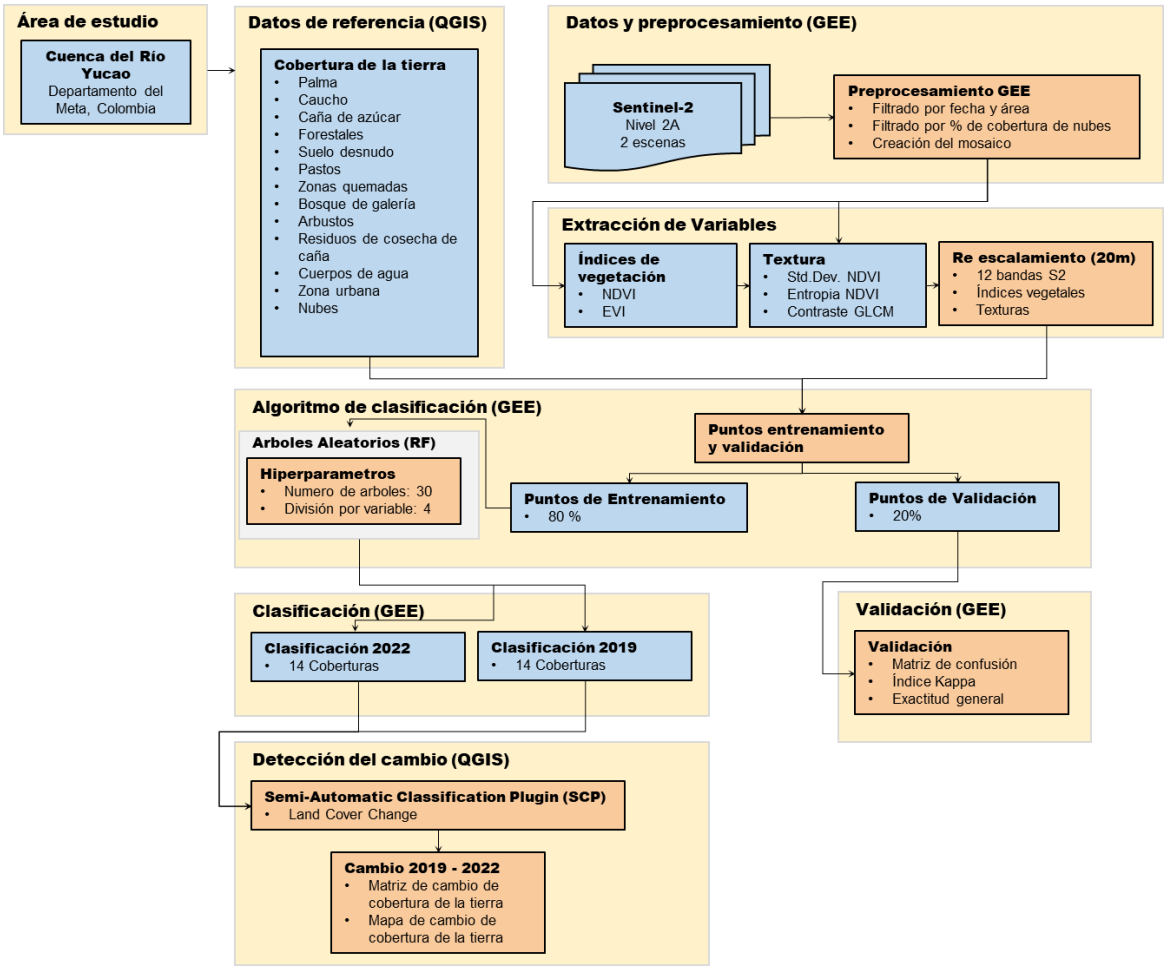

Figura 4.1. Método semiautomático para detectar los cambios en la cobertura de la tierra.

4.1.1 Área de estudio

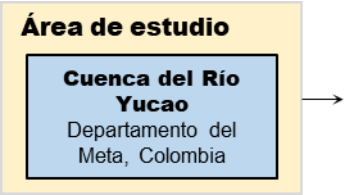

Figura 4.2. Metodología propuesta para la selección del área de estudio.

Primero, se define el área de estudio mediante la utilización de la función ee.FeatureCollection con un ID específico ("users/sarubianos/SZH_R_YUCAO"), la cual debe ser cargada previamente en la carpeta del proyecto en la pestaña de “Assets”.

```
var roi = ee.FeatureCollection("users/sarubianos/SZH_R_YUCAO");
```

4.1.2 Datos de referencia

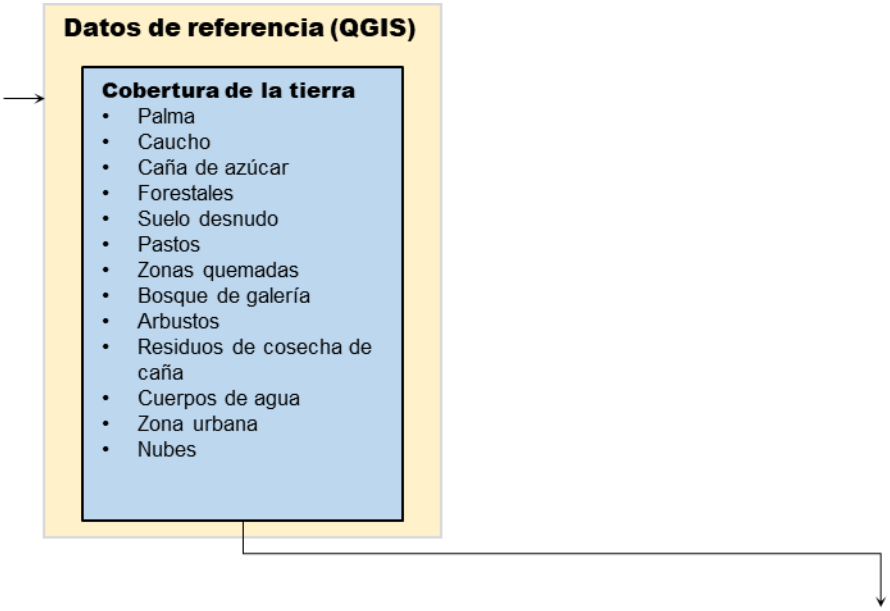

Figura 4.3. Metodología propuesta para los datos de referencia.

Segundo, se definen diversas colecciones de puntos de referencia para clases específicas, como arbustos, bosques, caña, etc., mediante la función ee.FeatureCollection. Las cuales deben ser cargadas previamente en la carpeta del proyecto en la pestaña de “Assets”.

```
var arbusto = ee.FeatureCollection("users/sarubianos/Pts_Arbustos"),
    bosque = ee.FeatureCollection("users/sarubianos/Pts_BosqueGaleria"),
    cana = ee.FeatureCollection("users/sarubianos/Pts_CanaAzucar"),
    caucho = ee.FeatureCollection("users/sarubianos/Pts_Caucho"),
    agua = ee.FeatureCollection("users/sarubianos/Pts_CuerposAgua"),
    forestal = ee.FeatureCollection("users/sarubianos/Pts_Forestales"),
    palma = ee.FeatureCollection("users/sarubianos/Pts_Palma"),
    pasto = ee.FeatureCollection("users/sarubianos/Pts_Pastos"),
    residuos = ee.FeatureCollection("users/sarubianos/Pts_ResiduosCana"),
    suelo = ee.FeatureCollection("users/sarubianos/Pts_SueloDesnudo"),
    urbano = ee.FeatureCollection("users/sarubianos/Pts_Urbano"),
    quema = ee.FeatureCollection("users/sarubianos/Pts_ZonasQuemadas"),
    nubes = ee.FeatureCollection("users/sarubianos/Pts_Nubes"),
    sombras = ee.FeatureCollection("users/sarubianos/Pts_Sombras");
```

4.1.3 Datos y preprocesamiento

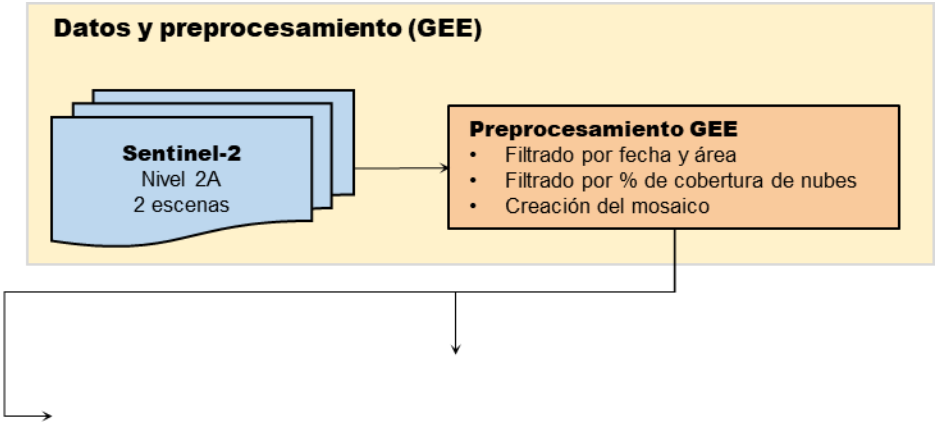

Figura 4.4. Metodología propuesta para la selección y preprocesamiento de las imágenes.

Luego, se establecen parámetros como el nombre del área, el año, las fechas de inicio y fin, y la semilla aleatoria. Además, la imágenes Sentinel-2 se llaman con la función ee.ImageCollection y se filtran según la fecha y ubicación. Se genera un listado y gráfico de estas imágenes filtradas en la consola que posteriormente ordenan de menor a mayor usando como parámetro 'CLOUDY_PIXEL_PERCENTAGE' y se selecciona la primera imagen que corresponde a la imagen con menor porcentaje de cobertura de nubes. Este proceso se realiza dos veces (s2 y s2_r2) ya que el área que se abarca cubre dos escenas diferentes de la misión Sentinel-2. Estas dos imágenes se recortan por la zona de estudio predefinida y se crea un mosaico de ambas.

```
/*//////////////////////////////////////////////////////////////////
                          First Year 2022
*//////////////////////////////////////////////////////////////////

var areaName = 'SubZona_Rio_Yucao';
var year = '2022';
var startDate = '2022-01-01';
var endDate = '2022-03-01';
var randomSeed = 0;

// Display in the console
print('Area' + " " + areaName +' ' + year);

//Add ROI to map
Map.addLayer(roi,{},'CuencaRioNegro');

//////////Sentinel-2 data//////////
```

```
var s2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filterBounds(roi);

var s2_r2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filterBounds(roi2);

// Get the dates of available images
var list = s2.aggregate_array('system:time_start').map(function(d) { return
ee.Date(d)});
print('S2 images of the area during the study period',list);

var list2 = s2_r2.aggregate_array('system:time_start').map(function(d) {
return ee.Date(d)});
print('S2 images of the area during the study period',list);

// Get the cloud score of the images
var getCloudScores = function(img){
    var value = ee.Image(img).get('CLOUDY_PIXEL_PERCENTAGE');
    return ee.Feature(null, {'score': value});
};

var s2clouds = s2.map(getCloudScores);
print ('cloud score', ui.Chart.feature.byFeature(s2clouds));

var s2clouds2 = s2_r2.map(getCloudScores);
print ('cloud score 2', ui.Chart.feature.byFeature(s2clouds2));

// Sort images by least cloudy pixel %, select and rename the bands
var s2image = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
                    .sort('CLOUDY_PIXEL_PERCENTAGE')
                    .filterBounds(roi)
                    .map(function(img){
                      var t = img.select([
'B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12']).divide(10000);//Rescale to 0-1
                      var out =
t.copyProperties(img).copyProperties(img,['system:time_start']);
                    return out;
                      })
                      .select(['B1','B2','B3','B4','B5','B6','B7','B8','B8A',
'B9', 'B11','B12'],['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2']);

var s2image2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
                    .sort('CLOUDY_PIXEL_PERCENTAGE')
                    .filterBounds(roi2)
```

```
                    .map(function(img){
                      var t = img.select([
'B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12']).divide(10000);//Rescale to 0-1
                      var out =
t.copyProperties(img).copyProperties(img,['system:time_start']);
                    return out;
                      })
                      .select(['B1','B2','B3','B4','B5','B6','B7','B8','B8A',
'B9', 'B11','B12'],['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2']);

//Start CloudMasking***
//Insert here in case you need CloudMasking
//End Cloud Masking

// Obtain the least cloudy image and clip to the ROI
var s2leastCloud1 = ee.Image(s2image.first());
var s2ROI1 = s2leastCloud1.clip(roi);
print('S2 image seleccted',s2leastCloud1);

var s2leastCloud2 = ee.Image(s2image2.first());
var s2ROI2 = s2leastCloud2.clip(roi2);
print('S2 image seleccted',s2leastCloud2);

//Make a Mosaic
var s2leastCloud =
ee.ImageCollection.fromImages([s2leastCloud1,s2leastCloud2]).mosaic();
var s2ROI = s2leastCloud.clip(roi);

var vizParams = {bands: ['red', 'green', 'blue'], min: 0, max: 0.3};
Map.addLayer(s2ROI, vizParams, 'S2 least cloudy');
```

Se deja a criterio del usuario hacer un enmascaramiento de las nubes ingresando la siguiente parte del código entre líneas “Start Cloud Masking” y “End Cloud Masking”.

```
//Start CloudMasking

var s2Clouds = ee.ImageCollection('COPERNICUS/S2_CLOUD_PROBABILITY');
var MAX_CLOUD_PROBABILITY = 60;
//var roi1 = ee.Geometry.Point([-72.46545925567536, 4.07913611567874]);
function maskClouds(img) {
  var clouds = ee.Image(img.get('cloud_mask')).select('probability');
  var isNotCloud = clouds.lt(MAX_CLOUD_PROBABILITY);
  return img.updateMask(isNotCloud);
}
// The masks for the 10m bands sometimes do not exclude bad data at
// scene edges, so we apply masks from the 20m and 60m bands as well.
```

```
function maskEdges(s2_img) {
  return s2_img.updateMask(
      s2_img.select('red4').mask().updateMask(s2_img.select('h2o').mask()));
}

// Filter input collections by desired data range and region.
var criteria = ee.Filter.and(
    ee.Filter.bounds(roi), ee.Filter.date(startDate, endDate));
var s2Sr = s2image.filter(criteria).map(maskEdges);
var s2Clouds = s2Clouds.filter(criteria);

// Join S2 SR with cloud probability dataset to add cloud mask.
var s2SrWithCloudMask = ee.Join.saveFirst('cloud_mask').apply({
  primary: s2Sr,
  secondary: s2Clouds,
  condition:
      ee.Filter.equals({leftField: 'system:index', rightField:
'system:index'})
});

var s2CloudMasked =
    ee.ImageCollection(s2SrWithCloudMask).map(maskClouds).median();
var rgbVis = {min: 0, max: 0.3, bands: ['red', 'green', 'blue']};

Map.addLayer(
    s2CloudMasked, rgbVis, 'S2 SR masked at ' + MAX_CLOUD_PROBABILITY + '%',
    true);

//End Cloud Masking
*/
```

4.1.4 Extracción de variables

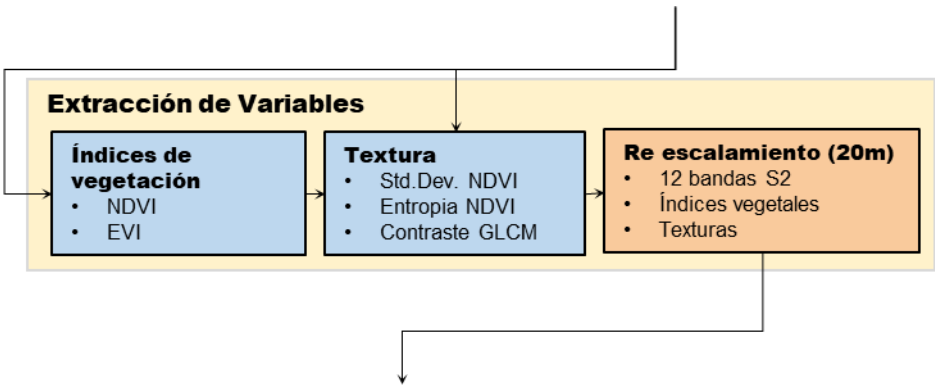

Figura 4.5. Metodología propuesta para la extracción de las variables.

Aquí se calculan diversas métricas a partir de las imágenes, incluyendo el Índice de Vegetación Normalizado (NDVI) y el Índice de Vegetación Mejorado (EVI) y 4 descriptores

de textura (Tabla 3.2.) usando un kernel cuadrado de 5x5 pixeles. Estas métricas se añaden a la imagen como nuevas bandas, esta nueva imagen se reproyecta al sistema de referencia WGS 84/UTM zone 17N (EPSG:32617) y por la diferencia entre las resoluciones espaciales de las bandas de la misión, se redimensionan todas las bandas a una resolución de 10 m.

```
// Compute the Normalized Difference Vegetation Index (NDVI)
var red = s2ROI.select('red');
var nir = s2ROI.select('nir');
var blue = s2ROI.select('blue');

var ndvi = nir.subtract(red).divide(nir.add(red)).rename('NDVI');

// Compute the EVI using an expression.
var evi = s2ROI.expression(
    '2.5 * ((NIR - RED) / (NIR + 6 * RED - 7.5 * BLUE + 1))', {
      'NIR': s2ROI.select('nir'),
      'RED': s2ROI.select('red'),
      'BLUE': s2ROI.select('blue')
}).rename('evi');

var evi_b5 = s2ROI.expression(
    '2.5 * ((NIR1 - RED) / (NIR1 + 6 * RED - 7.5 * BLUE + 1))', {
      'NIR1': s2ROI.select('red1'),
      'RED': s2ROI.select('red'),
      'BLUE': s2ROI.select('blue')
}).rename('evi_b5');

var ndviParams = {min: -1, max: 1, palette: ['Red', 'yellow', 'green']};
Map.addLayer(ndvi, ndviParams, 'NDVI', true);
Map.addLayer(evi, ndviParams, 'EVI', true);
Map.addLayer(evi_b5, ndviParams, 'EVI_B5', true);

// Compute standard deviation of NDVI as texture
var texture = ndvi.reduceNeighborhood({
  reducer: ee.Reducer.stdDev(),
  kernel: ee.Kernel.square(5),
});

Map.addLayer(texture, {min: 0, max: 0.25},'Texture', false);
print('texture',texture)

// Compute entropy of NDVI and NIR as texture
//Define a neighborhood with a kernel
//texture computed over 5 x 5
var ndvi8 =
nir.subtract(red).divide(nir.add(red)).rename('NDVI_entpy').unitScale(-1, 1)
            .multiply(255).toByte();
```

```
var nir8 = s2ROI.select('nir').rename('NIR_entpy').unitScale(0,
1).multiply(255).toByte();
var square = ee.Kernel.square({radius: 5});
var entropy = ndvi8.entropy(square);
var entropy2 = nir8.entropy(square);

Map.addLayer(entropy,{min: 1, max:5},'Entropy');
Map.addLayer(entropy2,{min: 1, max:5},'Entropy2');

// Compute the gray-level co-occurrence matrix (GLCM), get contrast.
var glcm = nir8.glcmTexture({size: 3});
print('glcm',glcm);
var contrast = glcm.select('NIR_entpy_contrast');
print('constrast', contrast);
Map.addLayer(contrast,{min: 0, max: 1500},'contrast');

// Add NDVI and texture bands
var s2final =
ee.Image(s2ROI).addBands(ndvi).addBands(texture).addBands(entropy)

.addBands(entropy2).addBands(contrast).addBands(evi).addBands(evi_b5);
print('s2final',s2final);

// Add all the appropriate bands
var bands = ['aerosol', 'blue', 'green', 'red', 'red1', 'red2', 'red3', 'nir',
            'red4', 'h2o', 'swir1', 'swir2', 'NDVI', 'NDVI_stdDev',
            'NDVI_entpy', 'NIR_entpy', 'NIR_entpy_contrast','evi','evi_b5'];
var s2finalWbands = s2final.select(bands);

// Scale the image to 20m
var s2classification = s2finalWbands.reproject(ee.Projection('EPSG:32617')
                .atScale(10)).reduceResolution({reducer:
ee.Reducer.mean(),maxPixels: 65535});
```

4.1.5 Clasificación

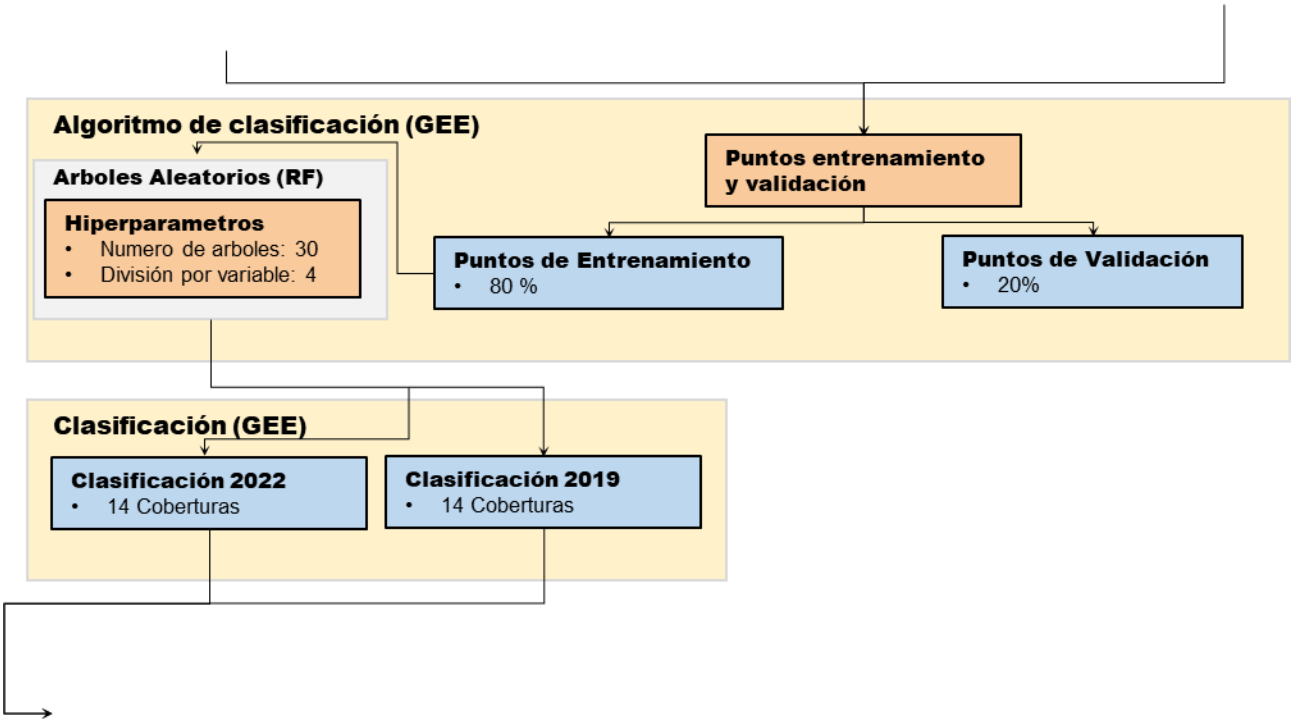

Figura 4.6. Metodología propuesta para el entrenamiento del algoritmo y la clasificación de las imagenes.

Posteriormente, se crean los conjuntos de datos de entrenamiento y validación con la función ".ramdomColumn" que adiciona una columna en la cual se asigna un valor aleatorio entre 0 y 1 con una distribución uniforme para cada punto dentro de cada uno de los puntos. Se genera la variable "split" con un valor de 0.8, usada como parámetro en las funciones "ee.Filter.lt" que selecciona los puntos con un valor menor que el definido en la variable Split y "ee.Filter.gte" que selecciona los puntos con un valor mayor o igual. Con la función ".sampleRegions" se genera la variable training en la cual se almacenan los valores espectrales de cada una de las bandas de la imagen para los puntos que fueron seleccionados para entrenamiento.

```
//////////create training and verification data//////////
// Assign random column to sample
var n = randomSeed;
var randomArbustos = arbusto.randomColumn('random', n);
var randomSombras = sombras.randomColumn('random', n);
var randomBosque = bosque.randomColumn('random', n);
var randomCana = cana.randomColumn('random', n);
var randomCaucho = caucho.randomColumn('random', n);
```

```
var randomAgua = agua.randomColumn('random', n);
var randomForestal = forestal.randomColumn('random', n);
var randomNubes = nubes.randomColumn('random', n);
var randomPalma = palma.randomColumn('random', n);
var randomPasto = pasto.randomColumn('random', n);
var randomResiduos = residuos.randomColumn('random', n);
var randomSuelos = suelo.randomColumn('random', n);
var randomUrbano = urbano.randomColumn('random', n);
var randomQuema = quema.randomColumn('random', n);

// 80:20 for training and testing
var split = 0.8;

var trainingSample =
 randomBosque.filter(ee.Filter.lt('random', split))
  .merge(randomArbustos.filter(ee.Filter.lt('random', split)))
  .merge(randomSombras.filter(ee.Filter.lt('random', split)))
  .merge(randomCana.filter(ee.Filter.lt('random', split)))
  .merge(randomCaucho.filter(ee.Filter.lt('random', split)))
  .merge(randomAgua.filter(ee.Filter.lt('random', split)))
  .merge(randomForestal.filter(ee.Filter.lt('random', split)))
  .merge(randomNubes.filter(ee.Filter.lt('random', split)))
  .merge(randomPalma.filter(ee.Filter.lt('random', split)))
  .merge(randomPasto.filter(ee.Filter.lt('random', split)))
  .merge(randomResiduos.filter(ee.Filter.lt('random', split)))
  .merge(randomSuelos.filter(ee.Filter.lt('random', split)))
  .merge(randomUrbano.filter(ee.Filter.lt('random', split)))
  .merge(randomQuema.filter(ee.Filter.lt('random', split)));

var testingSample = randomBosque.filter(ee.Filter.gte('random', split))
  .merge(randomArbustos.filter(ee.Filter.gte('random', split)))
  .merge(randomSombras.filter(ee.Filter.gte('random', split)))
  .merge(randomCana.filter(ee.Filter.gte('random', split)))
  .merge(randomCaucho.filter(ee.Filter.gte('random', split)))
  .merge(randomAgua.filter(ee.Filter.gte('random', split)))
  .merge(randomForestal.filter(ee.Filter.gte('random', split)))
  .merge(randomNubes.filter(ee.Filter.gte('random', split)))
  .merge(randomPalma.filter(ee.Filter.gte('random', split)))
  .merge(randomPasto.filter(ee.Filter.gte('random', split)))
  .merge(randomResiduos.filter(ee.Filter.gte('random', split)))
  .merge(randomSuelos.filter(ee.Filter.gte('random', split)))
  .merge(randomUrbano.filter(ee.Filter.gte('random', split)))
  .merge(randomQuema.filter(ee.Filter.gte('random', split)));

// Get the values for training
var training = s2classification.sampleRegions({
  collection: trainingSample,
  properties: ['ClassID'],
  scale: 10,
});
```

Para el proceso de clasificación se utiliza un clasificador de Bosque Aleatorio con el algoritmo (“ee.Classifier.smileRandomForest”) en este algoritmo los híperparámetros se ajustaron para el número de árboles (numberOfTrees) con un valor de 90 árboles y el número de variables de predicción por nodo (variablesPerSplit) se ajustó a 4.

```
//////////classify and verify//////////
// Create the classifier
var classifier = ee.Classifier.smileRandomForest({
  numberOfTrees: 90,
  variablesPerSplit: 4
  })
    .train(training, 'ClassID');

//////Variable Importance of RF Classifier
var dict = classifier.explain();
  var explainTitle = 'Explain ' + areaName + ' :';
  print(explainTitle, dict);

  var variable_importance = ee.Feature(null,
ee.Dictionary(dict).get('importance'));

  // Chart of Variable Importance of RF Classifier
  var chartTitle = 'Random Forest Variable Importance for trees for ' +
areaName;
  var chart =
    ui.Chart.feature.byProperty(variable_importance)
      .setChartType('ColumnChart')
      .setOptions({
        title: chartTitle,
        legend: {position: 'none'},
        hAxis: {title: 'Bands'},
        vAxis: {title: 'Importance'}
      });
  print(chart);

// Classify the input imagery
var classified = s2classification.classify(classifier,'classification');
```

Se crea una paleta de colores para cada una de las coberturas clasificadas, que posteriormente se emplea para desplegar la visualización de la clasificación realizada en conjunto con la leyenda.

```
// Create a palette to display the classes
var palette =['8be8a1',// Arbustos          1 (Verde claro)
              'ed09c3',// Palma             2 (Violeta)
              '09e0ce',// Caucho            3 (Azul Aguamarina)
```

```
                'FF7F00',// Caña                4 (Naranja)
                'ffff00',// Forestales         5 (Amarillo)
                '662e06',// Suelo Desnudo      6 (Cafe)
                '807c0f',// Pastos             7 (Amarillo Oscuro)
                'b02b13',// Zonas Quemadas     8 (Rojo)
                '0d7526',// Bosque de Galería 9 (Verde Oscuro)
                'ababa6',// Urbano             10 (Gris)
                'eced8e',// Residuos de Cosecha de Caña 11 (beish)
                '0000ff',// Cuerpos de Agua    12 (Azul)
                '202421',// Sombras            13 (Negro)
                'ffffff',// Nubes              14 (Blanco)
                ];

// Display the classified map
Map.addLayer(classified, {min: 1, max: 14, palette: palette}, 'Classified');
Map.centerObject(roi, 15);

var visualization = classified.visualize({palette: palette, min: 1,  max:
14});

// Create a legend
var labels = ['Arbustos','Palma de Aceite','Caucho', 'Caña de Azucar',
'Forestales', 'Suelo Desnudo'
              , 'Pastos', 'Zonas quemadas','Bosque de Galería', 'Contrucciones
Urbanas',
              'Residuos de cosecha de caña','Cuerpos de
Agua','Sombras','Nubes'];

var add_legend = function(title, lbl, pal)
  {var legend = ui.Panel({style: {position: 'bottom-left'}}), entry;
    legend.add(ui.Label({value: title, style: { fontWeight: 'bold', fontSize:
'18px'
                                                , margin: '0 0 4px 0', padding:
'0px' } }));
   for (var x = 0; x < lbl.length; x++)
      {entry = [ ui.Label({style:{color: pal[x], border:'1px solid black'
      , margin: '0 0 4px 0'}, value: '  '}), ui.Label({ value: labels[x]
      , style: { margin: '0 0 4px 4px' } }) ];
      legend.add(ui.Panel(entry, ui.Panel.Layout.Flow('horizontal')));}
Map.add(legend);
  };

add_legend('Legend', labels, palette);
```

4.1.6 Validación

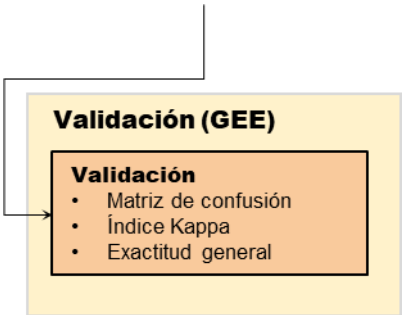

Figura 4.7. Metodología propuesta para la evaluación del desempeño del clasificador.

Se evalúa el desempeño del clasificador validando en primer lugar para el set de datos utilizados en el entrenamiento, en segunda instancia, se realiza la clasificación de los datos de validación y se calcula la matriz de confusión y de esta se extrae el valor de la precisión general de la clasificación y la precisión del usuario y productor.

```
// Get a confusion matrix representing resubstitution accuracy
var trainAccuracy = classifier.confusionMatrix();
print('Resubstitution error matrix: ', trainAccuracy);
print('Training overall accuracy: ', trainAccuracy.accuracy());

// Sample the input to get validation data
var validation = s2classification.sampleRegions({
  collection: testingSample,
  properties: ['ClassID'],
  scale: 10,
});

// Classify the validation data
var validated = validation.classify(classifier);

// Get a confusion matrix representing expected accuracy
var testAccuracy = validated.errorMatrix('ClassID', 'classification');
print ('Validation accuracy exported to "Tasks"');
print('Validation error matrix: ', testAccuracy);
print('Validation overall accuracy: ', testAccuracy.accuracy());
print('Validation custumers accuracy: ', testAccuracy.consumersAccuracy());
print('Validation producers accuracy: ', testAccuracy.producersAccuracy());
```

Se realiza un ajuste del hiperparametro de número de árboles para el clasificador de Bosques Aleatorios, evaluando la precisión del modelo para diferentes cantidades de árboles.

```
///////////Hyperparmeter Tuning//////////////
// Tune the numberOfTrees parameter

var numTreesList = ee.List.sequence(5,200,5)

var accuracies = numTreesList.map(function(numTrees){
  var classifier = ee.Classifier.smileRandomForest(numTrees)
      .train({
        features: training,
        classProperty:'ClassID',
        inputProperties: s2classification.bandNames()
      });
  return validation
    .classify(classifier)
    .errorMatrix('ClassID','classification')
    .accuracy();
});

var chart10= ui.Chart.array.values({
  array: ee.Array(accuracies),
  axis: 0,
  xLabels: numTreesList
  }).setOptions({
    title: 'Hyperparameter Tuning for the numberOfTrees Parameter',
    vAxis: {title: 'Validation Accuracy'},
    hAxis: {title: 'Number of trees', gridlines: {count:15}}
  });
print(chart10)
```

Finalmente se exportan los resultados a Google Drive, la matriz de confusión en formato .csv y los mapas de la clasificación realizada en formato .tif y escala de 10 m.

```
//////////////export results//////////////
var exportAccuracy = ee.Feature(null, {matrix: testAccuracy.array()});
var exportAccuracyNumber = ee.Feature(null, {matrix:
testAccuracy.accuracy()});

Export.table.toDrive({
  collection: ee.FeatureCollection(exportAccuracy),
  description: 'AccuracyMatrix'+'_'+areaName + year + '_'+ randomSeed,
  fileFormat: 'CSV'
});

//////////////export images//////////////
Export.image.toDrive({
  image: visualization,
  description: 'classifiedMap_colour'+'_'+areaName+year+'_'+ randomSeed,
  region: roi,
  crs: 'EPSG:32617',
  scale: 10
```

```
});

Export.image.toDrive({
  image: classified,
  description: 'classifiedMap_raster'+'_'+ areaName + year + '_'+ randomSeed,
  region: roi,
  crs: 'EPSG:32617',
  scale: 10
});
```

4.1.7 Detección de Cambio

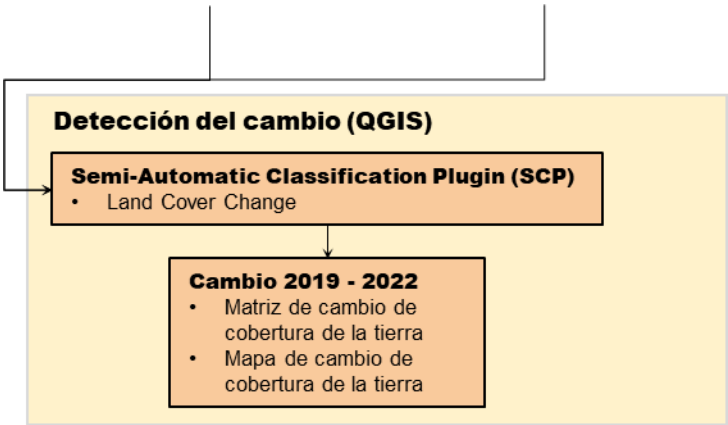

Figura 4.8. Metodología propuesta para la detección de cambios de cobertura de la tierra.

Posteriormente se realiza la clasificación de la segunda fecha que para este estudio fue del año 2019, utilizando el clasificador previamente entrenado, los resultados de esta clasificación se exportan a Google Drive. Estos dos mapas de coberturas de la tierra para las fechas 2022 y 2019 se llevan al software QGIS donde mediante el complemento SCP (Semi-Automatic Classification Plugin) se realiza la detección del cambio mediante un análisis de tabulación cruzada píxel por píxel con la función “Land cover change”. Este procedimiento genera como resultado una matriz cruzada bidireccional que contene diferentes combinaciones de clases de cambio "desde-hasta" con las áreas en m^2 que permite evidenciar los cambios entre clases (Chowdhury et al., 2020) (Figura 4.14).

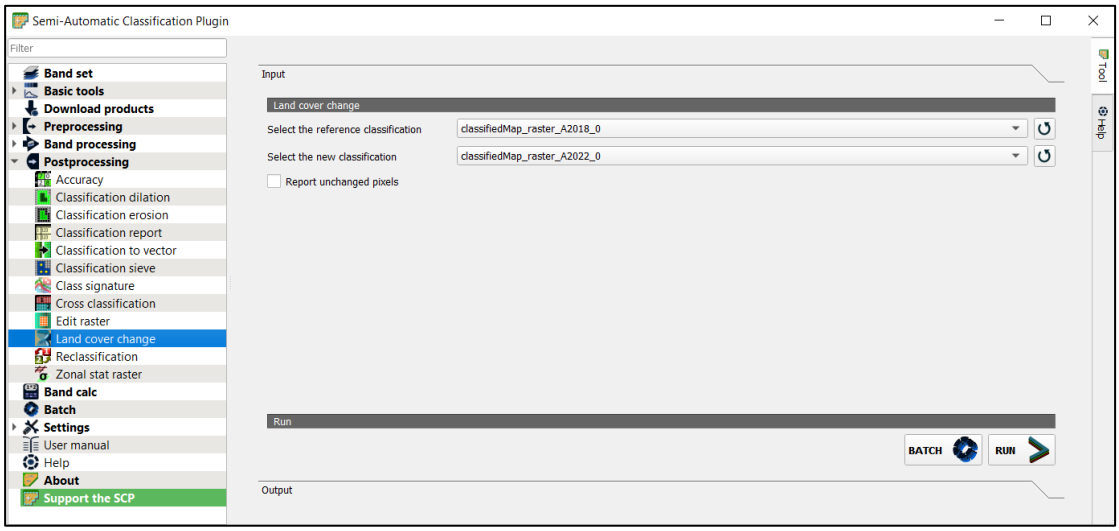

Figura 4.9. Uso del complemento SCP para la detección del cambio de la cobertura de la tierra.

4.2 Metodología aplicada en la zona de estudio

Lo primero que se realizó fue el filtrado de las imágenes por zona de interés y fecha para el primer trimestre del año 2022, las cuales se ordenaron por el porcentaje de cobertura de nubes, este procedimiento se realizó a las dos escenas que abarcan toda el área de interés seleccionando las imágenes con un porcentaje de cobertura de nubosidad de 0.14 y 3.50, de igual manera se realizó este procedimiento para la segunda fecha en el año 2019 y seleccionando las imágenes con 8.07 y 3.31 de este porcentaje. las imágenes seleccionadas (Tabla 4.1.) y los gráficos generados en la consola para ilustrar las imágenes disponibles con su porcentaje de cobertura de nubes son presentados a continuación (Figura 4.15.).

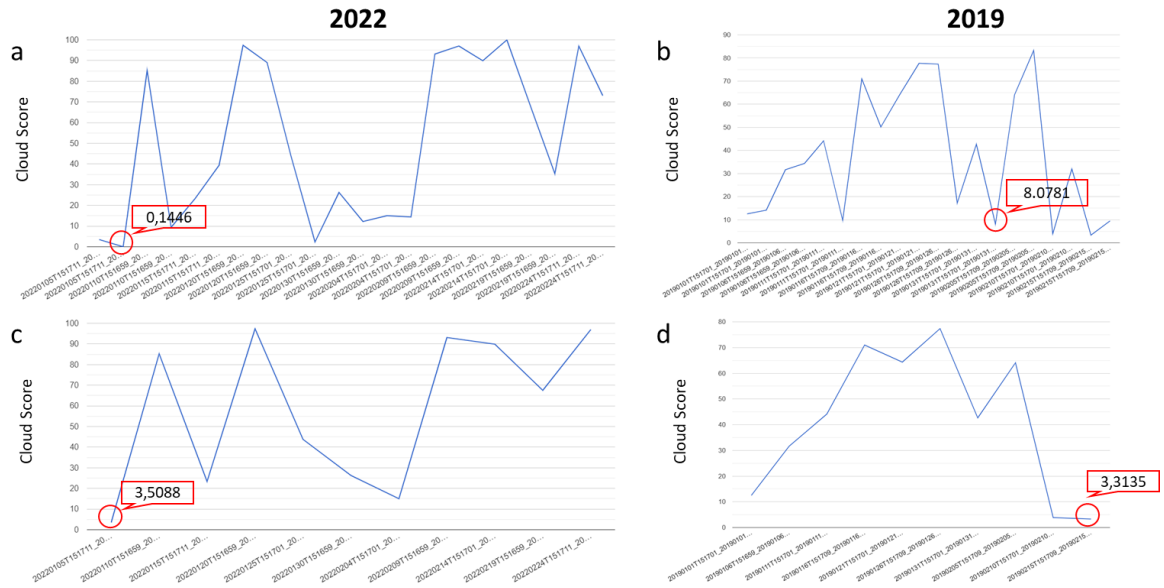

Figura 4.10. Puntaje de nubosidad para las imágenes encontradas en el primer trimestre de los años 2022 (a, c) y 2019 (b, d).

Tabla 4.1. Imágenes Sentinel-2 seleccionadas.

Año	Tesela (Tile)	Identificador de la Imagen (Granule ID)	% Cobertura de nubes
2022	18NZK	L2A_T18NZK_A034156_20220105T151705	0.1446
	18NYK	L2A_T18NYK_A034156_20220105T151705	3.5088
2019	18NZK	L2A_T18NZK_A018855_20190131T151701	8.0781
	18NYK	L2A_T18NYK_A010161_20190215T151703	3.3135

A nivel general visualmente las clasificaciones realizadas para el año 2022 (Figura 4.11.) y para el año 2019 (Figura 4.12.) muestran coherencia en las diferentes coberturas del estudio, sin embargo, cuando vemos a detalle las clasificaciones, se observa que hay cierta confusión por parte del clasificador para discriminar ciertas coberturas, como por ejemplo Caucho con Cultivos forestales y Bosque de galería, que se puede corroborar en la matriz de confusión (Tabla 4.2.) que para la clase de Caucho muestra una especificidad de 0.97, precisión de 0.7, Sensibilidad de 0.7 y F1-Score de 0.7, Cultivos forestales una especificidad de 0.98, precisión de 0.6, Sensibilidad de 0.38 y F1-Score de 0.46 y Bosques de galería una especificidad de 0.96, precisión de 0.38, Sensibilidad de 0.6 y F1-Score de

0.46. De igual manera se encontró visualmente una confusión entre los bordes de las Nubes y la clase de Zonas urbanas y a su vez una confusión entre los bordes de las Sombras de nubes con las clases de Cuerpos de agua y Zonas quemadas, aunque estos errores no se ven tan marcados en los valores de especificidad, precisión, Sensibilidad y F1-Score en la matriz de confusión para estas clases.

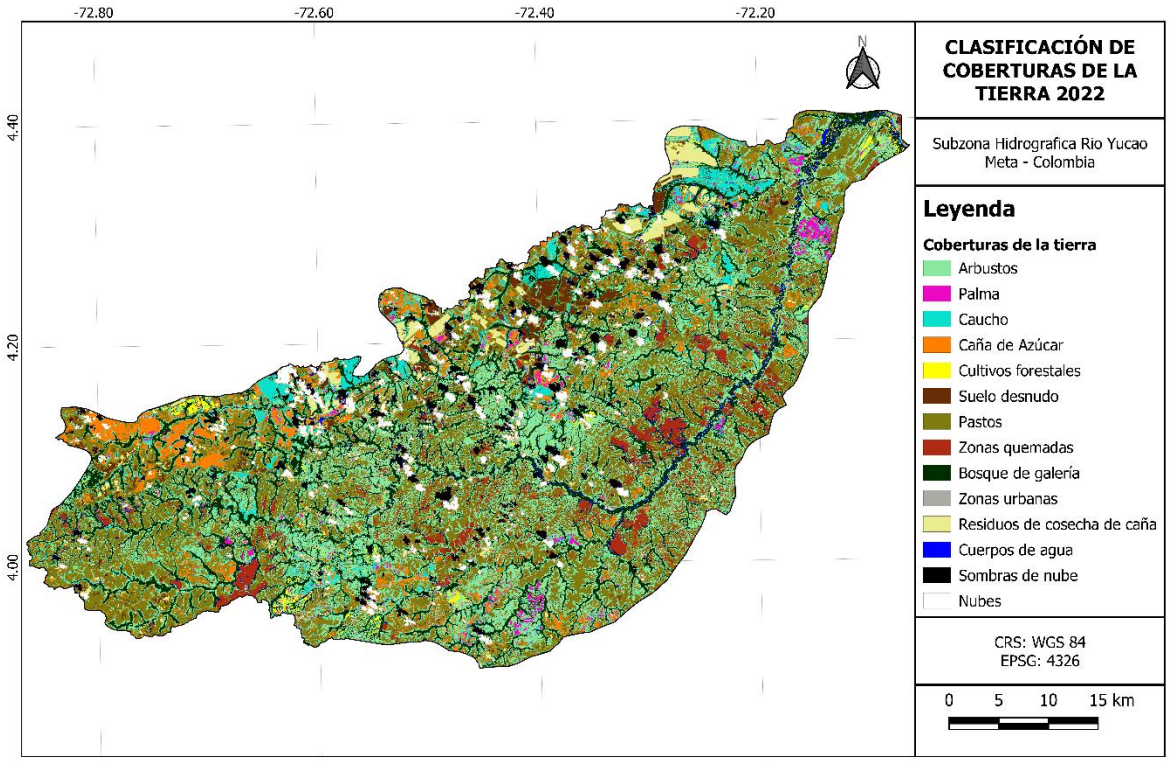

Figura 4.11. Clasificación de coberturas de la tierra 2022.

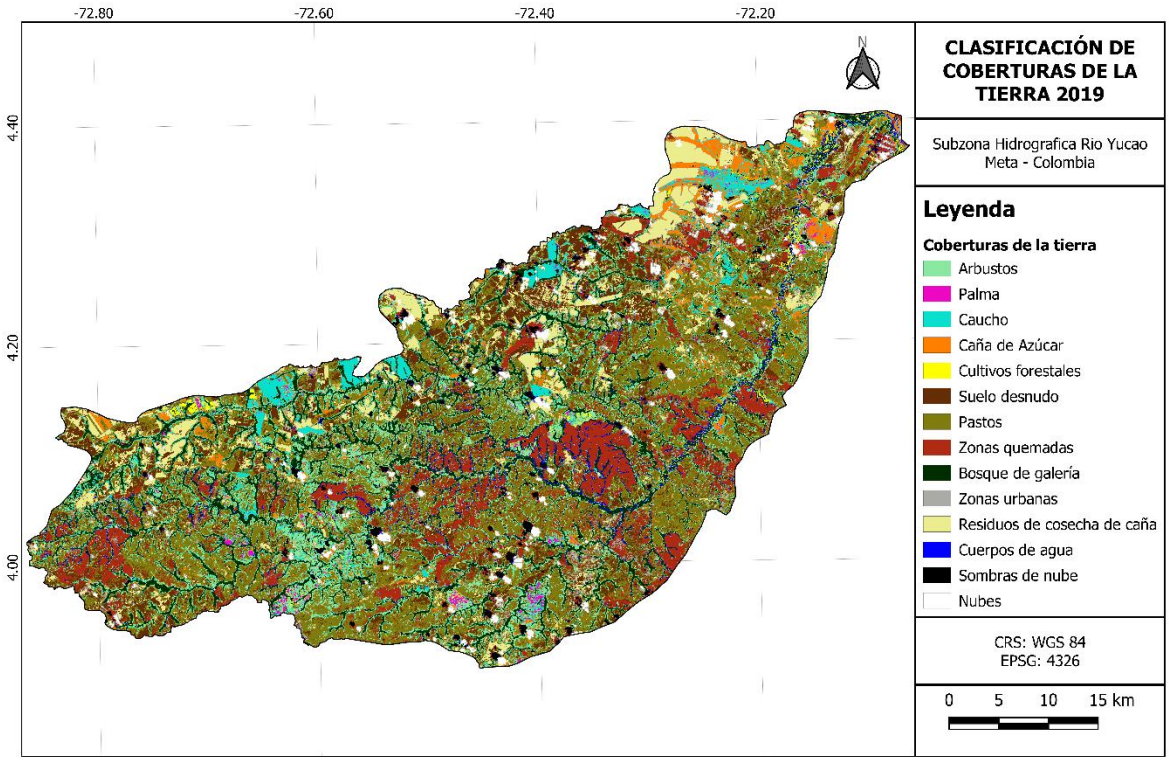

Figura 4.12. Clasificación de coberturas de la tierra 2019.

Para la clasificación de coberturas de la tierra para el año 2022 se obtuvo una precisión global de 84.13 % y un índice Kappa de 0.83 (**Tabla 4-2**) que según (Landis y Koch, 1977) corresponde a una fuerza de concordancia casi perfecta, aunque como se mencionó anteriormente se evidencia una confusión entre algunas clases que no se ven reflejadas en la matriz de confusión, esto se podría deber al número de muestras utilizados en el conjunto de datos utilizado para la validación.

Tabla 4.2. Matriz de confusión para la clasificación 2022.

Mapa \ Interpretación	Arbustos	Palma	Caucho	Caña de azúcar	Cultivos Forestal	Suelo desnudo	Pastos	Zonas quemadas	Bosque de galería	Sombras	Residuos de cosecha de caña	Cuerpos de agua	Zona urbana	Nubes	TOTAL	Exactitud del Usuario (%)	Error de Comisión (%)	Especificidad	Precisión	Sensibilidad Recall	F1-Score
Arbustos	7	0	1	0	1	0	0	0	0	0	0	0	0	0	9	77.78	22.22	0.96	0.58	0.78	0.67
Palma	0	9	1	0	0	0	0	0	0	0	0	0	0	0	10	90.00	10.00	1.00	1.00	0.90	0.95
Caucho	2	0	7	0	0	0	1	0	0	0	0	0	0	0	10	70.00	30.00	0.97	0.70	0.70	0.70
Caña de azúcar	0	0	0	8	0	0	0	0	0	0	0	0	0	0	8	100.00	0.00	1.00	1.00	1.00	1.00
Cultivos Forestal	0	0	1	0	3	0	0	0	4	0	0	0	0	0	8	37.50	62.50	0.98	0.60	0.38	0.46
Suelo desnudo	0	0	0	0	0	5	0	0	0	0	0	0	0	0	5	100.00	0.00	0.99	0.83	1.00	0.91
Pastos	0	0	0	0	0	1	6	0	0	0	0	0	0	0	7	85.71	14.29	0.97	0.67	0.86	0.75
Zonas quemadas	2	0	0	0	0	0	2	8	0	0	0	0	0	0	12	66.67	33.33	1.00	1.00	0.67	0.80
Bosque de galería	1	0	0	0	1	0	0	0	3	0	0	0	0	0	5	60.00	40.00	0.96	0.38	0.60	0.46
Zona urbana	0	0	0	0	0	0	0	0	0	16	0	0	0	0	16	100.00	0.00	0.99	0.94	1.00	0.97
Residuos de cosecha de caña	0	0	0	0	0	0	0	0	0	0	4	0	0	0	4	100.00	0.00	1.00	1.00	1.00	1.00
Cuerpos de agua	0	0	0	0	0	0	0	0	1	1	0	11	0	0	13	84.62	15.38	1.00	1.00	0.85	0.92
Sombras	0	0	0	0	0	0	0	0	0	0	0	0	9	0	9	100.00	0.00	1.00	1.00	1.00	1.00
Nubes	0	0	0	0	0	0	0	0	0	0	0	0	0	10	10	100.00	0.00	1.00	1.00	1.00	1.00
TOTAL	12	9	10	8	5	6	9	8	8	17	4	11	9	10	126						

Precisión Global	84.127
q	9.865
Kappa	0.828

Se realizó el ajuste hiperparámetros para el clasificador de Bosque Aleatorio, evaluando la precisión del modelo para diferentes cantidades de árboles donde se obtuvo la mayor precisión (0.8412) con 90 árboles (Figura 4.13.).

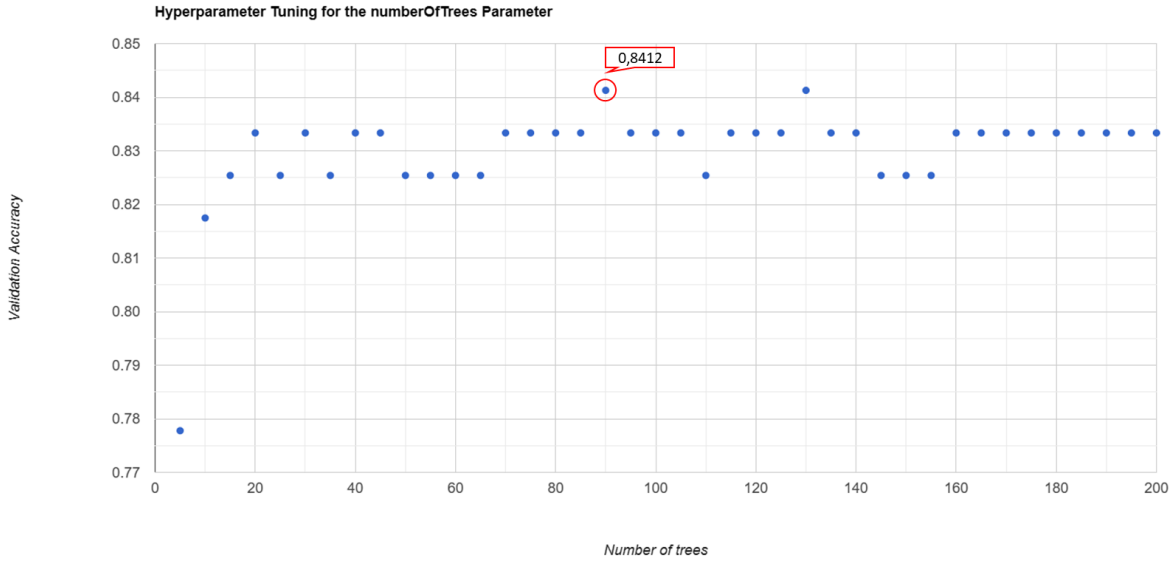

Figura 4.13. Optimización del hiperparametro número de árboles para el clasificador.

En la Figura 4.14. se grafican cada una de las variables empleadas y su importancia en el algoritmo de clasificación, mostrando como las variables de textura e índices de vegetación tienen una importancia que predomina respecto a las otras variables.

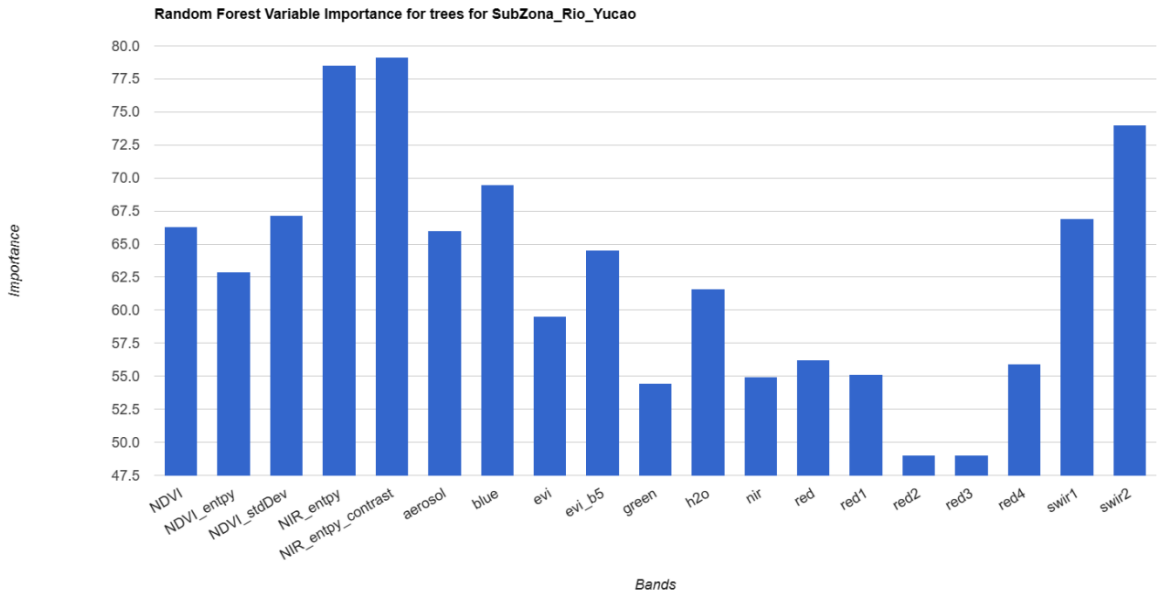

Figura 4.14. Importancia de las variables empleadas en el algoritmo de clasificación.

En la Figura 4.15. se muestran las firmas espectrales de las coberturas clasificadas para los años 2022 (**a**) y para el año 2019 (**b**), donde se puede observar que hay algunas bandas en las que la separación entre algunas coberturas es ajustada principalmente en las bandas Aerosol costero (B1), Vapor de agua (B9) y Cirrus (B10).

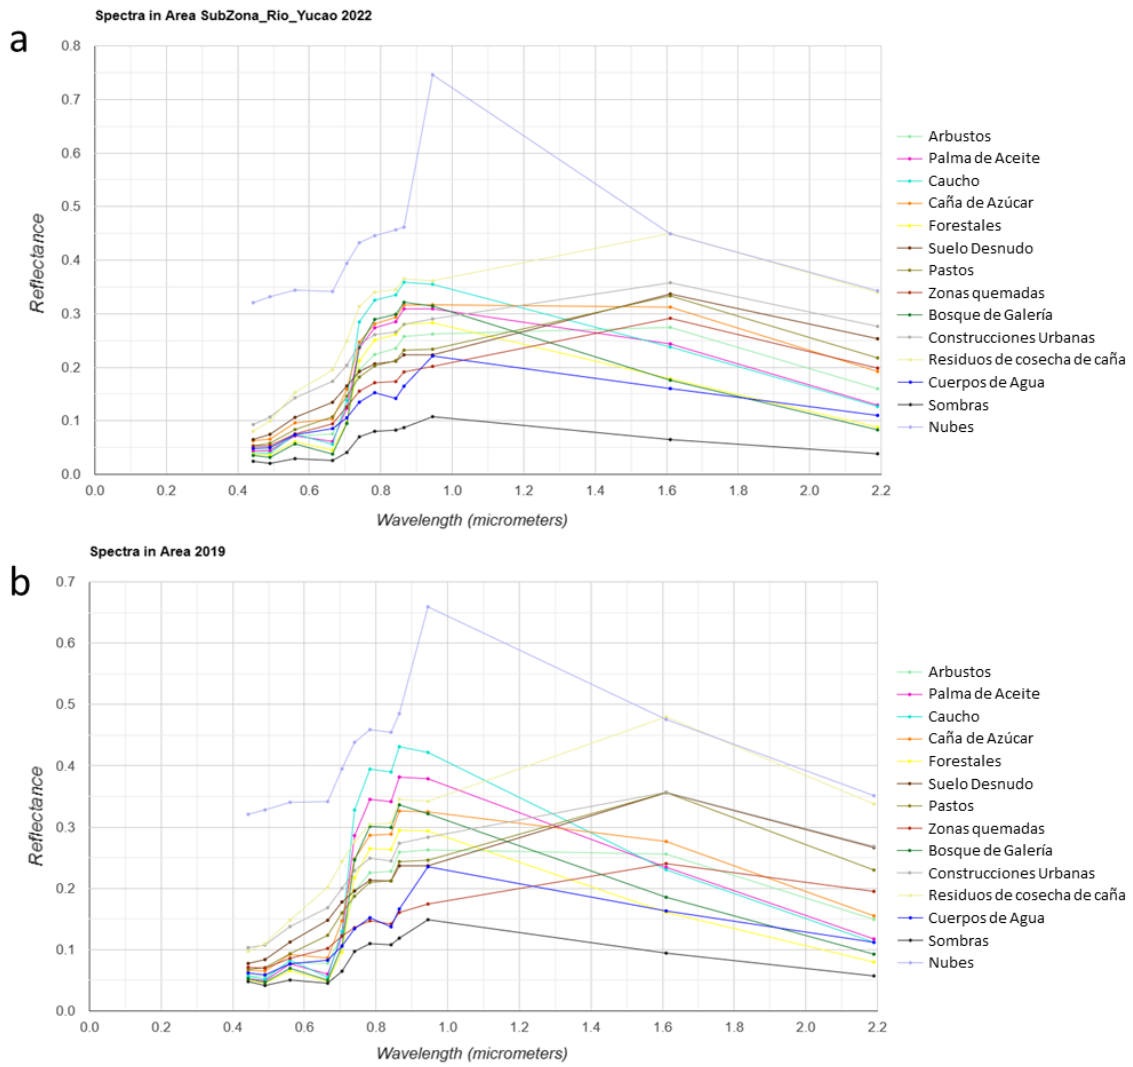

Figura 4.15. Firma espectral de las coberturas para los años 2022 (a) y 2019 (b).

En la Figura 4.16. se muestra el valor promedio de cada una de las coberturas clasificadas para algunas de las texturas e índices calculados, donde se observa un patrón similar para clases en las que hay mayor confusión como los ejemplos anteriormente mencionados y una mayor diferenciación entre las clases lo cual respalda los valores de mayor importancia en las bandas de textura.

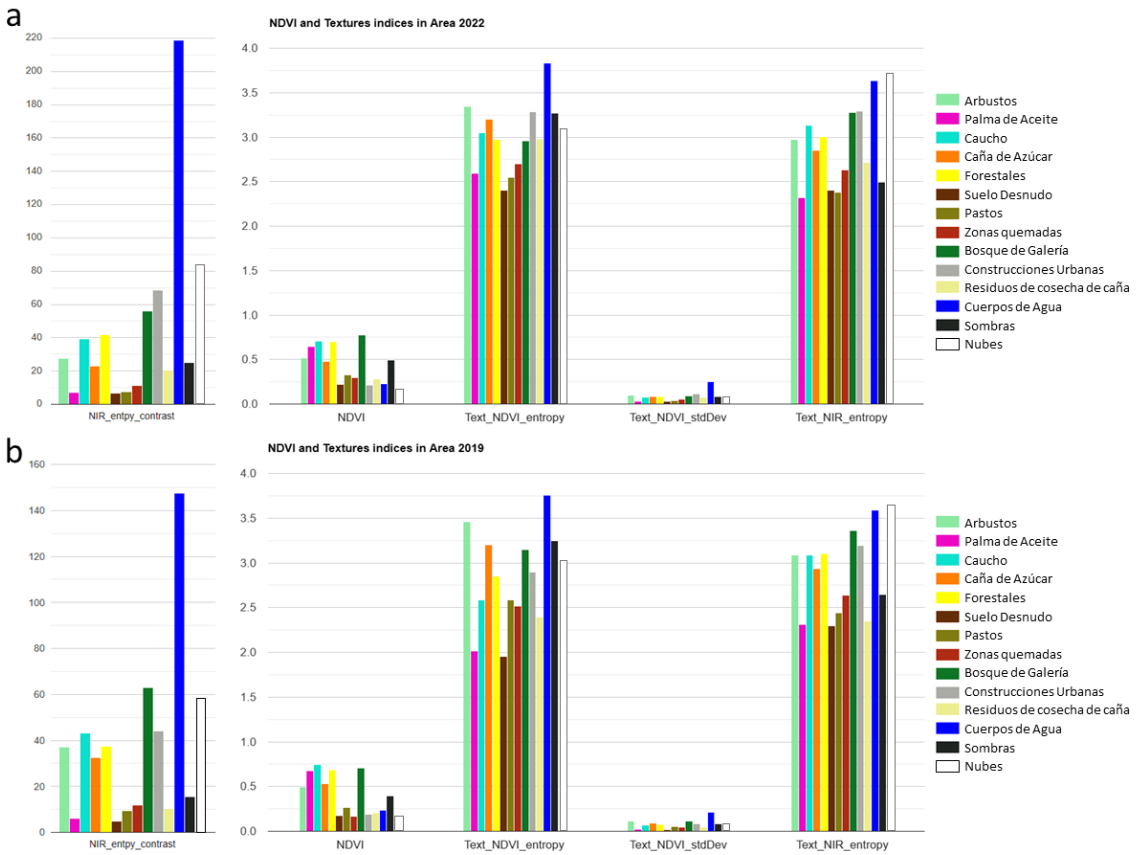

Figura 4.16. NDVI y texturas calculadas de las coberturas para el año 2022 (a) y 2019 (b).

En la tabla 4.3. se muestra la matriz de cambio donde la diagonal muestra la cantidad de hectáreas que no cambió e interpretada de forma horizontal se muestra el número de hectáreas que cambio una clase del año 2019 al año 2022. Por ejemplo, la clase Arbustos de las 29808 ha totales en el 2019 se mantuvieron 18728 y 319 pasaron a ser ocupadas por Palma.

Tabla 4.3. Matriz de cambio de cobertura de la tierra para la clasificación del año 2022.

2019 \ 2022	Arbustos	Palma	Caucho	Caña de azúcar	Cultivos Forestal	Suelo desnudo	Pastos	Zonas quemadas	Bosque de galería	Sombras	Residuos de cosecha de caña	Cuerpos de agua	Zona urbana	Nubes	TOTAL
Arbustos	18728	319	2322	743	659	15	483	153	4044	242	27	324	853	896	29808
Palma	150	533	126	24	257	0	7	0	144	4	1	1	32	35	1312
Caucho	1897	228	5045	406	264	3	140	6	3825	30	20	38	290	575	12769
Caña de azúcar	2993	867	1946	1083	286	31	391	43	1964	55	111	47	197	188	10200
Cultivos Forestal	82	43	38	18	495	3	24	1	1154	4	4	30	30	39	1965
Suelo desnudo	1184	228	212	1896	42	2077	14706	1585	18	480	1112	102	758	888	25287
Pastos	23345	539	2021	5416	164	851	28420	5213	264	1274	1153	445	1661	1916	72682
Zonas quemadas	7038	85	260	524	66	409	10664	5471	109	326	226	119	639	566	26502
Bosque de galería	512	28	507	279	351	0	12	1	25801	45	6	66	746	922	29275
Zona urbana	2394	33	254	483	18	248	4134	486	107	571	290	250	219	369	9856
Residuos de cosecha de caña	842	222	631	3079	28	1939	5611	202	22	248	3515	98	542	530	17508
Cuerpos de agua	2157	4	87	56	31	16	199	86	305	72	11	1010	111	104	4248
Sombras	1067	62	216	172	65	92	649	102	595	39	49	25	85	134	3353
Nubes	1290	84	333	253	50	104	995	138	790	92	112	36	171	165	4613
TOTAL	63678	3274	13996	14431	2776	5788	66436	13489	39142	3481	6636	2592	6332	7327	509237

5. Discusión

Dada la importancia de la detección del cambio de la cobertura de la tierra en los proyectos de ordenamiento territorial del país, el monitoreo y estudio de efectos causados por fenómenos naturales o por el mismo hombre y la valoración de sus posibles riesgos en distintos estudios ambientales (Kumar, 2006; Santana & Salas, 2007), es fundamental generar una metodología que optimice este proceso en tiempo y recursos. En el monitoreo del cambio de la cobertura, la clasificación de las coberturas de la tierra y la detección del cambio de estas mismas son dos procesos fundamentales y aunque se han identificado diferentes estudios que abarcan este proceso (Wang et al., 2022), la semiautomatización de una metodología con datos y software de libre acceso e implementación de este mismo en Colombia es escasa (González-González et al., 2022). En este contexto, este estudio buscó semiautomatizar una metodología para monitorear el cambio de la cobertura de la tierra y aplicarla a una zona en el departamento del Meta. Para esto se realizó la selección, preprocesamiento y clasificación de las imágenes Sentinel-2 en el programa GEE y la detección del cambio en el complemento SCP en el software QGIS.

En otros estudios realizados para analizar el cambio de coberturas de la tierra se han empleado diferentes softwares para realizar la clasificación de las coberturas. Hussain *et al.* (2022) realizó un análisis del cambio de uso y cobertura de la tierra para el distrito de Okara Punjab en Pakistan utilizando el software ERDAS imagine obteniendo buenos resultados en sus clasificaciones al igual que reportan otros autores (Naikoo et al., 2020), de igual manera otros investigadores realizan el procesamiento con en el programa ESRI ArcGIS Pro (Njoku & Tenenbaum, 2022) obteniendo de igual manera buenos resultados. Sin embargo, estos softwares son de licenciamiento y por ende aumenta los costos para

este tipo de análisis lo que dificulta a los usuarios que quieran hacer uso de estas herramientas.

Por otro lado, se han realizado estudios en los que también se han utilizado programas como R-Studio (Rotich et al., 2022) el cual es de libre acceso, pero requiere que las imágenes empleadas para la clasificación sean descargadas y almacenadas de manera digital, lo que incurre en un mayor tiempo al descargar las imágenes y mayor consumo de espacio de almacenamiento. Estos mismos inconvenientes los presenta el software QGIS con el complemento Semi-Automatic Classification Plugin (SCP) Leroux *et al*., 2018 (Belenok et al., 2021), además que los algoritmos de clasificación de machine learning como el algoritmo de RF en esta herramienta solo permite ajustar el número de árboles entre los hiperparametros del algoritmo, mientras que en la plataforma de GEE que se empleó en este estudio se ajustó el número de árboles y el número de variables por división que permiten mejorar el desempeño del clasificador ajustado a los datos. Esta plataforma tiene gran potencial por ser de libre acceso, tener repositorios de imágenes en línea y hacer el procesamiento en la nube, esto hace que el usuario ahorre recursos de dinero, tiempo y almacenamiento. Dynamic Word (Brown et al., 2022; Gao et al., 2022) sitio web que utiliza los recursos de GEE es de libre acceso, pero las clases de cobertura de la tierra que se pueden clasificar ya están predefinidas y son muy generales, por lo que la metodología desarrollada en este estudio para la clasificación de las coberturas en GEE y permite modificar las clases aprovechando todas las ventajas anteriormente mencionadas.

Otros estudios en las que son empleadas imágenes como PlanetScope se obtuvieron clasificaciones con una exactitud general mayor al 97% (Acharki, 2022) superando el desempeño de las imágenes Sentinel-2 y Landsat-8 pero que por el hecho de no ser de libre acceso agregan un costo en el análisis, sin embargo, otros autores como Rahman et al. (2020) reportan lo contrario con un mejor desempeño por encima del 4% para Sentinel-2 en comparación de Landsat-8 y PlanetScope. Así mismo Nyamekye et al. (2021) reporta que el uso de las bandas en la región del Red-Edge y su mayor resolución espectral que poseen las imágenes Sentinel-2 generan una mejor clasificación que Landsat-8 con el clasificador RF (Blickensdörfer et al., 2022; Ghayour et al., 2021; Nemmaoui et al., 2018; Sun et al., 2019).

Chachondhia et al. 2021 han encontrado buenos resultados utilizando en conjunto Sentinel-2 y Sentinel-1 pero el uso de imágenes de radar implica mayor procesamiento y experticia en el procesamiento de estas imágenes que no todos los usuarios tienen por lo que reduce su aplicabilidad, además que los autores reportan que aunque los resultados de la fusión de estas imágenes genera resultados más realistas, al comparar la exactitud general de las clasificaciones para el clasificador RF es mayor para las imágenes Sentinel-2 con 92 % en comparación de la fusión de S-1 y S-2 con un 85.71 %.

En el mapeo del cambio de coberturas de la tierra varias investigaciones han resaltado el uso del clasificador RF a partir de la detección de cambios coberturas empleando probabilidades para series temporales de imágenes, Yin et al. (2014) generó una metodología para intervalos de tiempo anuales utilizando datos de MODIS, otros estudios utilizaron enfoques de clasificación posterior basados en filtros temporales por píxel con reglas de transición (Clark et al., 2010), de igual manera Li et al. (2014) aplicaron un enfoque de co-simulación de campo aleatorio de cadena de Markov (MCRF) con datos preclasificados. Aunque estos métodos mostraron tener un buen desempeño su empleo requiere de series temporales y que para el presente estudio se optó por la selección de una sola imagen con la menor cantidad de nubes ya que en la series temporales hacen una composición de las imágenes con los valores medios de los pixeles pero esto podría enmascarar eventos específicos o perturbaciones de corta duración como incendios que representan un cambio para la cobertura y de importancia para entidades de planeación y vigilancia del territorio. Por lo que el complemento SCP es una herramienta apropiada para realizar la detección del cambio, el cual emplea un análisis de tabulación cruzada píxel por píxel tal como lo evidencia la investigación de Chowdhury et al., 2020, ya que este complemento genera un mapa de cambio y matiz de cambio de las coberturas de manera rápida.

En la clasificación con el clasificador Random forest se obtuvo una exactitud general de 84% que con literatura (Landis y Koch, 1977) corresponde a una clasificación aceptable concuerda con otros autores donde se obtuvo buenos resultados con este clasificador aunque se puede estar sobreestimando la validación por existir posible correlación espacial en las muestras de validación, ya que hay algunas confusiones entre clases como caucho, cultivos forestales y bordes de bosques de galería que es apenas entendible por

la naturaleza de las coberturas también entre las sobras y cuerpos de agua, y bordes de nubes y zonas urbanas. Concuerda con Slagter (2019) que también presenta ciertas confusiones en los bores de ciertas coberturas. De igual manera Candido et al., 2021 afirma en su investigación que a pesar del aumento en la precisión general y el coeficiente kappa, todavía existen errores entre los mapas de cobertura terrestre. Algunas clases de cobertura terrestre tienen un desempeño deficiente (clases de tierras forestales y arbustivas) en las métricas de precisión de clasificación (precisión de usuarios y productores, y medida f). La mayor parte de este bajo rendimiento se debe a la confusión de LightGBM entre las clases de cobertura de la tierra, como bosques y matorrales o pastizales y tierras cultivadas. Esto conduce a una estimación deficiente de las probabilidades de cobertura terrestre o a una detección deficiente de cambios, píxeles inciertos o sin cambios. Estas confusiones pueden atribuirse al hecho de que los bosques y los matorrales, así como los pastizales y las tierras cultivadas, presentan respuestas espectrales y temporales similares, lo que dificulta la separación de estas clases de cobertura terrestre (Yin et al., 2014). Esta observación entre las clases de vegetación concuerda con los hallazgos de Saah et al. (2020), en el que encontraron que las clases mixtas de bosques, huertos y plantaciones, matorrales y acuicultura produjeron las incertidumbres más altas de la simulación de Montecarlo.

6. Conclusiones

La plataforma GEE y los datos de la misión Sentinel-2 disponibles de manera gratuita, que ofrece la capacidad de acceder a un repositorio de imágenes satelitales como las de S-2 para ser consultadas sin necesidad de ser descargadas que por su parte una tienen una resolución espacial y temporal relativamente alta, a su vez pueden ser procesadas en la nube lo que hace más eficiente este proceso, por lo tanto, brindan una oportunidad única para un monitoreo de coberturas de la tierra más preciso desde el espacio en menor tiempo y con menores recursos. Esta investigación tuvo como objetivo implementar un proceso semiautomático para monitorear el cambio en la cobertura de la tierra con software y datos de libre acceso. Esto se hizo clasificando los datos de Sentinel-2 en la plataforma GEE mediante el clasificador de árboles aleatorios el rendimiento fue evaluado mediante la exactitud general con un 94% aunque al realizar una evaluación visual a detalle se encontraron ciertas imprecisiones en la clasificación de clases como caucho, cultivos forestales y bosques de galería.

A. Anexo: Script para el monitoreo del cambio de la cobertura en GEE

```
var roi = ee.FeatureCollection("users/sarubianos/SZH_R_YUCAO"),
    roi2 =
    /* color: #d63000 */
    /* shown: false */
    ee.Geometry.Point([-72.46545925567536, 4.07913611567874]),
    roi3 =
    /* color: #0b4a8b */
    /* shown: false */
    ee.Geometry.Point([-72.16496719147494, 4.321842254421517]),
    roi4 =
    /* color: #98ff00 */
    /* shown: false */
    ee.Geometry.Polygon(
        [[[-72.20135965840616, 4.2773352944134615],
          [-72.13578437118072, 4.306436228722387],
          [-72.19071640549402, 4.346833156872388],
          [-72.23843861477584, 4.3451214664198075],
          [-72.25938156257266, 4.291714865175091]]]),
    ndviParams = {"min":-1,"max":1,"palette":["Red","yellow","green"]},
    arbusto = ee.FeatureCollection("users/sarubianos/Pts_Arbustos"),
    bosque =
ee.FeatureCollection("users/sarubianos/Pts_BosqueGaleria"),
    cana = ee.FeatureCollection("users/sarubianos/Pts_CanaAzucar"),
    caucho = ee.FeatureCollection("users/sarubianos/Pts_Caucho"),
    agua = ee.FeatureCollection("users/sarubianos/Pts_CuerposAgua"),
    forestal = ee.FeatureCollection("users/sarubianos/Pts_Forestales"),
    palma = ee.FeatureCollection("users/sarubianos/Pts_Palma"),
    pasto = ee.FeatureCollection("users/sarubianos/Pts_Pastos"),
    residuos =
ee.FeatureCollection("users/sarubianos/Pts_ResiduosCana"),
    suelo = ee.FeatureCollection("users/sarubianos/Pts_SueloDesnudo"),
    urbano = ee.FeatureCollection("users/sarubianos/Pts_Urbano"),
    quema = ee.FeatureCollection("users/sarubianos/Pts_ZonasQuemadas"),
    nubes = ee.FeatureCollection("users/sarubianos/Pts_Nubes"),
    sombras = ee.FeatureCollection("users/sarubianos/Pts_Sombras");
/*////////////////////////////////////////////////////////////////
                          First Year 2022
*////////////////////////////////////////////////////////////////
```

```
var areaName = 'SubZona_Rio_Yucao';
var year = '2022';
var startDate = '2022-01-01';
var endDate = '2022-03-01';
var randomSeed = 0;

// Display in the console
print('Area' + " " + areaName +' ' + year);

//Add ROI to map
Map.addLayer(roi,{},'CuencaRioNegro');

//////////Sentinel-2 data//////////
var s2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filterBounds(roi);

var s2_r2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filterBounds(roi2);

// Get the dates of available images
var list = s2.aggregate_array('system:time_start').map(function(d) {
return ee.Date(d)});
print('S2 images of the area during the study period',list);

var list2 = s2_r2.aggregate_array('system:time_start').map(function(d)
{ return ee.Date(d)});
print('S2 images of the area during the study period',list);

// Get the cloud score of the images
var getCloudScores = function(img){
    var value = ee.Image(img).get('CLOUDY_PIXEL_PERCENTAGE');
    return ee.Feature(null, {'score': value});
};

var s2clouds = s2.map(getCloudScores);
print ('cloud score', ui.Chart.feature.byFeature(s2clouds));

var s2clouds2 = s2_r2.map(getCloudScores);
print ('cloud score 2', ui.Chart.feature.byFeature(s2clouds2));

// Sort images by least cloudy pixel %, select and rename the bands
var s2image = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',
10))
                    .sort('CLOUDY_PIXEL_PERCENTAGE')
                    .filterBounds(roi)
                    .map(function(img){
```

```
                        var t = img.select([
'B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12']).divide(10000);//Rescale to 0-1
                        var out =
t.copyProperties(img).copyProperties(img,['system:time_start']);
                      return out;
                        })

.select(['B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12'],['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2']);

var s2image2 = ee.ImageCollection('COPERNICUS/S2_SR')
                      .filterDate(startDate, endDate)
                      .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',
10))
                      .sort('CLOUDY_PIXEL_PERCENTAGE')
                      .filterBounds(roi2)
                      .map(function(img){
                        var t = img.select([
'B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12']).divide(10000);//Rescale to 0-1
                        var out =
t.copyProperties(img).copyProperties(img,['system:time_start']);
                      return out;
                        })

.select(['B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12'],['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2']);
/*
//Start CloudMasking

var s2Clouds = ee.ImageCollection('COPERNICUS/S2_CLOUD_PROBABILITY');
var MAX_CLOUD_PROBABILITY = 60;
//var roi1 = ee.Geometry.Point([-72.46545925567536, 4.07913611567874]);
function maskClouds(img) {
  var clouds = ee.Image(img.get('cloud_mask')).select('probability');
  var isNotCloud = clouds.lt(MAX_CLOUD_PROBABILITY);
  return img.updateMask(isNotCloud);
}
// The masks for the 10m bands sometimes do not exclude bad data at
// scene edges, so we apply masks from the 20m and 60m bands as well.
function maskEdges(s2_img) {
  return s2_img.updateMask(

s2_img.select('red4').mask().updateMask(s2_img.select('h2o').mask()));
}

// Filter input collections by desired data range and region.
var criteria = ee.Filter.and(
    ee.Filter.bounds(roi), ee.Filter.date(startDate, endDate));
```

```
var s2Sr = s2image.filter(criteria).map(maskEdges);
var s2Clouds = s2Clouds.filter(criteria);

// Join S2 SR with cloud probability dataset to add cloud mask.
var s2SrWithCloudMask = ee.Join.saveFirst('cloud_mask').apply({
  primary: s2Sr,
  secondary: s2Clouds,
  condition:
      ee.Filter.equals({leftField: 'system:index', rightField:
'system:index'})
});

var s2CloudMasked =
    ee.ImageCollection(s2SrWithCloudMask).map(maskClouds).median();
var rgbVis = {min: 0, max: 0.3, bands: ['red', 'green', 'blue']};

Map.addLayer(
    s2CloudMasked, rgbVis, 'S2 SR masked at ' + MAX_CLOUD_PROBABILITY +
'%',
    true);

//End Cloud Masking
*/

// Obtain the least cloudy image and clip to the ROI
var s2leastCloud1 = ee.Image(s2image.first());
var s2ROI1 = s2leastCloud1.clip(roi);
print('S2 image seleccted',s2leastCloud1);

var s2leastCloud2 = ee.Image(s2image2.first());
var s2ROI2 = s2leastCloud2.clip(roi2);
print('S2 image seleccted',s2leastCloud2);

//Make a Mosaic
var s2leastCloud =
ee.ImageCollection.fromImages([s2leastCloud1,s2leastCloud2]).mosaic();
var s2ROI = s2leastCloud.clip(roi);

var vizParams = {bands: ['red', 'green', 'blue'], min: 0, max: 0.3};
Map.addLayer(s2ROI, vizParams, 'S2 least cloudy');

// Compute the Normalized Difference Vegetation Index (NDVI)
var red = s2ROI.select('red');
var nir = s2ROI.select('nir');
var blue = s2ROI.select('blue');

var ndvi = nir.subtract(red).divide(nir.add(red)).rename('NDVI');

// Compute the EVI using an expression.
var evi = s2ROI.expression(
    '2.5 * ((NIR - RED) / (NIR + 6 * RED - 7.5 * BLUE + 1))', {
      'NIR': s2ROI.select('nir'),
```

```
      'RED': s2ROI.select('red'),
      'BLUE': s2ROI.select('blue')
}).rename('evi');

var evi_b5 = s2ROI.expression(
    '2.5 * ((NIR1 - RED) / (NIR1 + 6 * RED - 7.5 * BLUE + 1))', {
      'NIR1': s2ROI.select('red1'),
      'RED': s2ROI.select('red'),
      'BLUE': s2ROI.select('blue')
}).rename('evi_b5');

var ndviParams = {min: -1, max: 1, palette: ['Red', 'yellow',
'green']};
Map.addLayer(ndvi, ndviParams, 'NDVI', true);
Map.addLayer(evi, ndviParams, 'EVI', true);
Map.addLayer(evi_b5, ndviParams, 'EVI_B5', true);

// Compute standard deviation of NDVI as texture
var texture = ndvi.reduceNeighborhood({
  reducer: ee.Reducer.stdDev(),
  kernel: ee.Kernel.square(5),
});

Map.addLayer(texture, {min: 0, max: 0.25},'Texture', false);
print('texture',texture)

// Compute entropy of NDVI and NIR as texture
//Define a neighborhood with a kernel
//texture computed over 5 x 5
var ndvi8 =
nir.subtract(red).divide(nir.add(red)).rename('NDVI_entpy').unitScale(-
1, 1)
            .multiply(255).toByte();
var nir8 = s2ROI.select('nir').rename('NIR_entpy').unitScale(0,
1).multiply(255).toByte();
var square = ee.Kernel.square({radius: 5});
var entropy = ndvi8.entropy(square);
var entropy2 = nir8.entropy(square);

Map.addLayer(entropy,{min: 1, max:5},'Entropy');
Map.addLayer(entropy2,{min: 1, max:5},'Entropy2');

// Compute the gray-level co-occurrence matrix (GLCM), get contrast.
var glcm = nir8.glcmTexture({size: 3});
print('glcm',glcm);
var contrast = glcm.select('NIR_entpy_contrast');
print('constrast', contrast);
Map.addLayer(contrast,{min: 0, max: 1500},'contrast');

// Add NDVI and texture bands
var s2final =
ee.Image(s2ROI).addBands(ndvi).addBands(texture).addBands(entropy)
```

```
.addBands(entropy2).addBands(contrast).addBands(evi).addBands(evi_b5);
print('s2final',s2final);

// Add all the appropriate bands
var bands = ['aerosol', 'blue', 'green', 'red', 'red1', 'red2', 'red3',
'nir',
            'red4', 'h2o', 'swir1', 'swir2', 'NDVI', 'NDVI_stdDev',
            'NDVI_entpy', 'NIR_entpy',
'NIR_entpy_contrast','evi','evi_b5'];
var s2finalWbands = s2final.select(bands);

// Scale the image to 20m
var s2classification =
s2finalWbands.reproject(ee.Projection('EPSG:32617')
                .atScale(10)).reduceResolution({reducer:
ee.Reducer.mean(),maxPixels: 65535});

//////////create training and verification data//////////
// Assign random column to sample
var n = randomSeed;
var randomArbustos = arbusto.randomColumn('random', n);
var randomSombras = sombras.randomColumn('random', n);
var randomBosque = bosque.randomColumn('random', n);
var randomCana = cana.randomColumn('random', n);
var randomCaucho = caucho.randomColumn('random', n);
var randomAgua = agua.randomColumn('random', n);
var randomForestal = forestal.randomColumn('random', n);
var randomNubes = nubes.randomColumn('random', n);
var randomPalma = palma.randomColumn('random', n);
var randomPasto = pasto.randomColumn('random', n);
var randomResiduos = residuos.randomColumn('random', n);
var randomSuelos = suelo.randomColumn('random', n);
var randomUrbano = urbano.randomColumn('random', n);
var randomQuema = quema.randomColumn('random', n);

// 80:20 for training and testing
var split = 0.8;

var trainingSample =
 randomBosque.filter(ee.Filter.lte('random', split))
  .merge(randomArbustos.filter(ee.Filter.lt('random', split)))
  .merge(randomSombras.filter(ee.Filter.lt('random', split)))
  .merge(randomCana.filter(ee.Filter.lt('random', split)))
  .merge(randomCaucho.filter(ee.Filter.lt('random', split)))
  .merge(randomAgua.filter(ee.Filter.lt('random', split)))
  .merge(randomForestal.filter(ee.Filter.lt('random', split)))
  .merge(randomNubes.filter(ee.Filter.lt('random', split)))
  .merge(randomPalma.filter(ee.Filter.lt('random', split)))
  .merge(randomPasto.filter(ee.Filter.lt('random', split)))
  .merge(randomResiduos.filter(ee.Filter.lt('random', split)))
  .merge(randomSuelos.filter(ee.Filter.lt('random', split)))
```

```
  .merge(randomUrbano.filter(ee.Filter.lt('random', split)))
  .merge(randomQuema.filter(ee.Filter.lt('random', split)));

var testingSample = randomBosque.filter(ee.Filter.gte('random', split))
  .merge(randomArbustos.filter(ee.Filter.gte('random', split)))
  .merge(randomSombras.filter(ee.Filter.gte('random', split)))
  .merge(randomCana.filter(ee.Filter.gte('random', split)))
  .merge(randomCaucho.filter(ee.Filter.gte('random', split)))
  .merge(randomAgua.filter(ee.Filter.gte('random', split)))
  .merge(randomForestal.filter(ee.Filter.gte('random', split)))
  .merge(randomNubes.filter(ee.Filter.gte('random', split)))
  .merge(randomPalma.filter(ee.Filter.gte('random', split)))
  .merge(randomPasto.filter(ee.Filter.gte('random', split)))
  .merge(randomResiduos.filter(ee.Filter.gte('random', split)))
  .merge(randomSuelos.filter(ee.Filter.gte('random', split)))
  .merge(randomUrbano.filter(ee.Filter.gte('random', split)))
  .merge(randomQuema.filter(ee.Filter.gte('random', split)));

// Get the values for training
var training = s2classification.sampleRegions({
  collection: trainingSample,
  properties: ['ClassID'],
  scale: 10,
});

//////////classify and verify//////////
// Create the classifier
var classifier = ee.Classifier.smileRandomForest({
  numberOfTrees: 90,
  variablesPerSplit: 4
  })
    .train(training, 'ClassID');

//////Variable Importance of RF Classifier
var dict = classifier.explain();
  var explainTitle = 'Explain ' + areaName + ' :';
  print(explainTitle, dict);

  var variable_importance = ee.Feature(null,
ee.Dictionary(dict).get('importance'));

  // Chart of Variable Importance of RF Classifier
  var chartTitle = 'Random Forest Variable Importance for trees for ' +
areaName;
  var chart =
    ui.Chart.feature.byProperty(variable_importance)
      .setChartType('ColumnChart')
      .setOptions({
        title: chartTitle,
        legend: {position: 'none'},
        hAxis: {title: 'Bands'},
        vAxis: {title: 'Importance'}
```

```
      });
  print(chart);

// Classify the input imagery
var classified =
s2classification.classify(classifier,'classification');

// Create a palette to display the classes
var palette =['8be8a1',// Arbustos           1 (Verde claro)
              'ed09c3',// Palma              2 (Violeta)
              '09e0ce',// Caucho             3 (Azul Aguamarina)
              'FF7F00',// Caña               4 (Naranja)
              'ffff00',// Forestales         5 (Amarillo)
              '662e06',// Suelo Desnudo      6 (Cafe)
              '807c0f',// Pastos             7 (Amarillo Oscuro)
              'b02b13',// Zonas Quemadas     8 (Rojo)
              '0d7526',// Bosque de Galería 9 (Verde Oscuro)
              'ababa6',// Urbano             10 (Gris)
              'eced8e',// Residuos de Cosecha de Caña 11 (beish)
              '0000ff',// Cuerpos de Agua    12 (Azul)
              '202421',// Sombras            13 (Negro)
              'ffffff',// Nubes              14 (Blanco)
              ];

// Display the classified map
Map.addLayer(classified, {min: 1, max: 14, palette: palette},
'Classified');
Map.centerObject(roi, 15);

// Get a confusion matrix representing resubstitution accuracy
var trainAccuracy = classifier.confusionMatrix();
print('Resubstitution error matrix: ', trainAccuracy);
print('Training overall accuracy: ', trainAccuracy.accuracy());

// Sample the input to get validation data
var validation = s2classification.sampleRegions({
  collection: testingSample,
  properties: ['ClassID'],
  scale: 10,
});

// Classify the validation data
var validated = validation.classify(classifier);

// Get a confusion matrix representing expected accuracy
var testAccuracy = validated.errorMatrix('ClassID', 'classification');
print ('Validation accuracy exported to "Tasks"');
print('Validation error matrix: ', testAccuracy);
print('Validation overall accuracy: ', testAccuracy.accuracy());
print('Validation custumers accuracy: ',
testAccuracy.consumersAccuracy());
```

```
print('Validation producers accuracy: ',
testAccuracy.producersAccuracy());

var visualization = classified.visualize({palette: palette, min: 1,
max: 14});

// Create a legend
var labels = ['Arbustos','Palma de Aceite','Caucho', 'Caña de Azucar',
'Forestales', 'Suelo Desnudo'
              , 'Pastos', 'Zonas quemadas','Bosque de Galería',
'Contrucciones Urbanas',
              'Residuos de cosecha de caña','Cuerpos de
Agua','Sombras','Nubes'];

var add_legend = function(title, lbl, pal)
  {var legend = ui.Panel({style: {position: 'bottom-left'}}), entry;
    legend.add(ui.Label({value: title, style: { fontWeight: 'bold',
fontSize: '18px'
                                                , margin: '0 0 4px 0',
padding: '0px' } }));
   for (var x = 0; x < lbl.length; x++)
      {entry = [ ui.Label({style:{color: pal[x], border:'1px solid
black'
      , margin: '0 0 4px 0'}, value: '  '}), ui.Label({ value:
labels[x]
      , style: { margin: '0 0 4px 4px' } }) ];
      legend.add(ui.Panel(entry, ui.Panel.Layout.Flow('horizontal')));}
Map.add(legend);
  };

add_legend('Legend', labels, palette);

//////////////export results//////////////
var exportAccuracy = ee.Feature(null, {matrix: testAccuracy.array()});
var exportAccuracyNumber = ee.Feature(null, {matrix:
testAccuracy.accuracy()});

Export.table.toDrive({
  collection: ee.FeatureCollection(exportAccuracy),
  description: 'AccuracyMatrix'+'_'+areaName + year + '_'+ randomSeed,
  fileFormat: 'CSV'
});

//////////////export images//////////////
Export.image.toDrive({
  image: visualization,
  description: 'classifiedMap_colour'+'_'+areaName+year+'_'+
randomSeed,
  region: roi,
  crs: 'EPSG:32617',
  scale: 10
});
```

```
Export.image.toDrive({
  image: classified,
  description: 'classifiedMap_raster'+'_'+ areaName + year + '_'+
randomSeed,
  region: roi,
  crs: 'EPSG:32617',
  scale: 10
});

//////////Hyperparmeter Tuning/////////////
// Tune the numberOfTrees parameter

var numTreesList = ee.List.sequence(5,200,5)

var accuracies = numTreesList.map(function(numTrees){
  var classifier = ee.Classifier.smileRandomForest(numTrees)
      .train({
        features: training,
        classProperty:'ClassID',
        inputProperties: s2classification.bandNames()
      });
  return validation
    .classify(classifier)
    .errorMatrix('ClassID','classification')
    .accuracy();
});

var chart10= ui.Chart.array.values({
  array: ee.Array(accuracies),
  axis: 0,
  xLabels: numTreesList
  }).setOptions({
    title: 'Hyperparameter Tuning for the numberOfTrees Parameter',
    vAxis: {title: 'Validation Accuracy'},
    hAxis: {title: 'Number of trees', gridlines: {count:15}}
  });
print(chart10)

/////////chart wavelengths by class/////////
// Chart S2 spectral bands
var classifiedImage = classified.select(['classification']);
var bands1 = ['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2'];
var newImage = s2classification
    .select(bands1)
    .addBands(classifiedImage);
print('newImage',newImage);
var wavelengths = [0.443, 0.490, 0.560, 0.665, 0.705, 0.740, 0.783,
0.842, 0.865, 0.945, 1.610, 2.190];
var options = {
  lineWidth: 1,
```

```
  pointSize: 2,
  hAxis: {title: 'Wavelength (micrometers)'},
  vAxis: {title: 'Reflectance'},
  title: 'Spectra in Area'+ ' '+ areaName + ' '+ year,
  colors: [   '8be8a1',// Arbustos          1 (Verde claro)
              'ed09c3',// Palma             2 (Violeta)
              '09e0ce',// Caucho            3 (Azul Aguamarina)
              'FF7F00',// Caña              4 (Naranja)
              'ffff00',// Forestales        5 (Amarillo)
              '662e06',// Suelo Desnudo     6 (Cafe)
              '807c0f',// Pastos            7 (Amarillo Oscuro)
              'b02b13',// Zonas Quemadas    8 (Rojo)
              '0d7526',// Bosque de Galería 9 (Verde Oscuro)
              'ababa6',// Urbano            10 (Gris)
              'eced8e',// Residuos de Cosecha de Caña 11 (beish)
              '0000ff',// Cuerpos de Agua   12 (Azul)
              '202421',// Sombras           13 (Negro)
              'A9A9F5',// Nubes             14 (Blanco)
]};
var labels2 = ['Arbustos','Palma de Aceite','Caucho', 'Caña de Azucar',
'Forestales', 'Suelo Desnudo'
              , 'Pastos', 'Zonas quemadas','Bosque de Galería',
'Contrucciones Urbanas',
              'Residuos de cosecha de caña','Cuerpos de
Agua','Sombras','Nubes'];
var chart = ui.Chart.image.byClass(
    newImage, 'classification', roi4, ee.Reducer.mean() , 10, labels2,
wavelengths)
    .setOptions(options).setChartType('ScatterChart');
print(chart);

// Chart indices
var bands2 = ['NDVI','NDVI_stdDev','NDVI_entpy','NIR_entpy'];
var newImage2 = s2classification
    .select(bands2)
    .addBands(classifiedImage);

var newImage3 =
s2classification.select('NIR_entpy_contrast').addBands(classifiedImage)
;

var xaxis = ['NDVI',
'Text_NDVI_stdDev','Text_NDVI_entropy','Text_NIR_entropy'];
var options2 = {
  lineWidth: 1,
  pointSize: 2,
  title: 'NDVI and Textures indices in Area'+ ' ' + year,
  colors: ['8be8a1',// Arbusos          1 (Verde claro)
              'ed09c3',// Palma             2 (Violeta)
              '09e0ce',// Caucho            3 (Azul Aguamarina)
              'FF7F00',// Caña              4 (Naranja)
              'ffff00',// Forestales        5 (Amarillo)
```

```
                '662e06',// Suelo Desnudo      6 (Cafe)
                '807c0f',// Pastos             7 (Amarillo Oscuro)
                'b02b13',// Zonas Quemadas     8 (Rojo)
                '0d7526',// Bosque de Galería 9 (Verde Oscuro)
                'ababa6',// Urbano             10 (Gris)
                'eced8e',// Residuos de Cosecha de Caña 11 (beish)
                '0000ff',// Cuerpos de Agua    12 (Azul)
                '202421',// Sombras            13 (Negro)
                'A9A9F5',// Nubes              14 (Blanco)
]};

var chart2 = ui.Chart.image.byClass(
    newImage2, 'classification', roi4, ee.Reducer.mean(), 10, labels2,
xaxis)
    .setOptions(options2);
print(chart2);

var chart3 = ui.Chart.image.byClass(
    newImage3, 'classification', roi4, ee.Reducer.mean(), 10, labels2,
['NIR_entpy_contrast'])
    .setOptions(options2);
print(chart3);


/*////////////////////////////////////////////////////////////////
                    Second Year 2019
*////////////////////////////////////////////////////////////////

var areaName = 'SubZona Rio Yucao';
var year = '2019';
var startDate = '2019-01-01';
var endDate = '2019-02-20';
var randomSeed = 0;

// Display in the console
print('Area' + " " + areaName +' ' + year);

/////////Sentinel-2 data/////////
var s2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filterBounds(roi);

var s2_r2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filterBounds(roi2);

// Get the dates of available images
var list = s2.aggregate_array('system:time_start').map(function(d) {
return ee.Date(d)});
print('S2 images of the area during the study period',list);
```

```
var list2 = s2_r2.aggregate_array('system:time_start').map(function(d)
{ return ee.Date(d)});
print('S2 images of the area during the study period',list);

// Get the cloud score of the images
var getCloudScores = function(img){
    var value = ee.Image(img).get('CLOUDY_PIXEL_PERCENTAGE');
    return ee.Feature(null, {'score': value});
};

var s2clouds = s2.map(getCloudScores);
print ('cloud score', ui.Chart.feature.byFeature(s2clouds));

var s2clouds2 = s2_r2.map(getCloudScores);
print ('cloud score 2', ui.Chart.feature.byFeature(s2clouds2));

// Sort images by least cloudy pixel %, select and rename the bands
var s2image = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',
10))
                    .sort('CLOUDY_PIXEL_PERCENTAGE')
                    .filterBounds(roi)
                    .map(function(img){
                      var t = img.select([
'B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12']).divide(10000);//Rescale to 0-1
                      var out =
t.copyProperties(img).copyProperties(img,['system:time_start']);
                    return out;
                      })

.select(['B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12'],['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2']);

var s2image2 = ee.ImageCollection('COPERNICUS/S2_SR')
                    .filterDate(startDate, endDate)
                    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',
10))
                    .sort('CLOUDY_PIXEL_PERCENTAGE')
                    .filterBounds(roi3)
                    .map(function(img){
                      var t =
img.select(['B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
'B11','B12']).divide(10000);//Rescale to 0-1
                      var out =
t.copyProperties(img).copyProperties(img,['system:time_start']);
                    return out;
                      })

.select(['B1','B2','B3','B4','B5','B6','B7','B8','B8A', 'B9',
```

```
'B11','B12'],['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2']);

// Obtain the least cloudy image and clip to the ROI
var s2leastCloud1 = ee.Image(s2image.first());
var s2ROI1 = s2leastCloud1.clip(roi);
print('S2 image seleccted',s2leastCloud1);

var s2leastCloud2 = ee.Image(s2image2.first());
var s2ROI2 = s2leastCloud2.clip(roi);
print('S2 image seleccted',s2leastCloud2);

//Make a Mosaic
var s2leastCloud =
ee.ImageCollection.fromImages([s2leastCloud1,s2leastCloud2]).mosaic();
var s2ROI = s2leastCloud.clip(roi);

var vizParams = {bands: ['red', 'green', 'blue'], min: 0, max: 0.3};
Map.addLayer(s2ROI, vizParams, 'S2 least cloudy2');

// Compute the Normalized Difference Vegetation Index (NDVI)
var red = s2ROI.select('red');
var nir = s2ROI.select('nir');
var blue = s2ROI.select('blue');

var ndvi = nir.subtract(red).divide(nir.add(red)).rename('NDVI');

// Compute the EVI using an expression.
var evi = s2ROI.expression(
    '2.5 * ((NIR - RED) / (NIR + 6 * RED - 7.5 * BLUE + 1))', {
      'NIR': s2ROI.select('nir'),
      'RED': s2ROI.select('red'),
      'BLUE': s2ROI.select('blue')
}).rename('evi');

var evi_b5 = s2ROI.expression(
    '2.5 * ((NIR1 - RED) / (NIR1 + 6 * RED - 7.5 * BLUE + 1))', {
      'NIR1': s2ROI.select('red1'),
      'RED': s2ROI.select('red'),
      'BLUE': s2ROI.select('blue')
}).rename('evi_b5');

var ndviParams = {min: -1, max: 1, palette: ['Red', 'yellow',
'green']};
Map.addLayer(ndvi, ndviParams, 'NDVI', false);
Map.addLayer(evi, ndviParams, 'EVI', false);
Map.addLayer(evi_b5, ndviParams, 'EVI_B5', false);

// Compute standard deviation of NDVI as texture
var texture = ndvi.reduceNeighborhood({
  reducer: ee.Reducer.stdDev(),
  kernel: ee.Kernel.square(5),
```

```
});

Map.addLayer(texture, {min: 0, max: 0.25},'Texture', false);

// Compute entropy of NDVI and NIR as texture
//Define a neighborhood with a kernel
//texture computed over 5 x 5
var ndvi8 =
nir.subtract(red).divide(nir.add(red)).rename('NDVI_entpy').unitScale(-
1, 1)
            .multiply(255).toByte();
var nir8 = s2ROI.select('nir').rename('NIR_entpy').unitScale(0,
1).multiply(255).toByte();
var square = ee.Kernel.square({radius: 5});
var entropy = ndvi8.entropy(square);
var entropy2 = nir8.entropy(square);

Map.addLayer(entropy,{min: 1, max:5},'Entropy');
Map.addLayer(entropy2,{min: 1, max:5},'Entropy2');

// Compute the gray-level co-occurrence matrix (GLCM), get contrast.
var glcm = nir8.glcmTexture({size: 3});
print('glcm',glcm);
var contrast = glcm.select('NIR_entpy_contrast');
print('constrast', contrast);
//Map.addLayer(contrast,{min: 0, max: 1500, palette: ['0000CC',
'CC0000']},'contrast');
Map.addLayer(contrast,{min: 0, max: 1500},'contrast');

// Add NDVI and texture bands
var s2final =
ee.Image(s2ROI).addBands(ndvi).addBands(texture).addBands(entropy)

.addBands(entropy2).addBands(contrast).addBands(evi).addBands(evi_b5);
print('s2final',s2final);

// Add all the appropriate bands
var bands = ['aerosol', 'blue', 'green', 'red', 'red1', 'red2', 'red3',
'nir',
            'red4', 'h2o', 'swir1', 'swir2', 'NDVI', 'NDVI_stdDev',
            'NDVI_entpy', 'NIR_entpy',
'NIR_entpy_contrast','evi','evi_b5'];
var s2finalWbands2 = s2final.select(bands);

// Scale the image to 20m
var s2classification2 =
s2finalWbands2.reproject(ee.Projection('EPSG:32617')
                .atScale(10)).reduceResolution({reducer:
ee.Reducer.mean(),maxPixels: 65535});

// Classify the input imagery
```

```
var classified2 =
s2classification2.classify(classifier,'classification');

// Display the classified map
Map.addLayer(classified2, {min: 1, max: 14, palette: palette},
'Classified2');
Map.centerObject(roi, 15);

var visualization2 = classified2.visualize({palette: palette, min: 1,
max: 14});

//////////////export images//////////////
Export.image.toDrive({
  image: visualization2,
  description: 'classifiedMap_colour'+'_'+areaName + year + '_'+
randomSeed,
  region: roi,
  crs: 'EPSG:32617',
  scale: 10
});

Export.image.toDrive({
  image: classified2,
  description: 'classifiedMap_raster'+'_'+areaName + year + '_'+
randomSeed,
  region: roi,
  crs: 'EPSG:32617',
  scale: 10
});

//////////chart wavelengths by class/////////
// Chart S2 spectral bands
var classifiedImage = classified2.select(['classification']);
var bands1 = ['aerosol', 'blue', 'green', 'red',
'red1','red2','red3','nir','red4','h2o','swir1', 'swir2'];
var newImage = s2classification2
    .select(bands1)
    .addBands(classifiedImage);
print('newImage',newImage);
var wavelengths = [0.443, 0.490, 0.560, 0.665, 0.705, 0.740, 0.783,
0.842, 0.865, 0.945, 1.610, 2.190];
var options = {
  lineWidth: 1,
  pointSize: 2,
  hAxis: {title: 'Wavelength (micrometers)'},
  vAxis: {title: 'Reflectance'},
  title: 'Spectra in Area'+ ' ' + year,
  colors: [   '8be8a1',// Arbusos          1 (Verde claro)
              'ed09c3',// Palma            2 (Violeta)
              '09e0ce',// Caucho           3 (Azul Aguamarina)
              'FF7F00',// Caña             4 (Naranja)
              'ffff00',// Forestales       5 (Amarillo)
```

```
                '662e06',// Suelo Desnudo      6 (Cafe)
                '807c0f',// Pastos             7 (Amarillo Oscuro)
                'b02b13',// Zonas Quemadas     8 (Rojo)
                '0d7526',// Bosque de Galería 9 (Verde Oscuro)
                'ababa6',// Urbano             10 (Gris)
                'eced8e',// Residuos de Cosecha de Caña 11 (beish)
                '0000ff',// Cuerpos de Agua    12 (Azul)
                '202421',// Sombras            13 (Negro)
                'A9A9F5',// Nubes              14 (Blanco)
]};

var chart = ui.Chart.image.byClass(
    newImage, 'classification', roi4, ee.Reducer.mean() , 10, labels,
wavelengths)
    .setOptions(options).setChartType('ScatterChart');
print(chart);

// Chart indices
var bands2 = ['NDVI','NDVI_stdDev','NDVI_entpy','NIR_entpy'];
var newImage2 = s2classification2
    .select(bands2)
    .addBands(classifiedImage);

var newImage3 =
s2classification2.select('NIR_entpy_contrast').addBands(classifiedImage
);

var xaxis = ['NDVI',
'Text_NDVI_stdDev','Text_NDVI_entropy','Text_NIR_entropy'];
var options2 = {
  lineWidth: 1,
  pointSize: 2,
  title: 'NDVI and Textures indices in Area'+ ' ' + year,
  colors: [   '8be8a1',// Arbusos           1 (Verde claro)
              'ed09c3',// Palma              2 (Violeta)
              '09e0ce',// Caucho             3 (Azul Aguamarina)
              'FF7F00',// Caña               4 (Naranja)
              'ffff00',// Forestales         5 (Amarillo)
              '662e06',// Suelo Desnudo      6 (Cafe)
              '807c0f',// Pastos             7 (Amarillo Oscuro)
              'b02b13',// Zonas Quemadas     8 (Rojo)
              '0d7526',// Bosque de Galería 9 (Verde Oscuro)
              'ababa6',// Urbano             10 (Gris)
              'eced8e',// Residuos de Cosecha de Caña 11 (beish)
              '0000ff',// Cuerpos de Agua    12 (Azul)
              '202421',// Sombras            13 (Negro)
              'A9A9F5',// Nubes              14 (Blanco)
]};

var chart2 = ui.Chart.image.byClass(
    newImage2, 'classification', roi4, ee.Reducer.mean(), 10, labels,
xaxis)
```

```
    .setOptions(options2);
print(chart2);

var chart3 = ui.Chart.image.byClass(
    newImage3, 'classification', roi4, ee.Reducer.mean(), 10, labels,
['NIR_entpy_contrast'])
    .setOptions(options2);
print(chart3);
```

Bibliografía

Aber, S. E. W., & Aber, J. W. (2017). Chapter 5 - Terrain Mapping Meets Digital Data. In S. E. W. Aber & J. W. Aber (Eds.), Map Librarianship (pp. 87–94).

Arvor, D., Durieux, L., Andrés, S., & Laporte, M. A. (2013). Advances in Geographic Object-Based Image Analysis with ontologies: A review of main contributions and limitations from a remote sensing perspective. ISPRS Journal of Photogrammetry and Remote Sensing, 82, 125–137. https://doi.org/10.1016/j.isprsjprs.2013.05.003

Bovolo, F., Bruzzone, L., & Solano-Correa, Y. T. (2017). Multitemporal Analysis of Remotely Sensed Image Data. In Comprehensive Remote Sensing. https://doi.org/10.1016/b978-0-12-409548-9.10338-0

Brodley, C. E., & Friedl, M. A. (1997). Decision tree classification of land cover from remotely sensed data. Remote Sensing of Environment, 61(3), 399–409. https://doi.org/10.1016/S0034-4257(97)00049-7

Buzai, G. (2012). Geográfica Evolución Teórico-Metodológica Hacia Geography and Geographic Information Theoretical and Methodological. In Revista geográfica de América Central (Vol. 2).

Champion, N., Boldo, D., Pierrot-Deseilligny, M., & Stamon, G. (2010). 2D building change detection from high resolution satelliteimagery: A two-step hierarchical method based on 3D invariant primitives. Pattern Recognition Letters, 31(10), 1138–1147. https://doi.org/10.1016/j.patrec.2009.10.012

Cheng, G., & Han, J. (2016). A survey on object detection in optical remote sensing images. ISPRS Journal of Photogrammetry and Remote Sensing, 117, 11–28. https://doi.org/10.1016/j.isprsjprs.2016.03.014

Chuvieco, E. (2010). Fundamentos de teledetección. International Journal of Remote Sensing.

DeFries, R. (2013). Remote Sensing and Image Processing. In S. A. Levin (Ed.), Encyclopedia of Biodiversity (Second Edition) (Second Edition, pp. 389–399). https://doi.org/https://doi.org/10.1016/B978-0-12-384719-5.00383-X

DeFries, R. S., & Townshend, J. R. (1994). NDVI-derived Land Cover Classifications At a Global Scale. International Journal of Remote Sensing, 15(17), 3567–3586. https://doi.org/10.1080/01431169408954345

Dronova, I. (2015). Object-based image analysis in wetland research: A review. Remote Sensing, 7(5), 6380–6413. https://doi.org/10.3390/rs70506380

Duan, M., Song, X., Liu, X., Cui, D., & Zhang, X. (2022). Mapping the soil types combining multi-temporal remote sensing data with texture features. Computers and Electronics in Agriculture, 200, 107230. https://doi.org/https://doi.org/10.1016/j.compag.2022.107230

Eastman, J. R. (2001). Guide to GIS and Image Processing. Clark University, USA.

Gamanya, R., De Maeyer, P., & De Dapper, M. (2007). An automated satellite image classification design using object-oriented segmentation algorithms: A move towards standardization. Expert Systems with Applications, 32(2), 616–624. https://doi.org/10.1016/j.eswa.2006.01.055

Garcia-Gutierrez, J., Gonalves-Seco, L., & Riquelme-Santos, J. C. (2011). Automatic environmental quality assessment for mixed-land zones using lidar and intelligent techniques. Expert Systems with Applications, 38(6), 6805–6813. https://doi.org/10.1016/j.eswa.2010.12.065

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote Sensing of Environment, 202, 18–27. https://doi.org/https://doi.org/10.1016/j.rse.2017.06.031

Grekousis, G. (2019). Artificial neural networks and deep learning in urban geography: A systematic review and meta-analysis. Computers, Environment and Urban Systems, 74(September 2018), 244–256. https://doi.org/10.1016/j.compenvurbsys.2018.10.008

Groover, M. (2010). Fundementals of Modern Manufacturing Materials,Processes and Systems. John Wiley & Sons, 493.

Henderson, F. M., & Lewis, A. J. (2008). Radar detection of wetland ecosystems: A review. International Journal of Remote Sensing, 29(20), 5809–5835. https://doi.org/10.1080/01431160801958405

Jensen, J. R. (2016). Introductory Digital Image Processing: A Remote Sensing Perspective (4th ed., Vol. 4, Issue 1). Pearson.

Jiménez, M., González, M., Escalona, M., Valdez, J. R., & Aguirre, C. (2011). Comparación De Métodos Espaciales Para Detectar Cambios En El Uso Del Suelo Urbano. Revista Chapingo Serie Ciencias Forestales y Del Ambiente, 17(3), 389–406. https://doi.org/dx.doi.org/10.5154/r.rchscfa.2010.04.020

Khorram, S., Koch, F., van der Wiele, C. & Nelson S. (2012). Remote Sensing. Springer Science & Business Media. CRC Press. ISBN: 9781420008975

Knox, S. W. (2018). Machine learning: a concise introduction. In WILEY (Vol. 1).

Kumar, U. (2006). Comparative Evaluation of the Algorithms for Land Cover Mapping using Hyperspectral Data. International Institute for Geoinformation Science and Earth Observation.

Li, Y., Dang, B., Zhang, Y., & Du, Z. (2022). Water body classification from high-resolution optical remote sensing imagery: Achievements and perspectives. ISPRS Journal of Photogrammetry and Remote Sensing, 187, 306–327. https://doi.org/https://doi.org/10.1016/j.isprsjprs.2022.03.013

Liang, S., & Wang, J. (Eds.). (2020). Chapter 1 - A systematic view of remote sensing. In Advanced Remote Sensing (Second Edition) (Second Edition, pp. 1–57). https://doi.org/https://doi.org/10.1016/B978-0-12-815826-5.00001-5

Liu, B., Huang, B., & Zhang, W. (2017). Spatio-temporal analysis and optimization of land use/cover change: Shenzhen as a Case Study. CRC Press. http://library1.nida.ac.th/termpaper6/sd/2554/19755.pdf

Lu, D., Mausel, P., Brondízio, E., & Moran, E. (2004). Change detection techniques. International Journal of Remote Sensing. https://doi.org/10.1080/0143116031000139863

Mahdavi, S., Salehi, B., Amani, M., Granger, J., Brisco, B., & Huang, W. (2019). A dynamic classification scheme for mapping spectrally similar classes: Application to wetland classification. International Journal of Applied Earth Observation and Geoinformation, 83(January), 101914. https://doi.org/10.1016/j.jag.2019.101914

Mas, J. F., Lemoine-Rodríguez, R., González-López, R., López-Sánchez, J., Piña-Garduño, A., & Herrera-Flores, E. (2017). Land use/land cover change detection combining automatic processing and visual interpretation. European Journal of Remote Sensing, 50(1), 626-635.

Moher, D., Liberati, A., Tetzlaff, J., & Altman, D. G. (2009). Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. Journal of Clinical Epidemiology. https://doi.org/10.1016/j.jclinepi.2009.06.005

Moreno, E. G. (1999). Automatización de procesos industriales. Robótica y Automática. 43.

Müller, A. C., & Guido, S. (2016). Introduction to machine learning with Python: a guide for data scientists. In O'Reilly Media, Inc.

Nalli, N. R., & Kalluri, S. (2023). Chapter 1 - Introduction: Field measurements and remote sensing. In N. R. Nalli (Ed.), Field Measurements for Passive Environmental Remote Sensing (pp. 1–20). https://doi.org/https://doi.org/10.1016/B978-0-12-823953-7.00002-2

Neapolitan, R. E., & Jiang, X. (2018). Artificial Intelligence with an Introduction to Machine Learning. In Chapman and Hall/CRC.

Noi, P. T., & Kappas, M. (2018). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using sentinel-2 imagery. Sensors (Switzerland), 18(1). https://doi.org/10.3390/s18010018

Read, J. M., Chambers, C., & Torrado, M. (2020). Remote Sensing. In A. Kobayashi (Ed.), International Encyclopedia of Human Geography (Second Edition) (Second Edition, pp. 411–422). https://doi.org/https://doi.org/10.1016/B978-0-08-102295-5.10589-X

Rebala, G., Ravi, A., & Churiwala, S. (2019). An Introduction to Machine Learning. In An Introduction to Machine Learning. https://doi.org/10.1007/978-3-030-15729-6

Rifkin, J. (1996). The End of Work: The Decline of the Global Labor Force and the Dawn of the Post-Market Era. New York: G. P. Putnam's Sons.

Rodríguez, A., Rubiano, Y., Gutiérrez, A. J. ., Bernal, J., Rodríguez, N., Arguello, O., & Pulido, S. (2013). Cobertura vegetal y usos del suelo de la altillanura plana de los municipios de Puerto López y Puerto Gaitán, Meta: escala 1:25.000. Villavicencio (Colombia): CORPOICA.

Santana, L. M., & Salas, J. (2007). Análisis de cambios en la ocupación del suelo ocurridos en sabanas de Colombia entre 1987 y 2001, usando imágenes LANDSAT. GeoFocus, 7, 281–313.

Segarra, J., Buchaillot, M. L., Araus, J. L., & Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. Agronomy, 10(5), 641.

Selvam, S., Manisha, A., Vidhya, J., & Venkatramanan, S. (2019). Chapter 1 - Fundamentals of GIS. In S. Venkatramanan, M. V. Prasanna, & S. Y. Chung (Eds.), GIS and Geostatistical Techniques for Groundwater Science (pp. 3–15). https://doi.org/https://doi.org/10.1016/B978-0-12-815413-7.00001-8

Selvaraj, R., & Nagarajan, S. (2022). Chapter 6 - Change detection techniques for a remote sensing application: An overview. In Y.-D. Zhang & A. K. Sangaiah (Eds.), Cognitive Systems and Signal Processing in Image Processing (pp. 129–143). https://doi.org/https://doi.org/10.1016/B978-0-12-824410-4.00015-5

Srivastava, P. K., Prasad, R., Chaudhary Kumar, S., Yadav, S. A., Sharma, J., Suman, S., … Gupta, D. K. (2022). Chapter 20 - Challenges in Radar remote sensing. In P. K. Srivastava, D. K. Gupta, T. Islam, D. Han, & R. Prasad (Eds.), Radar Remote Sensing (pp. 377–387). https://doi.org/https://doi.org/10.1016/B978-0-12-823457-0.00020-3

Sullivan, W. (2017). Machine learning For Beginners Guide Algorithms: Supervised & Unsupervised learning, Decision Tree & Random Forest Introduction. CreateSpace Independent Publishing Platform.

Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). ISPRS Journal of Photogrammetry and Remote Sensing Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. ISPRS Journal of Photogrammetry and Remote Sensing, 164(April), 152–170. https://doi.org/10.1016/j.isprsjprs.2020.04.001

Teodoro, A. C., & Duarte, L. (2022). Chapter 11 - The synergy of remote sensing and geographical information systems in the management of natural disasters. In A. Denizli, M. S. Alencar, T. A. Nguyen, & D. E. Motaung (Eds.), Nanotechnology-Based Smart Remote Sensing Networks for Disaster Prevention (pp. 217–230). https://doi.org/https://doi.org/10.1016/B978-0-323-91166-5.00023-9

Wang, M., Wander, M., Mueller, S., Martin, N., & Dunn, J. B. (2022). Evaluation of survey and remote sensing data products used to estimate land use change in the United States: Evolving issues and emerging opportunities. Environmental Science & Policy, 129, 68–78. https://doi.org/https://doi.org/10.1016/j.envsci.2021.12.021

Zhou, W. (2021). GIS for Earth Sciences. In D. Alderton & S. A. Elias (Eds.), Encyclopedia of Geology (Second Edition) (Second Edition, pp. 281–293). https://doi.org/https://doi.org/10.1016/B978-0-08-102908-4.00018-7

Zhu, Z., Woodcock, C. E., & Olofsson, P. (2012). Continuous monitoring of forest disturbance using all available Landsat imagery. Remote Sensing of Environment, 122, 75–91. https://doi.org/10.1016/j.rse.2011.10.030