



**Guía para la identificación de las áreas sembradas en palma de aceite, a partir del uso de la plataforma de Google Earth Engine (Estudio de caso: municipio de Maní – Casanare).**

**Diana Patricia Mera Garzón**

Código 11792314797

**Universidad Antonio Nariño**

Programa Especialización en Sistemas de Información Geográfica

Facultad de Ingeniería Ambiental y Civil

Bogotá, Colombia

2023



**Guía para la identificación de las áreas sembradas en palma de aceite, a partir  
del uso de la plataforma de Google Earth Engine (Estudio de Caso: municipio de  
Maní – Casanare)**

**Diana Patricia Mera Garzón**

Proyecto de grado presentado como requisito parcial para optar al título de:  
**Especialización en Sistemas de Información Geográfica**

Director:

Andrés Felipe Carvajal Vanegas, Dr.

**Universidad Antonio Nariño**

Programa Especialización en Sistemas de Información Geográfica

Facultad de Ingeniería Ambiental y Civil

Bogotá, Colombia

2023

## Contenido

	Pág.
Resumen.....	3
Abstract.....	4
Introducción .....	5
Objetivos .....	6
1. Marco conceptual .....	7
2. Metodología.....	17
3. Resultados.....	22
Conclusiones .....	39
Recomendaciones .....	40

## Lista de Figuras

	Pág.
<b>Figura 1.</b> (a) <i>Patrón de siembra para una plantación de palma aceitera</i> ; (b) <i>Imagen satelital</i> ; (c) <i>Imagen Dron</i> . <b>Fuente:</b> Adaptada de (Chong et al., 2017).....	7
<b>Figura 2.</b> Clasificación Machine Learning. Adaptado de (VAS3K, 2023).....	15
<b>Figura 3.</b> Taxonomía de algoritmos de clasificación de imágenes. Adaptado de (Sheykhmousa et al., 2020). .....	16
<b>Figura 4.</b> Metodología para la identificación de áreas sembradas en palma de aceite. <b>Fuente:</b> Elaboración propia .....	17
<b>Figura 5.</b> Plataforma NICFI, con GEE – <i>Tomada 12 de octubre de 2023</i> .....	18
<b>Figura 6.</b> Imágenes Sentinel 2A – Programa Copernicus. <i>Tomada 12 de octubre de 2023</i> . .....	19
<b>Figura 7.</b> Visualización del código de clasificación supervisada en GEE.....	20
<b>Figura 8.</b> Ortofotomosaico de imágenes Sentinel 2A-L2, para el I-2023.....	22
<b>Figura 9.</b> Código para la generación de Ortofotomosaico de las imágenes Sentinel 2A -L2.....	23
<b>Figura 10.</b> Datos de entrenamiento y coberturas establecidas para la Clasificación Supervisada.....	23
<b>Figura 11.</b> Función de Clasificación de datos de entrenamiento .....	24
<b>Figura 12.</b> Código para unificar los datos de entrenamiento .....	24
<b>Figura 13.</b> Código para la selección aleatorio del 80% de los datos de entrenamiento .....	25
<b>Figura 14.</b> Código del modelo de clasificación, usando la imagen Sentinel 2A -L2.....	26
<b>Figura 15.</b> Función de la Matriz de Confusión y Precisión General del Modelo .....	26
<b>Figura 16.</b> Resultados de la Matriz de Confusión y la Precisión General .....	26
<b>Figura 17.</b> Código para exportar a Google Drive, la capa ráster clasificada. ....	27
<b>Figura 18.</b> Resultados de la clasificación de cobertura, según la metodología empleada. ....	27
<b>Figura 19.</b> Código para realizar el clip del Municipio de Maní – Casanare .....	27
<b>Figura 20.</b> Corte de la clasificación del municipio de Maní - Casanare .....	28
<b>Figura 21.</b> Código de clasificar y exportar el nuevo raster Reclasificado .....	29
<b>Figura 22.</b> Identificación de las zonas sembradas con Palma de Aceite en Maní – Casanare.....	30
<b>Figura 23.</b> Código para crear y descargar mosaico de imágenes Planet Scopus .....	31
<b>Figura 24.</b> Ortofotomosaico de imágenes Planet Scopus, para el I-2023 en Maní - Casanare....	31
<b>Figura 25.</b> Visualización del código de clasificación supervisada en GEE.....	32
<b>Figura 26.</b> Funciones para subir un shape file, dentro de GEE .....	33
<b>Figura 27.</b> Geoprocessing – Raster To Polygon de las Zonas Sembradas en Palma de Aceite...	34
<b>Figura 28.</b> Visualización de las áreas sembradas en Palma de Aceite.....	34
<b>Figura 29.</b> Estructuración de ajuste y edición cartográfica de las áreas en Palma de Aceite .....	35
<b>Figura 30.</b> Clasificación según Tamaño de Plantación de Maní - Casanare.....	37
<b>Figura 31.</b> Identificación de las áreas sembradas en Palma de Aceite en el Municipio de Maní – Casanare, para el periodo I-2023 .....	38

## Lista de tablas

	<b>Pág.</b>
<b>Tabla 1.</b> Subconjunto de muestras de entrenamiento para Clasificación Supervisada -RF.....	24
<b>Tabla 2.</b> Características de las Bandas de las Imágenes Sentinel 2A (Chuvieco, 2016). .....	25
<b>Tabla 3.</b> Valores de Reclasificación.....	28
<b>Tabla 4.</b> Metodología para la clasificación de proveedores de la planta de beneficio (Motta, 2007). .....	36
<b>Tabla 5.</b> Cuantificación de las áreas de Palma de Aceite según Clasificación Cenipalma.....	36

## Resumen

Este documento ofrece una visión general del código JavaScript utilizado en la plataforma Google Earth Engine (GEE) y funciona como una Guía Metodológica para la Identificación de áreas de cultivo de Palma Aceitera mediante métodos de clasificación supervisada con Random Forest. La guía detalla los procedimientos paso a paso y recomienda funciones específicas. Además, el código fuente se encuentra disponible al público, facilitando así su acceso y la posibilidad de reproducción por parte de otros usuarios de Sistemas de Información Geográfica (SIG).

Las fuentes de datos clave utilizadas en esta guía incluyen imágenes de Sentinel 2A - L2, acceso a la plataforma GEE, ortofotomosaicos derivados de imágenes de Planet Scope, y procesos de edición y ajuste cartográfico realizados mediante ArcGIS Pro.

Aunque el estudio de caso presentado en esta guía se enfoca en el municipio de Maní - Casanare, su aplicación es viable en otras partes del país o regiones donde se tengan disponibles imágenes fundamentales (Sentinel 2A y Planet Scope) y donde sea posible observar el cultivo de palma de aceite.

La elección de la plataforma GEE se basa en su capacidad para proporcionar procesamiento espacial escalable en la nube y su acceso gratuito y público a una amplia variedad de datos multitemporales de teledetección para fines de análisis geoespacial. La potencia computacional de esta plataforma y el desarrollo de algoritmos en la nube contribuyen en gran medida a la automatización de procesos.

La guía también incluye una breve descripción de varios métodos de Inteligencia Artificial (IA) que desempeñan un papel fundamental en la automatización de la interpretación de imágenes satelitales, especialmente en aplicaciones basadas en objetos. La integración de métodos de IA en GEE representa un avance significativo en programas automatizados de seguimiento de cultivos.

Las ventajas ofrecidas por la plataforma GEE han permitido la creación de esta Guía Metodológica para la identificación de áreas de cultivo de palma aceitera y la cuantificación de la extensión de este cultivo. Esto contribuye a la difusión de metodologías y al acceso abierto al conocimiento.

## **Abstract**

This document provides a comprehensive overview of the JavaScript code used within the Google Earth Engine (GEE) platform and serves as a Methodological Guide for the Identification of Oil Palm cultivation areas using supervised classification methods with Random Forest. The guide outlines detailed step-by-step procedures and recommends specific functions. Furthermore, the source code is made available to the public, simplifying access and enabling reproduction by other users of Geographic Information Systems (GIS).

Key data sources used in this guide encompass Sentinel 2A - L2 imagery, access to the GEE platform, orthophotomosaics derived from Planet Scope imagery, as well as cartographic editing and adjustment processes conducted through ArcGIS Pro.

While the case study presented in this guide primarily centers on the municipality of Maní - Casanare, its applicability extends to other regions or areas within the country where essential imagery sources (Sentinel 2A and Planet Scope) are accessible, and where oil palm cultivation can be observed.

The selection of the GEE platform is driven by its capability to deliver scalable spatial processing in the cloud and its provision of free and public access to a diverse range of multi-temporal remote sensing data for geospatial analysis purposes. The computational power of this platform, along with cloud-based algorithm development, significantly contributes to process automation.

The guide also incorporates a brief description of various Artificial Intelligence (AI) methods, which play a crucial role in automating the interpretation of satellite images, particularly in object-based applications. The integration of AI methods within GEE represents a substantial advancement in automated crop monitoring programs.

The advantages offered by the GEE platform have enabled the creation of this Methodological Guide for identifying oil palm cultivation areas and quantifying their extent. This contributes to the dissemination of methodologies and promotes open access to knowledge.



## Introducción

La Palma Aceitera es el segundo cultivo oleaginoso más cultivado en el mundo después de la soja, con más de 23 millones de hectáreas cultivadas en todo el mundo; se ha vuelto crucial para la economía de muchos países. En Colombia, es uno de los sectores agrícolas más desarrollados, y cada año el sector impulsa el desarrollo de tecnologías que conlleven a una mayor sostenibilidad de los sistemas agrícolas y alimentarios, y aborden los desafíos y oportunidades de los agronegocios (Arias et al., 2023).

El aceite de palma se ha convertido en un producto esencial y su creciente demanda está asociada con su requerimiento en las industrias de alimentos, cosméticos, jabones, farmacéutica y biocombustibles (Azhar et al., 2017). En consecuencia, se prevé que la demanda para 2050 sea de 240 millones de toneladas por año. Este agronegocio ha impulsado un rápido crecimiento económico en varios países tropicales (Ibragimov et al., 2019).

Colombia es el mayor productor de aceite de palma de América Latina y el cuarto productor a nivel mundial, aportando el 2,2 % (1,7 MnT) del aceite de palma mundial en comparación con Malasia e Indonesia, que en conjunto producen el 82,3 % (64,9 MnT)(Oil World, 2023). Con 600.000 hectáreas sembradas, la palma aceitera es actualmente el segundo cultivo más importante en extensión en Colombia y cuenta con alrededor de 6.856 productores, de los cuales el 85% son pequeños y el 12% medianos. Esta es una agroindustria que se ha desarrollado en torno a agricultores y empresas formales, generando oportunidades de empleo de calidad a nivel local y trayendo un invaluable desarrollo social y económico a gran parte del país (Fedapalma, 2021).

En la región de la Orinoquia Colombiana, la palma de aceite se encuentra en 35 municipios de los 4 departamentos que conforman dicha región, por lo tanto, es importante conocer la distribución geográfica de las palmas aceiteras para diversos fines (Chong et al., 2017). Como una característica distintiva en la superficie de la Tierra, las palmas de aceite pueden ser detectadas por sensores remotos. La clasificación de objetos de acuerdo con sus clases de cobertura terrestre ayuda a delinear la palma aceitera de su cobertura terrestre adyacente (por ejemplo, bosques, edificios, tierra desnuda, agua y otras plantaciones agrícolas).

En este contexto, es fundamental realizar una actualización de las áreas establecidas en palma de aceite en la región de la Orinoquia Colombiana (Zona Oriental – Según clasificación de Fedapalma), ya que es la región que actualmente posee más de 31 plantas extractoras, y con un gran potencial de crecimiento; región que según Fedapalma aporta el 44.45% de la producción nacional de aceite de palma con 693.000 toneladas, según el último reporte de producción (Fedapalma, 2021). Para el efecto, se realizó la cuantificación de las áreas de palma de aceite en el municipio de Maní - Casanare, usando análisis espacial y se plantearon los siguientes objetivos.

## **Objetivos**

### ***Objetivo General***

Desarrollar una guía metodológica para la identificación y cuantificación de las áreas sembradas en palma de aceite, a partir del uso de la plataforma Google Earth Engine, utilizando como caso de estudio en el municipio de Maní, Casanare.

### ***Objetivo Específicos***


- Determinar los procedimientos necesarios para la identificación y cuantificación de áreas sembradas en palma de aceite a partir del uso de la plataforma Google Earth Engine
- Elaborar un instructivo con los procedimientos para la identificación y cuantificación de áreas sembradas en palma de aceite, tomando como caso de estudio el municipio de Maní, Casanare.

## 1. Marco conceptual

### 1.1 Características Generales de la palma de aceite

La palma de aceite, tiene una característica distintiva con una copa visible y un tronco de un solo tallo. Las frondas o lanzas emergen del ápice del tronco y se extienden hacia afuera en forma de espiral con ocho frondas formando una fila en sucesión. Tiene la forma de una estrella de ocho puntas. La palma aceitera es un cultivo arbóreo perenne, que se parece más a un árbol forestal que a otros cultivos agrícolas (Hamsa et al., 2019). Como cultivo industrial, la palma aceitera se planta en forma de monocultivo. En la mayoría de las plantaciones comerciales, la mayoría de las palmas de aceite plantadas son Guineensis (*Elaeis Guineensis*) y Híbrida (*OxG Pisifera*), lo que hace que las palmas de aceite parezcan uniformes.

Este patrón único hace que las palmas aceiteras se distingan de otros árboles o bosques en las imágenes satelitales (W. Li et al., 2017). Las palmas de aceite se siembran en patrones triangulares con una distancia entre plantaciones de nueve metros (9 m) (Figura 1), que es un estándar industrial para maximizar el rendimiento con una penetración óptima de la luz solar (Basiron, 2007). Por lo general, se practica una densidad de plantación de 130 a 140 palmas por hectárea, pero varía según las condiciones de plantación y el tipo de material sembrado de palma aceitera (Chong et al., 2017).



**Figura 1.** (a) Patrón de siembra para una plantación de palma aceitera; (b) Imagen satelital; (c) Imagen Dron. **Fuente:** Adaptada de (Chong et al., 2017).

## 1.2 Uso de sensores remotos en el monitoreo de plantaciones de palma de aceite

En el seguimiento de las plantaciones de palma aceitera, la teledetección se ha utilizado en diversas aplicaciones, como la clasificación de la cobertura, el conteo automático de árboles de palma, la detección de cambios, la estimación de la edad, la detección de plagas y enfermedades y la estimación del rendimiento.

### 1.2.1 Clasificación de la cobertura

Clasificar los objetos según sus clases de cobertura terrestre ayuda a delimitar la palma aceitera de su cobertura terrestre adyacente (p.e. bosques, edificios, terrenos baldíos, agua y otras plantaciones agrícolas). Permite la demarcación de límites y una estimación precisa de la cobertura del área de palma aceitera (Nooni et al., 2014). Cuando se aplica en un análisis temporal, es valioso para la detección de la expansión de la palma aceitera y las actividades terrestres relacionadas.

Las imágenes ópticas registran la radiación en la región visible e infrarrojo cercano (NIR) reflejada desde la superficie. Hay diferentes señales captadas de la luz solar a lo largo de los espectros electromagnéticos (p.e. las banda azul, verde, rojo, borde rojo (Red Edge), NIR y banda infrarroja (IR), dependiendo de las capacidades del sensor para detectarlas. Las distintas superficies producen diferentes niveles de intensidad en todo el espectro. Analizando la energía reflejada y clasificándolas mediante sus respectivas firmas espectrales, pueden identificarse distintas clases de cobertura (Chong et al., 2017).

Shafri et al., (2011), reportaron que, en el mapeo de ángulo espectral, el NIR es la banda más prominente en la separación de las coronas de la palma aceite, el cual proporciona un mayor contraste consistentemente. Esto se debe a la fuerte absorción de clorofila en la región de la banda roja (R) y a la fuerte absorción de agua en la región de la banda IR (Nooni et al., 2014).

El análisis combinado de estas bandas mediante la comparación del resultado aumenta aún más la separabilidad espectral de las palmas aceiteras de la cobertura que las rodea. El uso de índices multispectrales para la detección de la palma de aceite se ha incrementado, el parámetro más común en uso es el Índice de Vegetación de Diferencia Normalizada (NDVI), que es una relación normalizada entre el infrarrojo cercano (NIR) y el rojo (R) visible. Srestasathiern & Rakwatin, (2014), evaluaron los índices de vegetación de mejor rendimiento para separar las palmas de aceite de su entorno, y reportaron que el Índice de Diferencia Normalizada (NDI), mostro un mayor poder de discriminación utilizando métricas de disimilitud de histograma.

### 1.2.2 Detección de cambios

La expansión de la palma aceitera es una de las principales causas de deforestación y degradación del medio ambiente, conduciendo al deterioro de la biodiversidad, alteración del carbono y problemas sociales. Para medir la detección de cambios se realiza mediante un análisis multitemporal, identificando los cambios de cobertura del suelo.

Los cambios se pueden visualizar mediante el análisis de detección a través de la percepción remota, con el cual se puede identificar la tasa de deforestación, la urbanización y expansión de plantaciones de palma de aceitera, con el fin de monitorear y auditar los cambios del suelo cumpliendo con los estándares de la Mesa Redonda sobre Sostenibilidad del Aceite de Palma (RSPO, 2007).

La Mesa Redonda sobre la Sostenibilidad de Aceite de Palma (RSPO) utiliza la detección de cambios para observar si las plantaciones de palma aceitera fueron previamente convertidas en bosque, como objetivo de conservar y proteger los recursos naturales y la biodiversidad; porque los bosques tienen un gran valor biológico, social y cultural en muchas partes del mundo. Por lo cual esta organización ayuda a controlar y certificar la sostenibilidad de las tierras no autorizadas, implementado el análisis de mapas de cobertura de suelos durante un periodo determinado, permitiendo visualizar si alguna tierra se ha convertido en palma aceitera, lo cual implica el uso de datos multitemporales para comparar las condiciones del antes y después y tomar decisiones.

### 1.2.3 Conteo de árboles

El conteo de árboles es una práctica importante y necesaria para la estimación y el seguimiento del rendimiento, de las plantaciones de aceite y el uso de suelo. Esta práctica resulta costosa y es demasiado propenso al error humano; requiere mucha mano de obra para llevarla a cabo la actividad en campo, debido a su heterogeneidad en el terreno. La teledetección es una solución a este problema, que proporciona una vista aérea de la plantación y una forma de contar automáticamente los árboles.

La automatización del conteo de árboles implica técnicas de procesamiento de imágenes como la segmentación, clasificación e identificación de objetos. La mejor técnica depende de la utilización de imágenes de muy alta a buena resolución espacial y nos conduce a la implementación de la agricultura de precisión en la industria de la palma aceitera, para mejorar rendimientos y reducir costos y mantenimiento.

La imagen de alta resolución espacial ayuda a discriminar las palmas a niveles de árbol individual, utilizando datos hiperespectrales aéreos con una resolución espacial de (1m), creando un esquema para emplear varias guías para el análisis de textura, morfología y análisis de manchas para llevar el conteo automático de árboles (Shafri et al., 2011).

La matriz de concurrencia de niveles de grises se utiliza para describir el área de palma aceitera de manera única en el análisis de textura. El realce de bordes del área con contraste de intensidades utilizando un filtro Sobel (El filtro Sobel detecta los bordes horizontales y verticales separadamente sobre una imagen en escala de grises). Las formas de las palmas aceiteras extraídas se refinan mediante la construcción morfológica que envuelve la erosión y la dilatación de formas irregulares. El número de palmas aceiteras se cuenta con el análisis de blobs, logrando alcanzar una precisión de conteo del 95% (Santoso et al., 2016).

Otra técnica es la hipótesis de detección de picos locales donde cada pico indica el punto más alto de cada árbol con el análisis del poder discriminante de un índice de vegetación (Srestasathien & Rakwatin, 2014). Este enfoque es rentable y se basa en datos multiespectrales de alta resolución espacial (0,6m) procedentes de una plataforma satelital (Quickbird).

El conteo de árboles depende en gran medida de imágenes de alta resolución espacial y dependen del tamaño de la plantación, por lo cual los Vehículos Aéreos No Tripulados (UAV) se convierte en una práctica recurrente: Este método utiliza la correlación cruzada normalizada para detectar y eliminar componentes no derivados de la palma aceitera (Wong-in et al., 2015). utilizando técnicas de agrupamiento a múltiples escalas para identificar palmas aceiteras individual de un arbusto, utilizando cámaras digitales en un (UAV) la precisión del conteo automático es del 90%.

#### **1.2.4 Estimación de edad**

La estimación de edad es un indicador para el pronóstico del rendimiento, porque influye en la calidad de los racimos de fruta de la palma de aceite y su productividad, adicionalmente es un dato importante en la ecuación para el cálculo de la biomasa (Tan et al., 2013).

Los rasgos morfológicos de las palmas aceiteras pueden utilizarse para estimar su edad. El tronco de la palma es tupido en la etapa inicial de crecimiento (1 a 2 años) y aumenta progresivamente en altura en la etapa posterior. El diámetro del troco es aproximadamente de 40 cm y su crecimiento en altura anual es de 30 – 60 cm (Webster, 1969). El crecimiento de las palmas aceiteras es alométrico, es decir crecen a diferentes ritmos. Los parámetros biofísicos se correlacionan con las etapas de la planta (joven, madura y vieja) e incluyen el Índice de Área Foliar (LAI), el Área Proyección de la Copa (CPA) y la altura de la palma de aceitera y estos parámetros se pueden detectar mediante sensores remotos, a través de sombras, asperezas y respuesta espectral (Chemura et al., 2015).

Índice de Área Foliar (LAI) describe la estructura de los árboles midiendo la densidad de la superficie de las hojas en un dosel, dando como resultado una interceptación eficiente de la luz, el aire y el agua. A medida que las palmas aceiteras envejecen se vuelven más frondas que aumenta el LAI, es una característica útil en la estimación de la edad (Fang et al., 2019).

La utilización de un sensor remoto, el aumento del LAI en las palmas aceiteras muestran un aumento proporcional en la reflectividad espectral o NDVI durante la etapa inicial. La saturación es el resultado de la práctica de poda y el objetivo es controlar el recuento de hojas como forma de optimizar la distribución de nutrientes y con fines higiénicos. LAI es útil para estimar la edad de la palma aceitera durante el desarrollo temprano (Sun et al., 2020).

### 1.2.5 Detección de plagas y enfermedades

La detección de plagas y enfermedades es de gran importancia en el control de manejo de enfermedades que ayudan a planificar estrategias de intervención para prevenir brotes. En las plantaciones de palma aceitera una enfermedad notoria es la *Ganoderma boninensis* un padecimiento fúngico (infección por hongos) que pudre las palmas aceiteras desde el interior, volviendo el cultivo vulnerable a las alteraciones atmosféricas de vientos y agua. Esta enfermedad es muy contagiosa y debe ponerse en cuarentena y retirarlas para evitar su propagación de la enfermedad (Liaghat et al., 2014).

Utilizando la teledetección sensores remotos aéreos o satelitales, se puede evaluar el estado de las palmas con un diagnóstico temprano de las enfermedades de plaga con el instrumento de hiperespectral de campo portátil para diferenciar la palma de aceite sana de la infectada (Shafri et al., 2011).

La detección de *Ganoderma boninensis* a mayor escala, es necesario el uso de sensores remotos. Santoso et al., (2011), utilizaron imágenes de alta resolución de Quickbird para mapear e identificar palmas aceiteras infectadas con *Ganoderma boninensis*. Se probaron la reflectancia espectral, el NDVI y otros índices de vegetación para discriminar palmas sanas e infectadas. Además, Khairunniza-Bejo et al., (2021), reportaron que una detección temprana de *Ganoderma boninensis*, a través de sensores hiperespectrales NIR, usando máquinas de soporte vectorial.

### 1.2.6 Estimación de rendimiento

El rendimiento de la palma aceitera debe estimarse para lograr los máximos beneficios económicos mediante la elaboración de estrategias de gestión adecuadas. La estimación del rendimiento, como paso preliminar para predecir y pronosticar la productividad, ayuda en el proceso de toma de decisiones en la plantación (Chong et al., 2017).

La palma aceitera produce su cosecha en forma de Racimos de Fruta Fresca (RFF). En un escenario normal, pasan 18 meses desde la etapa de inicio de la inflorescencia hasta la madurez óptima. Los racimos de frutos están debajo de la copa de la palma. Los maduros se ubican en la parte más baja de la copa, lo que permite que se realice una cosecha no tan complicada (Webster, 1969).

Desde el punto de vista de la teledetección no es factible observar los frutos desde una imagen o vista aérea, por lo cual se recurre a centrarse en la robustez y sanidad de la palma de aceite como indicador de buen rendimiento. Por lo cual la estimación de rendimiento debe ser un análisis temporal continuo, ya que los datos de rendimiento recopilados en ese momento son el reflejo de los esfuerzos invertidos durante meses, correspondiente al manejo nutricional, sanitario y de gestión (Fedapalma, 2021).

El rendimiento de la palma aceitera puede ser afectado por varios factores internos y externos. Los factores internos incluyen la edad y las variedades de palma aceitera (p.e Guineensis - *Elaeis Guineensis* y Híbrida - *OxG Pisifera*), mientras que los factores externos incluyen la precipitación, sequías, enfermedades, fertilidad del suelo, humedad del suelo y eficiencia de la cosecha. Es necesario tener los factores tanto internos como externos, de igual manera se debe tener en cuenta la edad de la palma de aceite, debido a que los requerimientos p.e nutricionales y contenido de agua aprovechable, varían dependiendo del estado fenológico del material o variedad (Ang et al., 2022).

### **1.3 Aplicación de Google Earth Engine en las plantaciones de palma de aceite**

Google Earth Engine (GEE) es una plataforma de computación en la nube lanzada por Google en 2010. GEE utiliza la infraestructura computacional de Google y los conjuntos de datos Sensores Remotos (RS) de acceso abierto disponibles (Gorelick et al., 2017). GEE es la plataforma de procesamiento de grandes datos geográficos más popular, que facilita el proceso de descubrimiento científico al proporcionar a los usuarios acceso gratuito a numerosos conjuntos de datos obtenidos de forma remota (Amani et al., 2019). Los usuarios pueden acceder a GEE a través de una interfaz de programación de aplicaciones (API) basada en Internet y un entorno de desarrollo interactivo basado en la web (Tamiminia et al., 2020).

Se ha observado que los conjuntos de datos Landsat y Sentinel son muy utilizados por los usuarios de GEE. Además, los algoritmos de aprendizaje automático supervisado, como Random Forest, se ha aplicado más frecuentemente a las tareas de clasificación de imágenes. La GEE también se ha empleado en una amplia gama de aplicaciones, como la clasificación de la Cobertura Terrestre/Usos del Suelo (Land Cover/Land Use), hidrología, planificación urbana, desastres naturales, análisis climáticos y el procesamiento de imágenes (Amani et al., 2020).



En los estudios de clasificación de la cobertura terrestre realizados durante la última década, se produjeron mayores precisiones cuando se utilizaron imágenes satelitales de series temporales que cuando se utilizaron imágenes de una sola fecha. Recientemente, la disponibilidad de GEE, ha llamado la atención de aplicaciones basadas en sensores remotos donde se aplican ampliamente métodos de agregación temporal derivados de imágenes de series temporales, es decir, el uso de métricas como media o mediana (Noi Phan et al., 2020).

GEE permite la clasificación de Cobertura Terrestre (Land Cover) mediante algoritmos incorporados. Estos algoritmos realizan clasificación basada en píxeles mediante el método supervisado. Dentro de los múltiples usos de este algoritmo, se encuentra la identificación y los Cambios de Cobertura Terrestre (Land Use/Cover Change), a través de análisis multitemporales (Nasiri et al., 2022).

Se han desarrollado múltiples técnicas para cartografiar la cobertura vegetal de la palma aceitera utilizando datos de teledetección por satélite en los trópicos (Shafira et al., 2020); así como la detección usando Vehículos Aéreos No Tripulados (UAV), como herramienta rentable para generar inventarios y estimación del crecimiento por palma a través del Modelo Digital de Superficie (Fawcett et al., 2019). Los métodos ópticos para cartografiar la cubierta vegetal de la palma aceitera se basan en información derivada de la fenología o de las características de la imagen de la plantación de palma aceitera (L. Li et al., 2015), Los métodos basados en imágenes utilizan firmas espectrales, así como información de textura, para diferenciar las palmeras aceiteras de su entorno (Carlson et al., 2013;Lu et al., 2016).

Para resolver los desafíos que plantea el mapeo de plantaciones de palma aceitera en los trópicos húmedos, se han probado datos de radar, que son compatibles con todo tipo de clima y en todo momento, para mapear la palma aceitera (Weiss et al., 2020). La energía de microondas dispersada por la vegetación depende del tamaño y la densidad, así como de la orientación y las propiedades dieléctricas de los elementos que son comparables al tamaño de la longitud de onda del radar, mientras que la energía óptica reflejada por la vegetación depende de la estructura de la hoja, la pigmentación y la humedad (Joshi et al., 2016).

Los datos de radar proporcionan más información sobre las propiedades estructurales de la tierra, como los senderos y caminos de recolección, que son una característica destacada de las plantaciones de palma aceitera. Los datos de radar también permiten distinguir rodales de palma aceitera de dosel cerrado, con sus grandes frondas sostenidas por troncos sin ramas, de otra vegetación leñosa y cubierta arbórea (Ienco et al., 2019). Recientemente, se ha utilizado una combinación de datos ópticos y de radar para mapear la palma aceitera en diferentes contextos geográficos y utilizar diferentes combinaciones de datos (De Alban et al., 2018). Más específicamente para la clasificación de la cobertura terrestre de palma aceitera, la fusión de conjuntos de datos ópticos y de radar también ha dado como resultado una mayor precisión que la clasificación utilizando un solo conjunto de datos (Sarzynski et al., 2020).

### **1.3.1. Aplicación de Algoritmos de aprendizaje automático para la detección de plantaciones de palma de aceite**

Yang et al., (2022), reportaron que los algoritmos de aprendizaje automático e Inteligencia Artificial (IA), desarrolladas en GEE, se encuentra el mapeo de cultivos y la Clasificación de la Cobertura Terrestre (Land Cover Classification). Además, mencionan que se utilizan imágenes Landsat 8, Sentinel 1, Sentinel 2, DEM STRM (Shuttle Radar Topography Mission), como insumos principales, y que de los modelos de IA más populares son RF (Random Forest), CART (Classification and Regression Trees) y SVM (Support Vector Machine); y las métricas de evaluación más utilizados son la OA (Overall Accuracy), PA (Producer's Accuracy), UA (User's Accuracy) y el índice Kappa.

Los algoritmos de clasificación son uno de los pasos más importantes para obtener información significativa a partir de imágenes de satélite. Cada objeto produce una reflectancia diferente debido a su firma espectral. La clasificación de imágenes es el proceso de extraer información categorizando todos los píxeles de una imagen para obtener un conjunto de clases. Esta clasificación de píxeles utiliza la información espectral representada por los números digitales en una o más bandas espectrales. Los números deben representar los valores reales de reflectancia de la superficie para poder clasificar cada grupo de píxeles (Shafira et al., 2020).

La tarea de Land Use and Land Cover (LULC) consiste en clasificar cada píxel o segmento de las imágenes de satélite/UAV, y detectar regiones/objetos específicos en las imágenes. LULC es el uso más común del Aprendizaje Profundo (Deep Learning) en imágenes satélite, esta popularidad no es sorprendente, ya que se considera el descriptor más importante del medio ambiente. Así pues, la investigación sobre LULC y la segmentación de cultivos es mejorar la calidad de los métodos automatizados para que, con el tiempo sean al menos tan fiables como los de los expertos humanos (Victor et al., 2022).

En teledetección, elegir las mejores combinaciones de bandas en función de los canales disponibles de las imágenes de satélite permite comprender mejor sus características. Esencialmente, las combinaciones de bandas pueden extraer información significativa y específica de la imagen, como características geológicas, agrícolas y de vegetación (Asming et al., 2022).

En las imágenes de Sensores Remotos, varios tipos diferentes de Uso de la Tierra (Land Use) tienen firmas espectrales similares o son muy complejos, lo que dificulta su identificación adecuada. Se han desarrollado y entrenado diferentes modelos de Machine Learning (ML) los cuales se encuentran disponibles en GEE, con diferentes combinaciones de datos de entrada para determinar cuáles eran los más importantes a la hora de determinar los tipos de Uso de la Tierra (Adepoju & Adelabu, 2020).

Lee et al., (2016), realizaron una detección de plantaciones industriales de palma de aceite usando imágenes Landsat 8, a través de la plataforma de GEE. Realizaron una clasificación de la Cobertura, utilizando todas las bandas espectrales de Landsat 8 (B, G, R, NIR, SWIR, TIR) y la composición de bandas de verdadero color (RGB), para distinguir las siguientes clases de cobertura terrestre: palma aceitera inmadura, palma aceitera madura, palma aceitera no forestal, bosque, agua y nubes. Utilizaron métodos de clasificación de CART (Árboles de Clasificación y Regresión) y Random Forest (RF) que proporcionaron cálculos de precisión altos en todas las bandas, con un coeficiente de Kappa de 0,92 y la clasificación Random Forest (RFT) de (91,2%).

#### 1.4 Algoritmos de Machine Learning (ML) en Sensores Remotos

El Aprendizaje Automático (ML) se utiliza para enseñar a las máquinas cómo manejar los datos de manera más eficiente. Con la abundancia de conjuntos de datos disponibles, la demanda de aprendizaje automático está aumentando. El propósito del ML es aprender de los datos. Machine Learning se basa en diferentes algoritmos para resolver problemas de datos. A los científicos de datos les gusta señalar que no existe un único tipo de algoritmo que sirva para todos y que sea mejor para resolver un problema. El algoritmo de procedimiento empleado, depende del tipo de problema que se desea resolver, el número de variables, el tipo de modelo que mejor se adapta, etc. (Mahesh, 2018). En la Figura 2, se visualiza algunos de los algoritmos comúnmente utilizados en el ML.

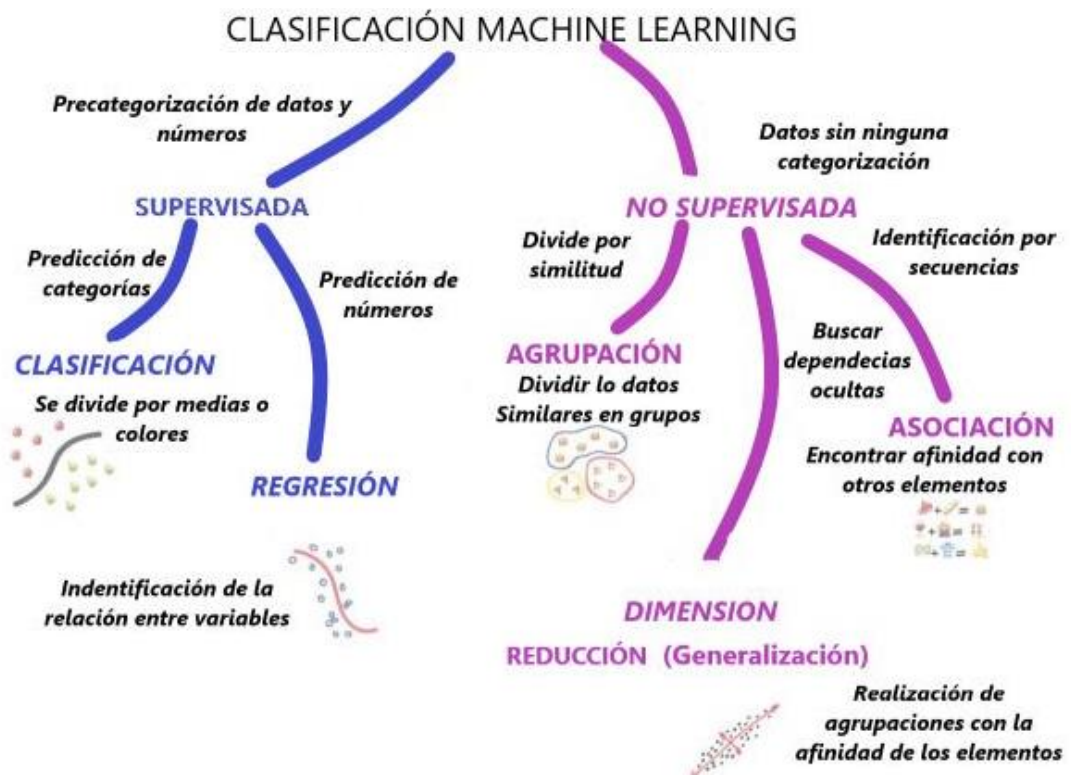
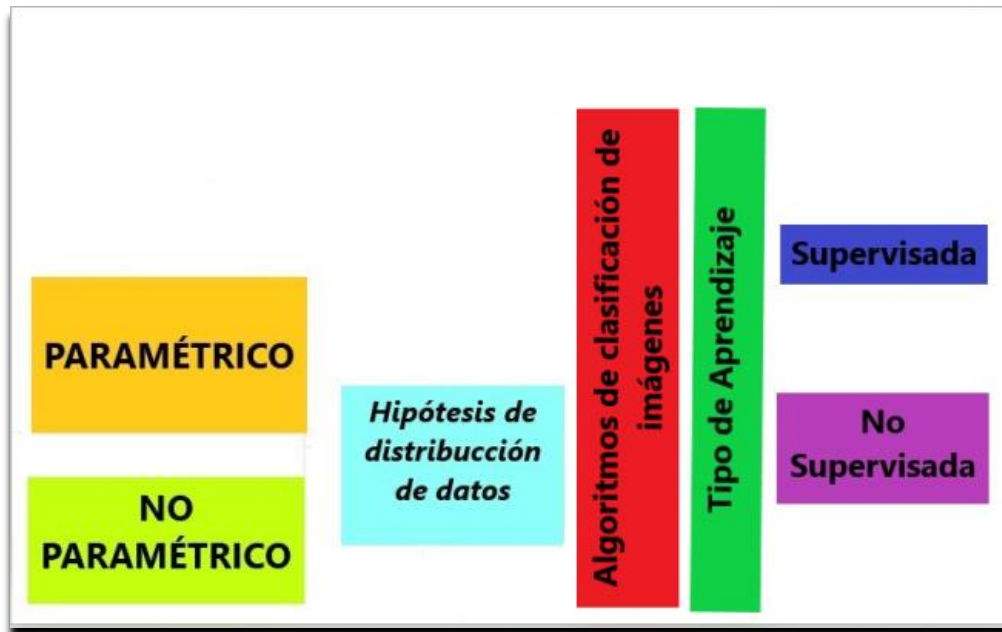


Figura 2. Clasificación Machine Learning. Adaptado de (VAS3K, 2023).

Los algoritmos de clasificación de imágenes se pueden clasificar en términos generales en enfoques supervisados y no supervisados. Se prefieren los clasificadores supervisados cuando se dispone de cantidades suficientes de datos de entrenamiento. Los métodos paramétricos y no paramétricos son otra categorización de algoritmos de clasificación basados en supuestos de distribución de datos (Figura 3).



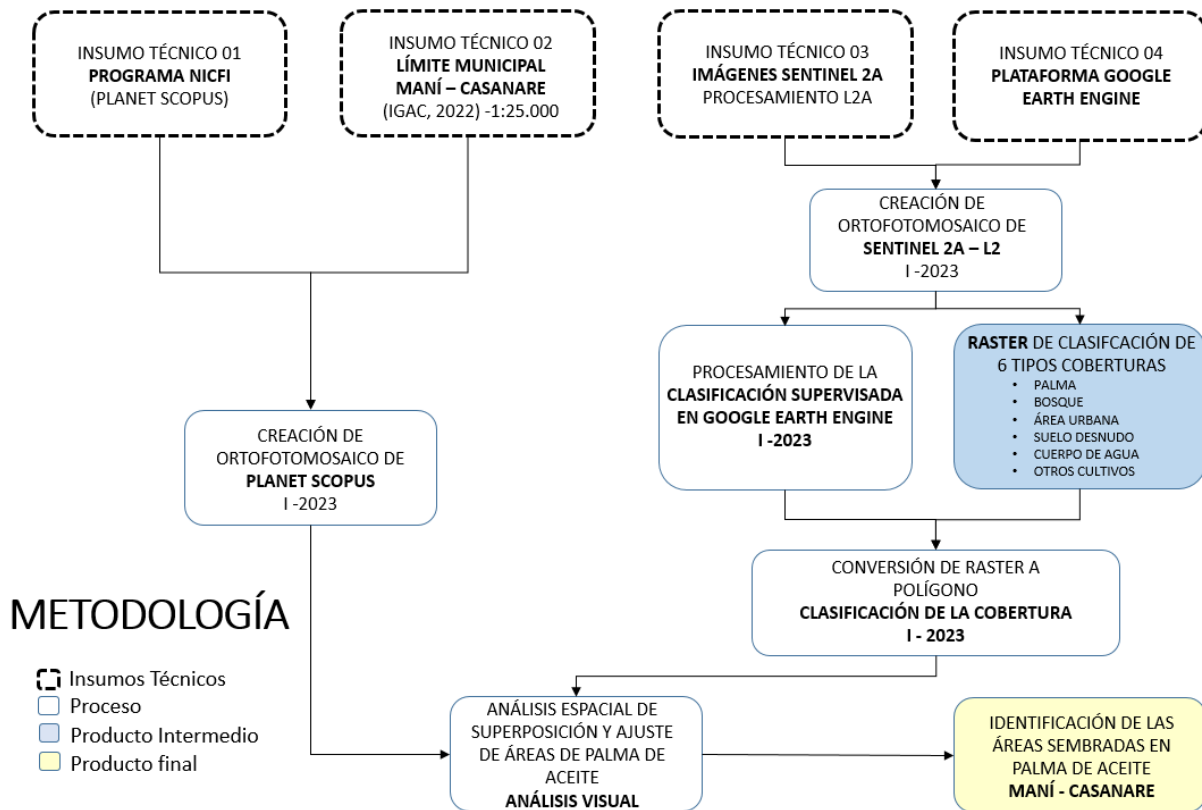
**Figura 3.** Taxonomía de algoritmos de clasificación de imágenes. Adaptado de (Sheykhmousa et al., 2020).

Los Sensores Remotos ha demostrado su valor en muchos campos, pero el éxito de cualquier clasificación de imágenes depende de varios factores, incluida la elección de un procedimiento de clasificación adecuado (Lu & Weng, 2007). Los clasificadores supervisados se utilizan ampliamente porque son más sólidos que los enfoques basados en modelos (Niemeyer et al., 2014).

RF es un enfoque de aprendizaje conjunto, desarrollado por Breiman (Breiman, 2001), para resolver problemas de clasificación y regresión. El aprendizaje conjunto es un esquema de aprendizaje automático para aumentar la precisión mediante la integración de múltiples modelos para resolver el mismo problema. En particular, varios clasificadores participan en la clasificación por conjuntos para obtener resultados más precisos en comparación con un solo clasificador (Sheykhmousa et al., 2020). En otras palabras, la integración de múltiples clasificadores disminuye la varianza, especialmente en el caso de clasificadores inestables, y puede producir resultados más confiables. Un clasificador de Bosque Aleatorio (Random Forest) es un clasificador de conjunto que produce múltiples árboles de decisión, utilizando un subconjunto de muestras y variables de entrenamiento seleccionadas aleatoriamente (Belgiu & Drăgu, 2016).

## 2. Metodología

La metodología que se implementó en este trabajo se desarrolló en 4 etapas, las cuales son: Compilación de 4 Insumos Técnicos, Procesamiento de la información, 1 Producto Intermedio, y 1 Producto Final. Este proceso metodológico está representado a través de un Modelo Cartográfico (Figura 4).



**Figura 4.** Metodología para la identificación de áreas sembradas en palma de aceite. **Fuente:** Elaboración propia

### 2.1. Insumo Técnico

El Insumo Técnico corresponde a la recopilación de información espacial básica, que se emplea como materia prima y que se utiliza en el proceso productivo para la elaboración, análisis y soporte de datos geográficos dentro de la metodología. Para el caso específico de este trabajo, se utilizaron 4 Insumos Técnicos:

- Inscripción y uso del Programa de NICFI (Planet Scopus). Imágenes de alta resolución espacial (3m x 3m), del municipio de Maní – Casanare, para el primer semestre del año 2023.

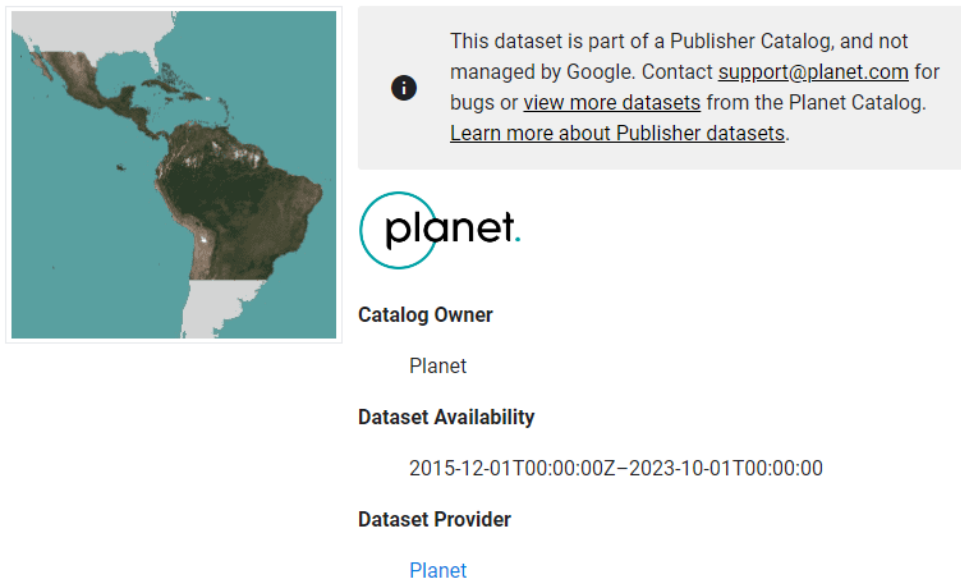
- Limite municipal de Deslindes IGAC del municipio de Maní – Casanare a escala 1:25.000, del 2022.
- Imágenes Sentinel 2A con procesamiento L2A, las cuales se encuentran corregidas atmosféricamente, ortorrectificada, que proporciona datos de Reflectancia de la Superficie. Imágenes compiladas para el primer semestre del año 2023.
- Acceso y programación en la plataforma de Google Earth Engine.

## 2.2. Procesamiento de la información o Proceso

Para la metodología desarrollada se realizaron 4 procesos, descritos a continuación:

- Creación del Ortofotomosaico de imágenes de Planet Scopus, mediante la plataforma de **Google Earth Engine**, en el marco de los Mapas Base del programa de datos satelitales NICFI para el monitoreo de bosques tropicales en América. ([https://developers.google.com/earth-engine/datasets/catalog/projects\\_planet-nicfi\\_assets\\_basemaps\\_americas](https://developers.google.com/earth-engine/datasets/catalog/projects_planet-nicfi_assets_basemaps_americas)) (Figura 5).
- Creación del Ortofotomosaico de imágenes de Sentinel 2A, del programa Copernicus, con nivel de procesamiento L2, mediante la plataforma de **Google Earth Engine**. Imágenes consolidadas para I-2023. ([https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS\\_S2\\_SR\\_HARMONIZED](https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED)) (Figura 6).

### NICFI Satellite Data Program Basemaps for Tropical Forest Monitoring - Americas



This dataset is part of a Publisher Catalog, and not managed by Google. Contact [support@planet.com](mailto:support@planet.com) for bugs or [view more datasets](#) from the Planet Catalog. [Learn more about Publisher datasets.](#)

**planet.**


**Catalog Owner**  
Planet

**Dataset Availability**  
2015-12-01T00:00:00Z–2023-10-01T00:00:00

**Dataset Provider**  
[Planet](#)

**Figura 5.** Plataforma NICFI, con GEE – Tomada 12 de octubre de 2023.

# Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A



## Dataset Availability

2017-03-28T00:00:00Z–2023-11-05T16:25:08

## Dataset Provider

[European Union/ESA/Copernicus](#)

## Earth Engine Snippet

```
ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
```



## Tags

copernicus

esa

eu

msi

reflectance

sentinel

sr

**Figura 6.** Imágenes Sentinel 2A – Programa Copernicus. *Tomada 12 de octubre de 2023.*

- Clasificación Supervisada: La clasificación supervisada es la técnica que se basa en agrupar píxeles que poseen espectros similares y se pueden asociar con diferentes clases de coberturas del suelo, utilizando datos de entrenamiento de variables predictoras medidas en cada unidad de muestreo y asignar clases previas. El algoritmo de clasificación utilizado es Random Forest, el cual ofrece una clasificación eficaz y eficiente de imágenes satélites, consiste en una combinación de clasificadores de árbol donde cada clasificador se genera usando un vector aleatorio muestreado independientemente del vector de entrada, y cada árbol arroja un voto unitario para la clase más popular para clasificar un vector de entrada. Esta clasificación se realizó con el Ortofotomosaico de las imágenes Sentinel 2A -L2, para el periodo I-2023. Los valores de clasificación fueron:
  - Cuerpos de Agua
  - Suelo desnudo
  - Palma de Aceite
  - Cultivos (pastos, arroz, maíz y otros cultivos transitorios)
  - Forestales
  - Áreas Urbanas

El código de Google Earth Engine, con la Clasificación Supervisada se encuentra en: <https://code.earthengine.google.com/c2547a17f997b2851ea6e5d9f892ea6c> (Figura 7).

The screenshot displays the Google Earth Engine web interface. At the top, the browser address bar shows the URL: `code.earthengine.google.com/c2547a17f997b2851ea6e5d9f892ea6c`. The interface includes a search bar, a toolbar with 'Run', 'Reset', and 'Apps' buttons, and a navigation panel on the right with 'Inspector', 'Console', and 'Tasks' tabs.

The 'Imports' section lists several variables: `water` (23 elements), `SueloDesnudo` (39 elements), `Palma` (120 elements), `Cropland` (69 elements), `Forest` (44 elements), `Urban` (43 elements), `table`, and `table2`.

The 'Console' tab shows the following output:

- FeatureCollection (338 elements) - JSON
- Confusion Matrix - JSON
- List (6 elements) - JSON
- Overall Accuracy: 0.8923076923076924 - JSON
- Image (1 band) - JSON

The 'Inspector' tab shows a function `maskS2clouds` with the following code:

```
1  
2 /////  
3 ///// Imagenes Sentinel 2  
4 /**  
5 * Function to mask clouds using the Sentinel-2 QA band  
6 * @param {ee.Image} image Sentinel-2 image  
7 * @return {ee.Image} cloud masked Sentinel-2 image  
8 */  
9 function maskS2clouds(image) {  
10   var qa = image.select('QA60');  
11  
12   // Bits 10 and 11 are clouds and cirrus, respectively  
13
```

The map view shows a satellite image of a region in Colombia, with several colored markers (green, blue, purple) overlaid on the terrain. The map includes a scale bar (20 km) and a legend.

Figura 7. Visualización del código de clasificación supervisada en GEE



- **Conversión de Raster a Polígono.** Este proceso se realizó mediante el software ArcGIS Pro, partiendo como base que el proceso de clasificación realizado en el paso anterior, da como resultado un archivo tipo raster con resolución de 10m x 10m, con una clasificación de 6 coberturas. Se realizó un proceso de Reclassificación de raster (**Reclassify – Spatial Analyst**), donde solo se tomó la Clasificación de la Palma de Aceite (Cobertura 3), y se asignó el resto de coberturas como NA (No Data), para minimizar el peso de la imagen, debido a que solo interesa la clasificación de la Palma de Aceite en el municipio de Maní – Casanare. Luego de la reclasificación se realizó la conversión de solo el raster de Palma, mediante la función **Raster To Polygon**.

### 2.3. **Producto Final**

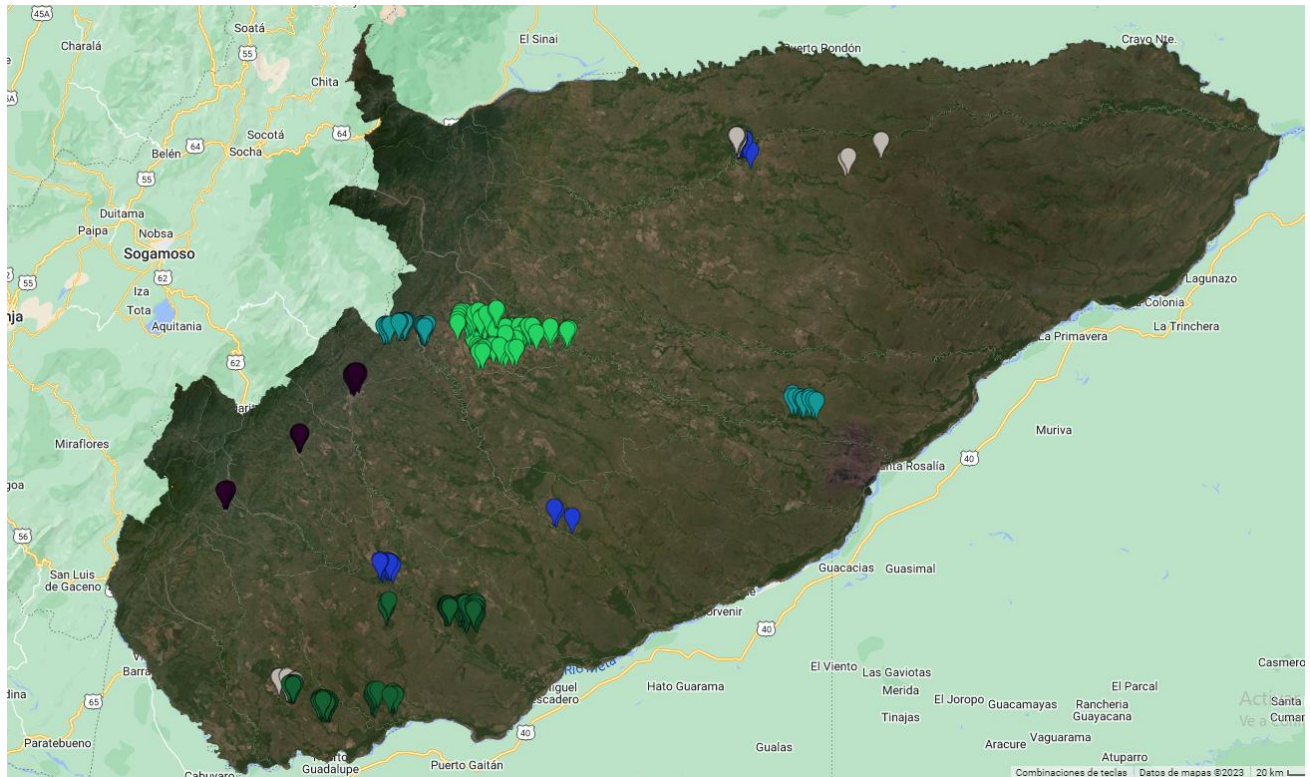
Análisis espacial de Superposición y ajuste de áreas de Palma de Aceite. En este proceso se realizó un Análisis Visual, de la capa resultante de la conversión de raster a polígono y se ajustó las áreas de Palma de Aceite con el Ortofotomosaico previamente realizado con las imágenes Planet Scopus, del programa NICFI.

### 3. Resultados

A continuación, se explica el código **línea por línea**, en lenguaje de código de JavaScript, dentro de la plataforma de GEE, como Guía metodológica para la identificación de las áreas sembradas en Palma de aceite, teniendo como caso de estudio el Municipio de Maní, Casanare.

#### 3.1 Identificación de las zonas sembradas con Palma de Aceite en Maní - Casanare

Para la identificación de las áreas sembradas en Palma de Aceite, se tomó el resultado del Ortofotomosaico de las Imágenes Sentinel 2A, con nivel de procesamiento L2 (Figura 8). Esta imagen fue realizada a través de la plataforma de Google Earth Engine, con la colección de imágenes `ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')`<sup>1</sup> con un filtro de menos del 10% de nubosidad declarada en la Función `maskS2clouds`, establecida y recomendada por la plataforma (Figura 9).



**Figura 8.** Ortofotomosaico de imágenes Sentinel 2A-L2, para el I-2023

---

<sup>1</sup> [https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS\\_S2\\_SR\\_HARMONIZED](https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED)

```

/////
//// Imagenes Sentinel 2
/**
 * Function to mask clouds using the Sentinel-2 QA band
 * @param {ee.Image} image Sentinel-2 image
 * @return {ee.Image} cloud masked Sentinel-2 image
 */
function maskS2clouds(image) {
  var qa = image.select('QA60');

  // Bits 10 and 11 are clouds and cirrus, respectively.
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;

  // Both flags should be set to zero, indicating clear conditions.
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
  .and(qa.bitwiseAnd(cirrusBitMask).eq(0));

  return image.updateMask(mask).divide(10000);
}

var dataset = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
  .filterDate('2023-01-01', '2023-10-30')
  // Pre-filter to get less cloudy granules.
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE',10))
  .map(maskS2clouds)
  .filterBounds(table)
  .median();

var visualization = {
  min: 0.0,
  max: 0.3,
  bands: ['B4', 'B3', 'B2']};

```

**Figura 9.** Código para la generación de Ortofotomosaico de las imágenes Sentinel 2A -L2

Se establecieron 6 coberturas, como datos de entrenamiento para el algoritmo de Clasificación Supervisada (Figura 10 y 11).

```

Imports (7 entries)
  ▶ var water: FeatureCollection (23 elements)
  ▶ var SueloDesnudo: FeatureCollection (39 elements)
  ▶ var Palma: FeatureCollection (120 elements)
  ▶ var CropLand: FeatureCollection (69 elements)
  ▶ var Forest: FeatureCollection (44 elements)
  ▶ var Urban: FeatureCollection (43 elements)
  ▶ var table: Table users/dmera96_taller2/Casanare_Mun

```

**Figura 10.** Datos de entrenamiento y coberturas establecidas para la Clasificación Supervisada

```

// Define a palette for the classification
var landcoverPalette = [
  '#1d38d6', //water(0) - Azul Oscuro
  '#bfb8af', //SueloDesnudo(1) - Gris Claro
  '#115f32', //Palma(2) - Verde Oscuro
  '#12d65c', //CropLand(3) - Verde Claro
  '#009999', //Forest(4) - Verde Azul
  '#29012a', //Urban(5) - Morado
];

```

**Figura 11.** Función de Clasificación de datos de entrenamiento

El clasificador de Bosque Aleatorio (Random Forest) se estableció utilizando un subconjunto de muestras y variables de entrenamiento seleccionadas aleatoriamente dentro de la imagen de Sentinel 2A – L2, se tomaron 338 datos de entrenamiento, distribuidos en seis clases (Tabla 1). Para la aplicación del algoritmo, se consolidaron los datos de entrenamiento en un solo archivo espacial (Figura 12).

**Tabla 1.** Subconjunto de muestras de entrenamiento para Clasificación Supervisada -RF

ID	Clasificador	Número de Clasificador	Color HEX	Color RGB
0	Cuerpos de Agua	23	#1d38d6	29,56,214
1	Suelo desnudo	39	#bfb8af	191,184,175
2	Palma de Aceite	120	#115f32	17,95,50
3	Otros Cultivos	69	#12d65c	18,214,92
4	Bosque	44	#009999	0,153,153
5	Zona Urbana	43	#29012a	41,1,42

```

////////Crear una region de interes - Datos de entrenamiento en un solo archivo
var training = water.merge(SueloDesnudo).merge(Palma).merge(CropLand).merge(Forest).merge(Urban);
print(training);

```

**Figura 12.** Código para unificar los datos de entrenamiento

A continuación, se especifica al código, que realice una selección aleatoria del 80% de los datos de entrenamiento. Esto corresponde a 270 datos ( $338 * 0.8$ ) de entrenamiento para el modelo supervisado Random Forest (Figura 13)

```

// Overlay the points on the imagery to get training
// Superposicion de los puntos en la imagen para obtener la capacitacion

var trainImage = input.sampleRegions({
  collection: training,
  properties: [label],
  scale: 30
});

// Seleccion aleatoria del 80% de los datos de entrenamiento

var trainingData = trainImage.randomColumn();
var trainSet = trainingData.filter(ee.Filter.lessThan('random', 0.8));
var testSet = trainingData.filter(ee.Filter.greaterThanOrEquals('random', 0.8));

```

**Figura 13.** Código para la selección aleatorio del 80% de los datos de entrenamiento

En la Figura 14 se identifica el código que utiliza la clasificación de Random Forest, empleando la función `ee.Classifier.smileRandomForest` (Breiman, 2001), la cual usa las Bandas B2, B3, B4 y B8 de la imagen Sentinel 2A - L2, esto indica que el algoritmo empleó las bandas Azul, Verde, Rojo, NIR (Tabla 2):

**Tabla 2.** Características de las Bandas de las Imágenes Sentinel 2A (Chuvieco, 2016).

	SENTINEL 2	
	Longitud de onda ( $\mu\text{m}$ )	Resolución (m)
Banda 1 - Aerosol	0,43 - 0,45	60
Banda 2 - Blue	0,45 - 0,52	10
Banda 3 - Green	0,54 - 0,57	10
Banda 4 - Red	0,65 - 0,68	10
Banda 5 - Red edge 1	0,69 - 0,71	20
Banda 6 - Red edge 2	0,73 - 0,74	20
Banda 7 - Red edge 3	0,77 - 0,79	20
Banda 8 - Near Infrared (NIR) 1	0,78 - 0,90	10
Banda 8A - Near Infrared (NIR) 2	0,85 - 0,87	20
Banda 9 - Water vapour	0,93 - 0,95	60
Banda 10 - Cirrus	1,36 - 1,39	60
Banda 11 - SWIR 1	1,56 - 1,65	20
Banda 12 - SWIR 2	2,10 - 2,28	20

```

// Classification Model
var label = 'Class'
var bands = ['B2', 'B3', 'B4', 'B8'];
var input = dataset.select(bands);
var classifier = ee.Classifier.smileRandomForest(50).train(trainSet, label, bands);

// Classify the image - Parametro de Visualización

var calssified= input.classify(classifier);

```

**Figura 14.** Código del modelo de clasificación, usando la imagen Sentinel 2A -L2

Se evaluó la precisión del modelo, por medio de la Matriz de Confusión, mediante la función **ee.ConfusionMatrix**, (Stehman, 1997) (Figura 15). En la Matriz de Confusión el eje de las Filas corresponde a los valores reales y el eje de las Columnas corresponde a los valores predichos. La Precisión General (Overall Accuracy) del modelo, fue de 0.892, correspondiente con el 89.2% de precisión (Figura 16).

```

//Accuracy Assessment
var confusionMatrix = ee.ConfusionMatrix(testSet.classify(classifier)
  .errorMatrix({
    actual: 'Class',
    predicted: 'classification'
  }));

print('Confusion Matrix: ', confusionMatrix);
print('Overall Accuracy: ', confusionMatrix.accuracy());

```

**Figura 15.** Función de la Matriz de Confusión y Precisión General del Modelo

```

Confusion Matrix:
▼ List (6 elements)
  ▶ 0: [7,0,0,0,0,0]
  ▶ 1: [0,4,0,2,0,0]
  ▶ 2: [0,0,24,0,1,0]
  ▶ 3: [0,1,0,9,0,1]
  ▶ 4: [0,0,0,0,5,0]
  ▶ 5: [0,0,0,2,0,9]

```

---

```

Overall Accuracy:
0.8923076923076924

```

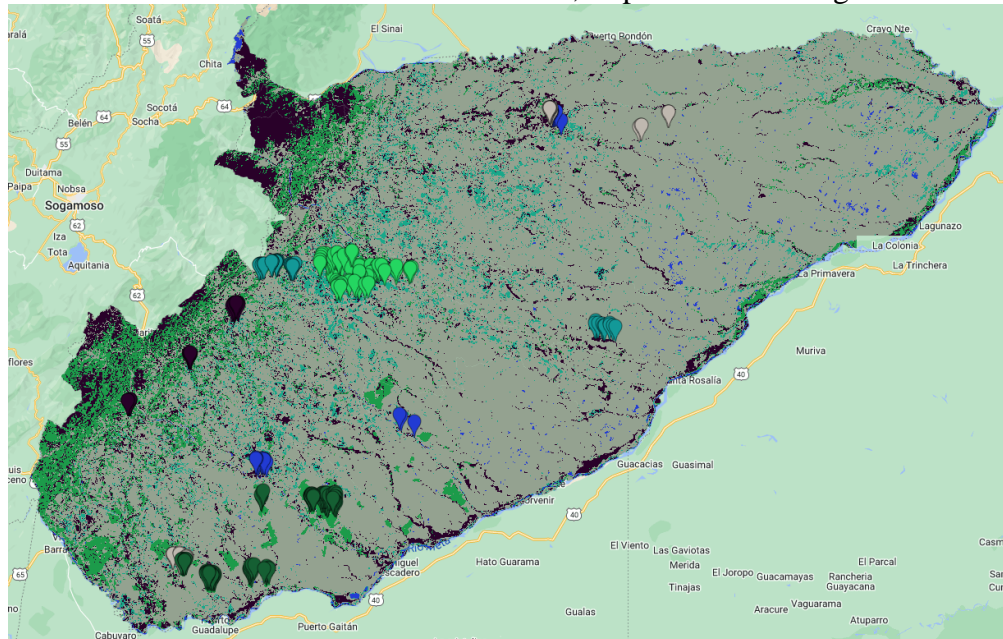
**Figura 16.** Resultados de la Matriz de Confusión y la Precisión General

Para exportar el Raster resultante de la Clasificación Supervisada, usando Random Forest, se aplicó la función `Export.image.toDrive`, (Figura 17).

```
// Export Classified map
Export.image.toDrive({
  image: calssified.clip(table),
  description: "Sentinel_2_Classified",
  scale: 10,
  region: table,
  maxPixels: 1e13,
  fileFormat: 'GeoTIFF',
  crs: 'EPSG:4326'
});
```

**Figura 17.** Código para exportar a Google Drive, la capa ráster clasificada.

Los resultados de la clasificación final, se presenta en la Figura 18.

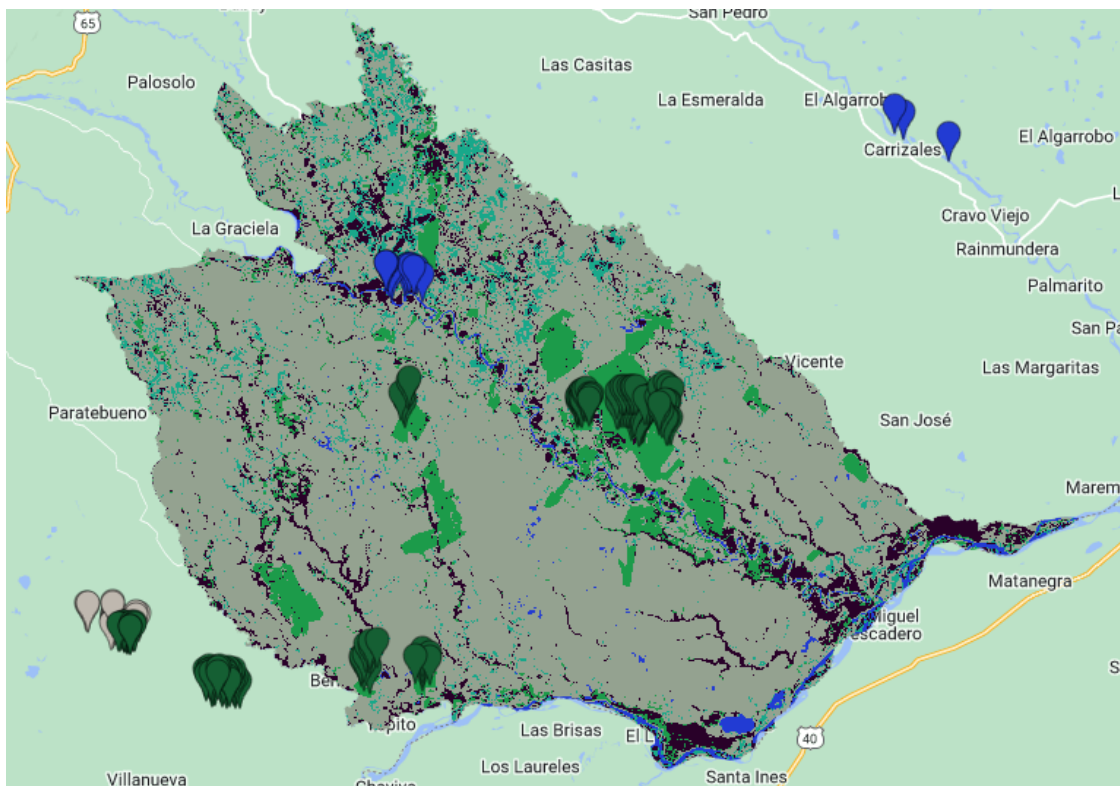


**Figura 18.** Resultados de la clasificación de cobertura, según la metodología empleada.

Se realizó un clip, directamente en la delimitación del municipio de Maní - Casanare, usando la Función `.clip` (Figura 19), declarada como una nueva variable “mani”, y visualizado como resultado de la clasificación del municipio de Maní (Figura 20).

```
var mani = calssified.clip(table2);
print(mani)
```

**Figura 19.** Código para realizar el clip del Municipio de Maní – Casanare



**Figura 20.** Corte de la clasificación del municipio de Maní - Casanare

A partir de la clasificación se realizó un Reclasificación, con la Función **.where**, donde el criterio de Clasificación se relaciona en la Tabla 3. Luego se exporta el raster Reclasificado ('Classes') mediante la Función **Export.image.toDrive**, (Figura 21).

**Tabla 3.** Valores de Reclasificación

ID	Clasificador	Reclasificación	Color HEX	Color RGB
0	Cuerpos de Agua	0	#FFFFFF'	255,255,255
1	Suelo desnudo	0		
2	Palma de Aceite	2	'#115f32'	17,95,50
3	Otros Cultivos	0	#FFFFFF'	255,255,255
4	Bosque	0		
5	Zona Urbana	0		



```

var Classes = mani
    .where(mani.lte(1),0)
    .where(mani.gt(1.2).and(mani.lte(2.1)),2)
    .where(mani.gt(2.2).and(mani.lte(5.1)),0);

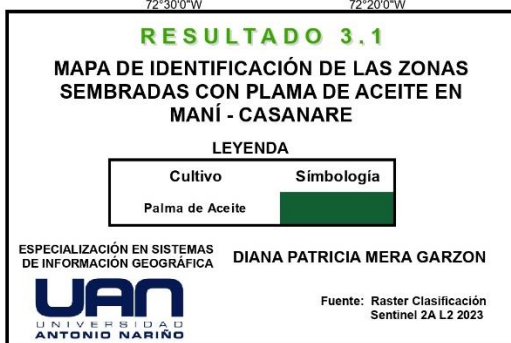
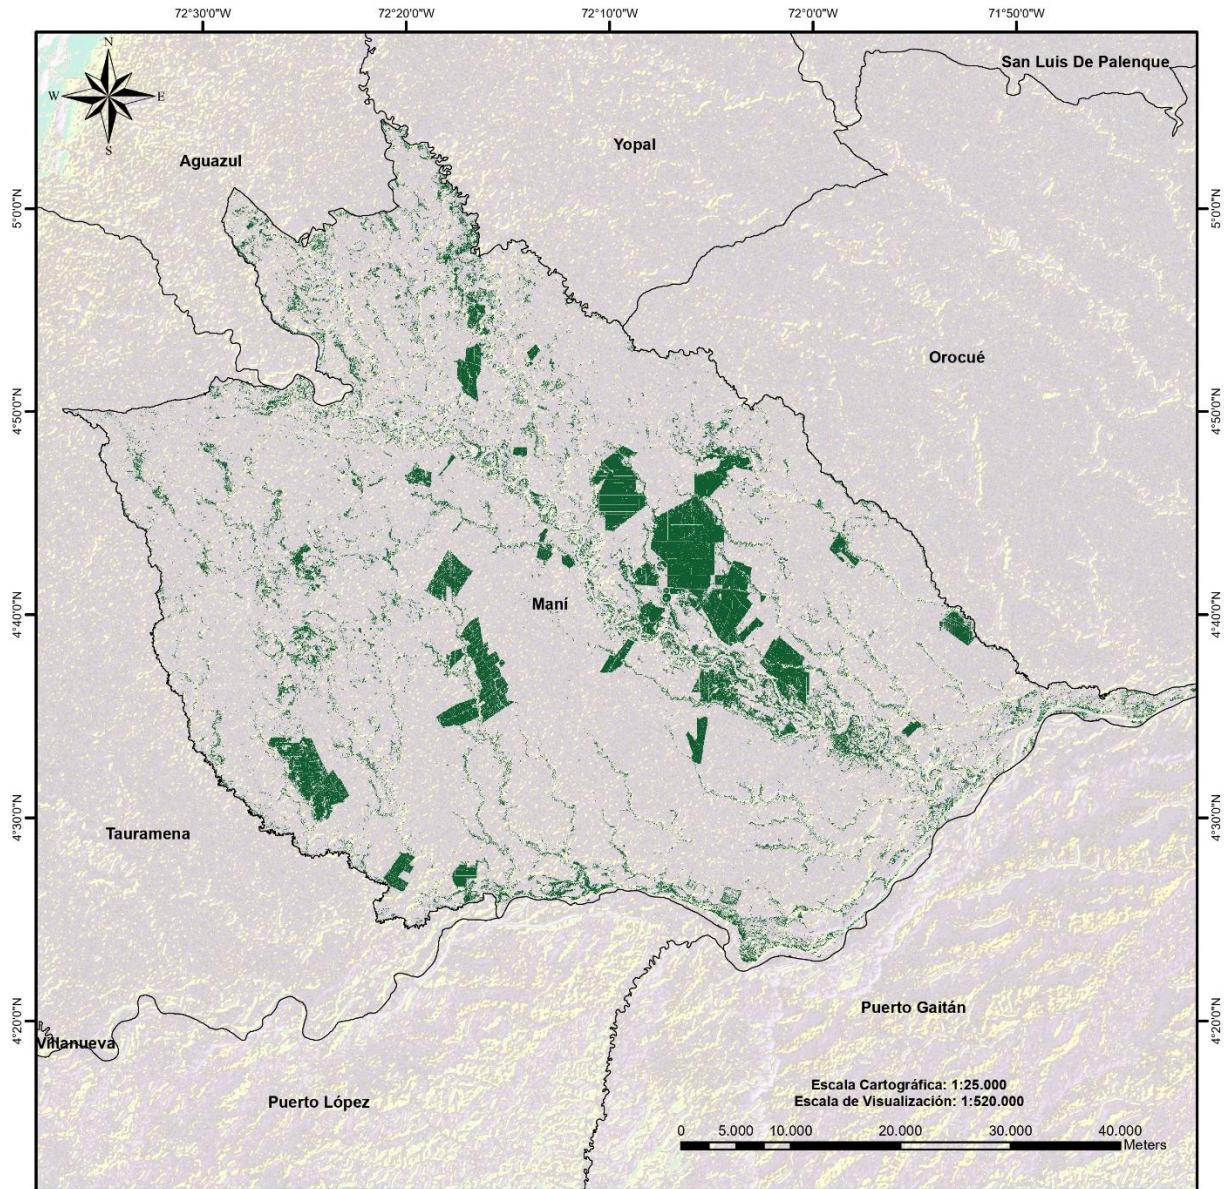
Map.addLayer(Classes, {min:0, max:2, palette: ['#FFFFFF', '#FFFFFF', '#115f32']}, 'Reclasificacion');

// Export Image_Sentinel2_Reclassify
Export.image.toDrive({
  image: Classes.clip(table2),
  description: 'Reclasificacion',
  maxPixels: 1e13,
  scale: 10,
  region: table2,
  fileFormat: 'GeoTIFF',
  crs: 'EPSG:4326'
});

```

**Figura 21.** Código de clasificar y exportar el nuevo raster Reclasificado

Luego de exportar la clasificación supervisada de la cobertura Palma de Aceite, para el municipio de Maní – Casanare, se realizó una salida gráfica final (Figura 22) mediante el software ArcGIS Pro.



**Figura 22.** Identificación de las zonas sembradas con Palma de Aceite en Maní – Casanare

### 3.2 Cuantificación de las áreas sembradas en Palma de Aceite en Maní - Casanare

A continuación, se explica el código (Figura 23) **línea por línea**, en lenguaje de código de JavaScript, dentro de la plataforma de GEE, para la generación del Ortofotomosaico (Figura 24) creado a partir de las imágenes de Planet Scope.

```
var table: Table users/dmera96_taller2/Casanare_Mun
var table2: Table users/dmera96_taller2/MANI_1
////
// Imágenes Planet
//
var nicfi = ee.ImageCollection('projects/planet-nicfi/assets/basemaps/americas');

// Filter basemaps by date and get the first image from filtered results
var basemap= nicfi.filter(ee.Filter.date('2023-01-01', '2023-06-30')).first();

Map.centerObject(basemap, 4)

var vis = {"bands":["R","G","B"],"min":64,"max":5454,"gamma":1.8};

Map.addLayer(basemap.clip(table), vis, '2023-01 mosaic Casanare');
Map.addLayer(basemap.clip(table2), vis, '2023-01 mosaic MANI');
Map.setCenter(-71.376, 5.526, 8);

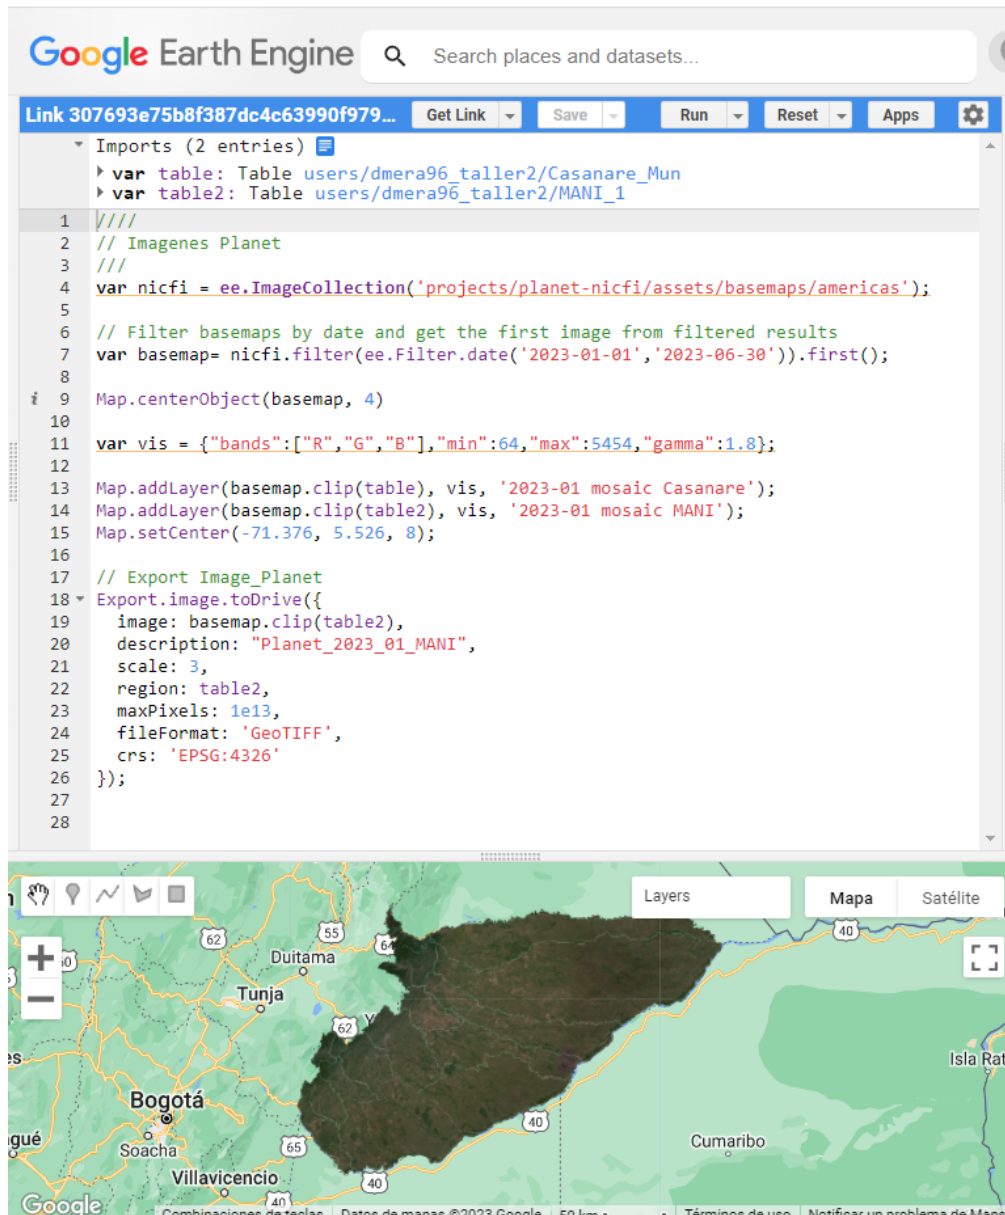
// Export Image_Planet
Export.image.toDrive({
  image: basemap.clip(table2),
  description: "Planet_2023_01_MANI",
  scale: 3,
  region: table2,
  maxPixels: 1e13,
  fileFormat: 'GeoTIFF',
  crs: 'EPSG:4326'
});
```

**Figura 23.** Código para crear y descargar mosaico de imágenes Planet Scopus



**Figura 24.** Ortofotomosaico de imágenes Planet Scopus, para el I-2023 en Maní - Casanare

Para la cuantificación de las áreas sembradas en Palma de Aceite, se realizó un Ortofotomosaico de las Planet Scopus (Figura 24). Esta imagen fue realizada a través de la plataforma de Google Earth Engine, con la colección de imágenes **NICFI Satellite Data Program Basemaps for Tropical Forest Monitoring – Americas**, que dentro de GEE se llama a través de la función `ee.ImageCollection('projects/planet-nicfi/assets/basemaps/americas')`. Es importante mencionar que se debe tener **licencia dentro de la plataforma NICFI** para usar esta colección de imágenes. El código se encuentra en el siguiente enlace: <https://code.earthengine.google.com/307693e75b8f387dc4c63990f979c099> (Figura 25).



The image shows a screenshot of the Google Earth Engine interface. The top part displays the code editor with the following code:

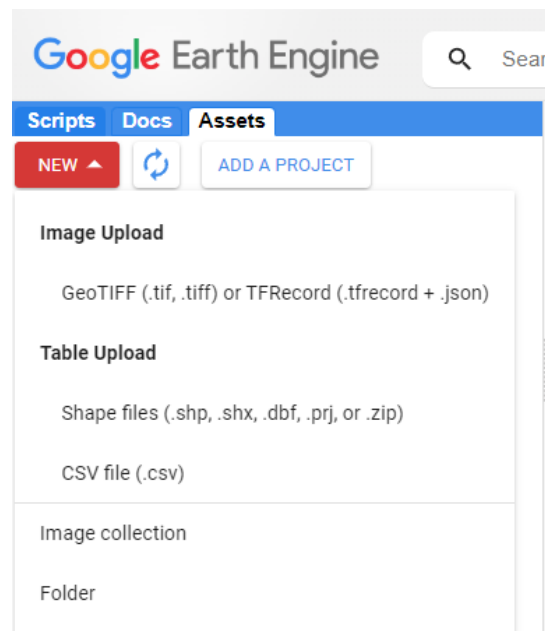
```
Link 307693e75b8f387dc4c63990f979... Get Link Save Run Reset Apps
Imports (2 entries)
  var table: Table users/dmera96_taller2/Casanare_Mun
  var table2: Table users/dmera96_taller2/MANI_1
1 //
2 // Imagenes Planet
3 //
4 var nicfi = ee.ImageCollection('projects/planet-nicfi/assets/basemaps/americas');
5
6 // Filter basemaps by date and get the first image from filtered results
7 var basemap= nicfi.filter(ee.Filter.date('2023-01-01','2023-06-30')).first();
8
9 Map.centerObject(basemap, 4)
10
11 var vis = {"bands":["R","G","B"],"min":64,"max":5454,"gamma":1.8};
12
13 Map.addLayer(basemap.clip(table), vis, '2023-01 mosaic Casanare');
14 Map.addLayer(basemap.clip(table2), vis, '2023-01 mosaic MANI');
15 Map.setCenter(-71.376, 5.526, 8);
16
17 // Export Image_Planet
18 Export.image.toDrive({
19   image: basemap.clip(table2),
20   description: "Planet_2023_01_MANI",
21   scale: 3,
22   region: table2,
23   maxPixels: 1e13,
24   fileFormat: 'GeoTIFF',
25   crs: 'EPSG:4326'
26 });
27
28
```

The bottom part of the screenshot shows a map view of the region around Bogotá, Colombia. The map displays a dark brown area representing the oil palm plantation, overlaid on a satellite image. The map includes various geographical features, roads, and place names like Bogotá, Tunja, Duitama, and Cumaribo. The interface also shows a search bar, a layers panel, and map controls.

**Figura 25.** Visualización del código de clasificación supervisada en GEE

El código (Figura 25), fue adaptado a partir del código recomendado por la plataforma NICFI<sup>2</sup>, con dos modificaciones:

1. Subir el Shape file (“*table2*”) en formato de compresión (.zip), a través de la pestaña “*Assets*”, función “*New*”, “*Table Upload*”, “*Shape files*” (Figura 26). En esta modificación subimos el área de estudio o área de interés.
2. Se uso la función **Export.image.toDrive**, para exportar el Raster resultante (Ortofotomosaico).

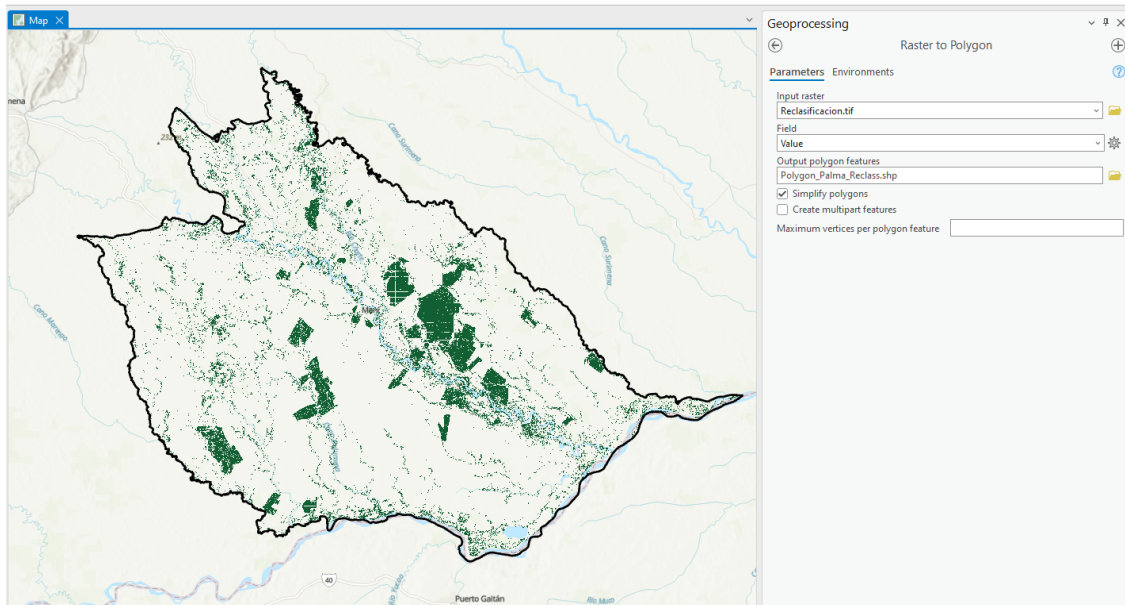


**Figura 26.** Funciones para subir un shape file, dentro de GEE

El siguiente proceso, fue la de conversión de Raster a Polígono, de la clasificación realizada en el Resultado 3.1. Este desarrollo se realizó en el software de ArcGIS PRO, con la función **Raster To Polygon**, del Panel Geoprocessing (Figura 27).

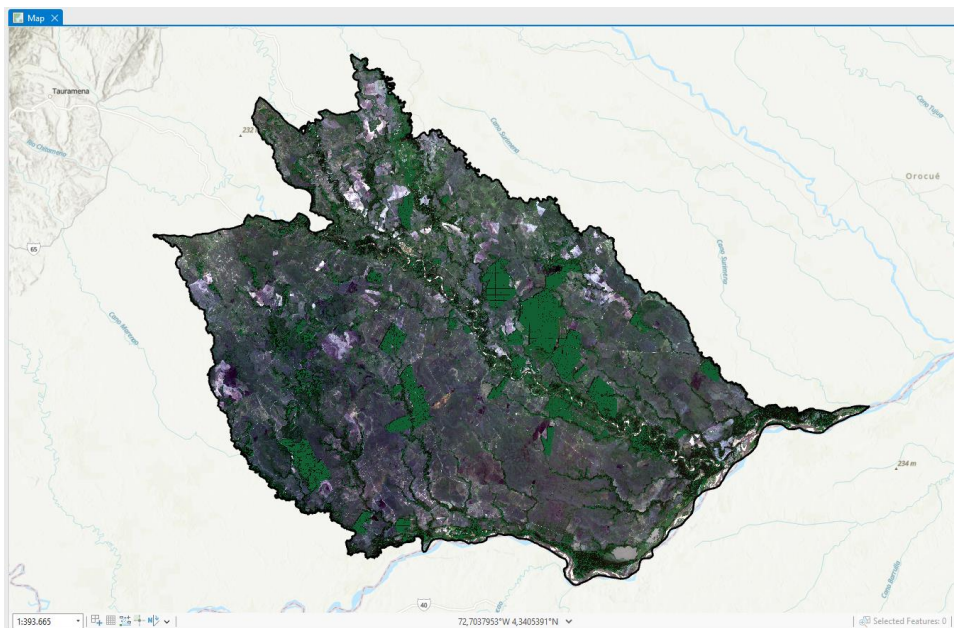
---

<sup>2</sup> [https://developers.google.com/earth-engine/datasets/catalog/projects\\_planet-nicfi\\_assets\\_basemaps\\_americas](https://developers.google.com/earth-engine/datasets/catalog/projects_planet-nicfi_assets_basemaps_americas)



**Figura 27.** Geoprocessing – Raster To Polygon de las Zonas Sembradas en Palma de Aceite

El Ortofotomosaico de Imágenes Planet Scopus, se usó como imagen actualizada y como imagen RGB base (Color Verdadero), para la delimitación de las áreas en palma de aceite del Municipio de Maní Casanare. Una primera visualización se presenta en la Figura 28.



**Figura 28.** Visualización de las áreas sembradas en Palma de Aceite

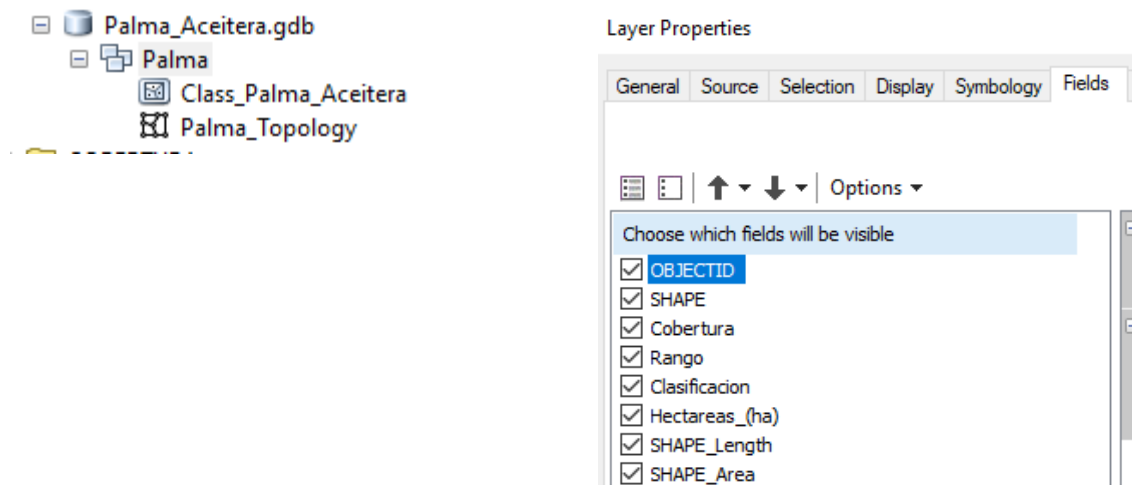
Se continua, con el proceso de superposición (Map Overlay) de Ortofotomosaico de Planet Scopus de 3m x 3m de resolución espacial, con la capa vectorial de las zonas del cultivo en Palma de Aceite, presentado en el Resultado 3.1, logrando un mejor detalle en la delimitación de las áreas en palma de aceite.

Al realizar la superposición se procede al Ajuste y Edición cartográfica de las zonas del cultivo, mediante el software de ArcGIS Pro. Este procedimiento se realizó según el Manual Técnico – “*Elaboración del Producto Digital de Cartografía Temática*” (IGAC, 2021).

El proceso consiste en modificar y/o ajustar polígonos que contienen datos que se encuentran conectados y almacenados dentro de una *File Geodatabase* estructurada con su *Dataset* y con proyección Cartográfica Origen Nacional CTM12 (IGAC, 2020 - Resolución IGAC 471 de mayo 14 de 2020).

Se aplicaron dos *Reglas Topológicas*: i) No Superposición de entidades (*Must Not Overlap*), que nos asegura que ningún polígono o entidad se traslape a otra entidad o dato. ii) No existencia de vacíos (*Must Not have Gaps*), nos indica que los polígonos deben tomar formas continuas sin áreas nulas ni espacios.

Luego de establecer las ajustar los polígonos mediante las Reglas Topológicas mencionadas, la capa resultante presenta 4 atributos, relacionados en la *Tabla de Atributos*, los cuales son: “Cobertura”, “Rango”, “Clasificación” y “Hectáreas (ha)” (Figura 29).



**Figura 29.** Estructuración de ajuste y edición cartográfica de las áreas en Palma de Aceite

Siguiendo la metodología de Caracterización Técnica y Económica de los Proveedores de una Planta de Beneficio (Motta, 2007) de CENIPALMA (Tabla 4), los productores se clasifican según el tamaño de la plantación de la siguiente manera:

**Tabla 4.** Metodología para la clasificación de proveedores de la planta de beneficio (Motta, 2007).

<b>Proveedor</b>	<b>Tamaño de la Plantación</b>
Pequeño	0 - 50 hectáreas
Mediano	51 - 200 hectáreas
Grande	Más de 200 hectáreas

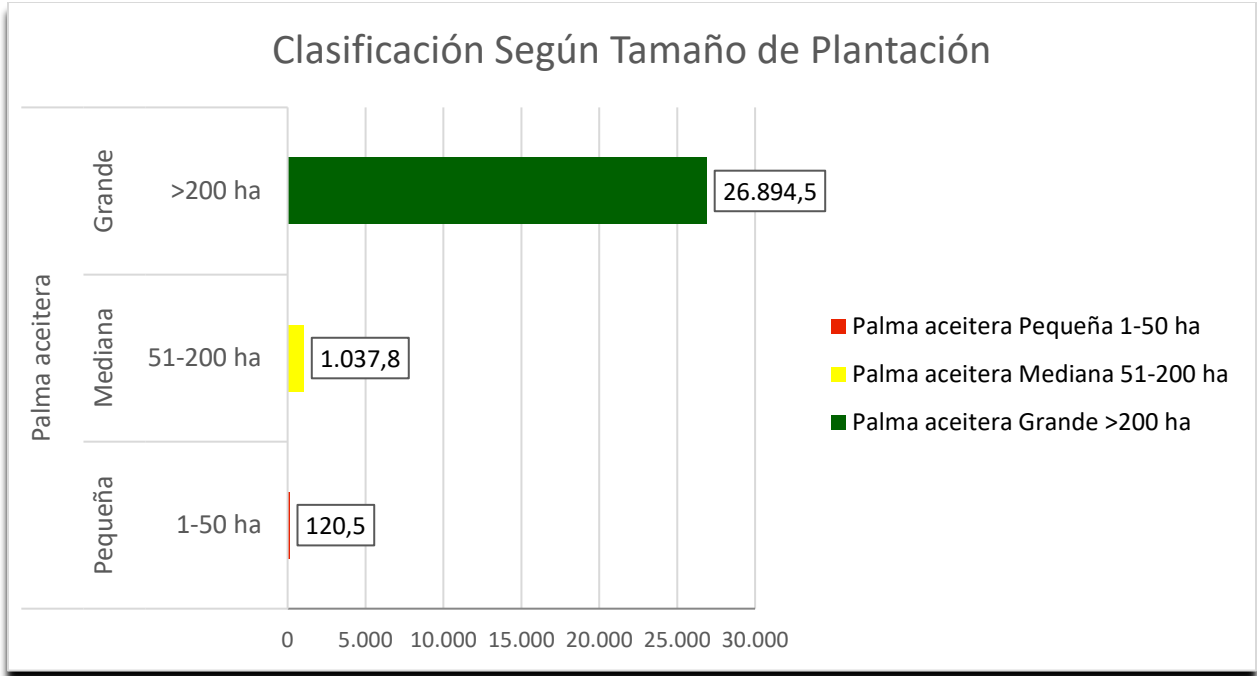
Aplicando la metodología establecida por CENIPALMA, se realizó la clasificación de las áreas sembradas en Palma de Aceite para el Municipio de Maní – Casanare. (Tabla 5), (Figura 30).

**Tabla 5.** Cuantificación de las áreas de Palma de Aceite según Clasificación Cenipalma

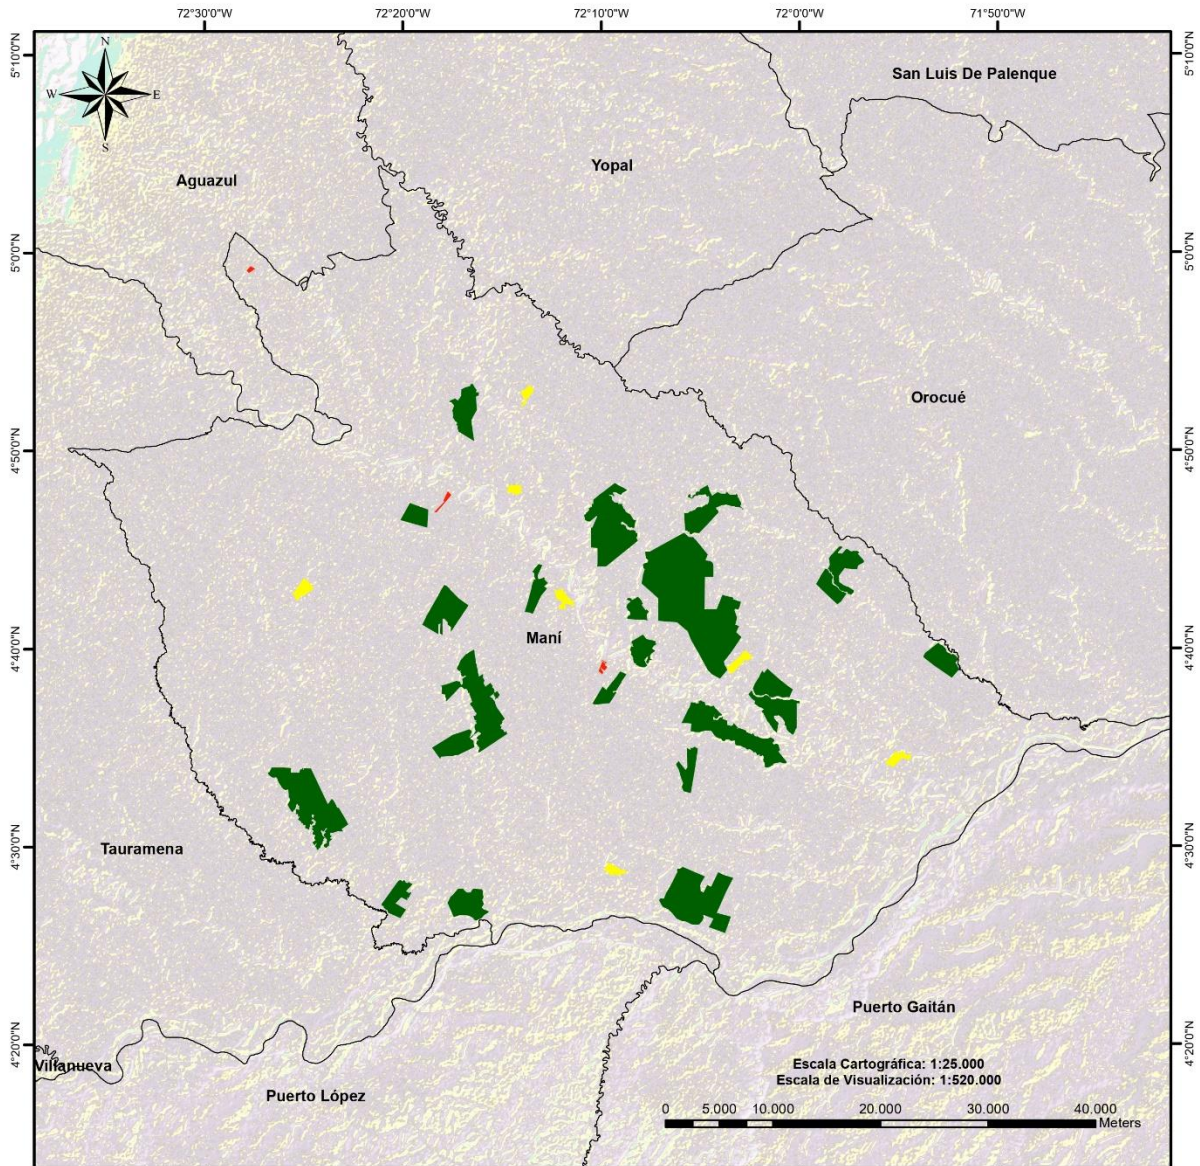
<b>Cobertura</b>	<b>Clasificación</b>	<b>Rango</b>	<b>Hectáreas (ha)</b>	<b>Porcentaje (%)</b>	<b>Número de Plantaciones</b>
<b>Palma aceitera</b>	Pequeña	1-50 ha	120,5	0,4	3
	Mediana	51-200 ha	1.037,8	3,7	7
	Grande	>200 ha	26.894,5	95,9	22
<b>Total General</b>			<b>28.052,7</b>	<b>100,0</b>	<b>32</b>

El 95,9% de las áreas en Palma de Aceite del Municipio de Maní – Casanare, corresponden a plantaciones con un área mayor a 200 ha, con un total de 26.894,5 ha representadas en 22 plantaciones, lo que indica que estas áreas productivas son de un promedio de 1.222,5 ha. En la Figura 31, se presenta la distribución espacial de las plantaciones en Palma de Aceite, según la clasificación de CENIPALMA (Motta, 2007).





**Figura 30.** Clasificación según Tamaño de Plantación de Maní - Casanare



**RESULTADO 3.2**  
**CUANTIFICAR LAS ÁREAS SEMBRADAS EN PALMA DE ACEITE EN MANÍ - CASANARE**  
**LEYENDA**

Cobertura	Clasificación	Rango	Hectáreas (ha)	Porcentaje (%)
Palma aceitera	Pequeña	1-50 ha	120,5	0,4
	Mediana	51-200 ha	1.037,8	3,7
	Grande	>200 ha	26.894,5	95,9
<b>Total General</b>			<b>28.052,7</b>	<b>100,0</b>

ESPECIALIZACIÓN EN SISTEMAS DE INFORMACIÓN GEOGRÁFICA  
**DIANA PATRICIA MERA GARZON**  
 Fuente: Vector Áreas de Palma de Aceite




**Figura 31.** Identificación de las áreas sembradas en Palma de Aceite en el Municipio de Maní – Casanare, para el periodo I-2023

## **Conclusiones**

El desarrollo de esta Guía Metodológica permite la identificación y cuantificación de áreas de cultivo de palma de aceite mediante el uso de la plataforma Google Earth Engine, aprovechando los datos de sensores remotos y algoritmos de Machine Learning en un enfoque de clasificación supervisada.

La guía incluye la creación de un instructivo que detalla de manera clara y precisa los procedimientos necesarios para llevar a cabo esta identificación y cuantificación. El instructivo se basa en un caso de estudio en el municipio de Maní, Casanare, proporcionando una guía práctica para otros usuarios interesados en realizar análisis similares.

Además de su propósito de obtener resultados concretos en la identificación y cuantificación de áreas de cultivo de palma de aceite, la Guía también busca fomentar el intercambio de conocimientos y metodologías. A través de una guía accesible y práctica, se pretende beneficiar a otros usuarios y enriquecer la comprensión de esta técnica de análisis en la comunidad interesada.

## **Recomendaciones**

La Guía Metodológica presentada en este documento se integra con la plataforma de Google Earth Engine (GEE), que, como cualquier herramienta, presenta ciertas limitaciones a considerar. Estas limitaciones incluyen cuotas de procesamiento, restricciones en el almacenamiento (a través de Google Drive), una interfaz de usuario que puede parecer compleja al principio (pero que se supera con tiempo y práctica), y la necesidad de tener conocimientos de programación para aprovechar al máximo sus capacidades. Por lo tanto, se recomienda que esta Guía sea utilizada por personas con experiencia en Sistemas de Información Geográfica (SIG).

Es importante destacar que para acceder a las imágenes de Planet Scope disponibles en GEE, es necesario contar con una cuenta de Gmail enlazada tanto en GEE como a través del programa NICFI (Iniciativa Internacional sobre Clima y Bosques de Noruega). Si no se dispone de acceso a este tipo de cuenta, se generará una limitación que impedirá la descarga de ortofotomosaicos de Planet Scope. Por lo tanto, se recomienda enlazar ambas cuentas a la misma dirección de Gmail.

Además, es esencial reconocer que la eficacia del procesamiento de imágenes, ya sea en ArcGIS Pro u en otro software SIG similar, está estrechamente ligada a la comprensión tanto de los datos como de las herramientas que ofrece la plataforma. La perseverancia en la práctica y la búsqueda continua de conocimientos adicionales son fundamentales para perfeccionar las habilidades en este ámbito.

Cabe resaltar que esta guía se ha diseñado específicamente para la identificación y cuantificación de cultivos de palma de aceite y no es adecuada para otros tipos de cultivos.

## Referencias Bibliográficas

- Adepoju, K. A., & Adelabu, S. A. (2020). Improving accuracy evaluation of Landsat-8 OLI using image composite and multisource data with Google Earth Engine. *Remote Sensing Letters*, 11(2), 107–116. <https://doi.org/10.1080/2150704X.2019.1690792>
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., Moghaddam, S. H. A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q., & Brisco, B. (2020). Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5326–5350. <https://doi.org/10.1109/JSTARS.2020.3021052>
- Amani, M., Mahdavi, S., Afshar, M., Brisco, B., Huang, W., Mirzadeh, S. M. J., White, L., Banks, S., Montgomery, J., & Hopkinson, C. (2019). Canadian wetland inventory using Google Earth Engine: The first map and preliminary results. *Remote Sensing*, 11(7). <https://doi.org/10.3390/RS11070842>
- Ang, Y., Shafri, H. Z. M., Lee, Y. P., Bakar, S. A., Abidin, H., Mohd Junaidi, M. U. U., Hashim, S. J., Che'Ya, N. N., Hassan, M. R., Lim, H. S., Abdullah, R., Yusup, Y., Muhammad, S. A., Teh, S. Y., & Samad, M. N. (2022). Oil palm yield prediction across blocks from multi-source data using machine learning and deep learning. *Earth Science Informatics*, 15(4), 2349–2367. <https://doi.org/10.1007/S12145-022-00882-9/METRICS>
- Arias, A., Darghan, N. A. ;, Rivera, A. E. ; Beltran, C. ; Typology, J. A., Martínez-Arteaga, D., Atanasio, N., Darghan, A. E., Rivera, C., & Beltran, J. A. (2023). Typology of Irrigation Technology Adopters in Oil Palm Production: A Categorical Principal Components and Fuzzy Logic Approach. *Sustainability 2023, Vol. 15, Page 9944*, 15(13), 9944. <https://doi.org/10.3390/SU15139944>
- Asming, M. A. A., Ibrahim, A. M., & Abir, I. M. (2022). Processing and classification of landsat and sentinel images for oil palm plantation detection. *Remote Sensing Applications: Society and Environment*, 26, 100747. <https://doi.org/10.1016/J.RSASE.2022.100747>
- Azhar, B., Saadun, N., Prideaux, M., & Lindenmayer, D. B. (2017). The global palm oil sector must change to save biodiversity and improve food security in the tropics. In *Journal of Environmental Management* (Vol. 203, pp. 457–466). Academic Press. <https://doi.org/10.1016/j.jenvman.2017.08.021>
- Basiron, Y. (2007). Palm oil production through sustainable plantations. *European Journal of Lipid Science and Technology*, 109(4), 289–295. <https://doi.org/10.1002/ejlt.200600223>

- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 114, pp. 24–31). Elsevier B.V. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Breiman, L. (2001). *Random Forests* (Vol. 45).
- Carlson, K. M., Curran, L. M., Asner, G. P., Pittman, A. M. D., Trigg, S. N., & Marion Adeney, J. (2013). Carbon emissions from forest conversion by Kalimantan oil palm plantations. *Nature Climate Change*, 3(3), 283–287. <https://doi.org/10.1038/nclimate1702>
- Chemura, A., van Duren, I., & van Leeuwen, L. M. (2015). Determination of the age of oil palm from crown projection area detected from WorldView-2 multispectral remote sensing data: The case of Ejisu-Juaben district, Ghana. *ISPRS Journal of Photogrammetry and Remote Sensing*, 100, 118–127. <https://doi.org/10.1016/j.isprsjprs.2014.07.013>
- Chong, K. L., Kanniah, K. D., Pohl, C., & Tan, K. P. (2017). A review of remote sensing applications for oil palm studies. *Geo-Spatial Information Science*, 20(2), 184–200. <https://doi.org/10.1080/10095020.2017.1337317>
- Chuvieco, E. (2016). Fundamentals of Satellite Remote Sensing : An Environmental Approach, Second Edition. *Fundamentals of Satellite Remote Sensing*. <https://doi.org/10.1201/B19478>
- De Alban, J. D. T., Connette, G. M., Oswald, P., & Webb, E. L. (2018). Combined Landsat and L-band SAR data improves land cover classification and change detection in dynamic tropical landscapes. *Remote Sensing*, 10(2). <https://doi.org/10.3390/rs10020306>
- Fang, H., Baret, F., Plummer, S., & Schaepman-Strub, G. (2019). An Overview of Global Leaf Area Index (LAI): Methods, Products, Validation, and Applications. In *Reviews of Geophysics* (Vol. 57, Issue 3, pp. 739–799). Blackwell Publishing Ltd. <https://doi.org/10.1029/2018RG000608>
- Fawcett, D., Azlan, B., Hill, T. C., Kho, L. K., Bennie, J., & Anderson, K. (2019). Unmanned aerial vehicle (UAV) derived structure-from-motion photogrammetry point clouds for oil palm (*Elaeis guineensis*) canopy segmentation and height estimation. *International Journal of Remote Sensing*, 40(19), 7538–7560. <https://doi.org/10.1080/01431161.2019.1591651>
- Fedapalma. (2021). *Informe de Gestión Fedepalma*. <https://publicaciones.fedepalma.org/index.php/labfedepalma/issue/view/1543/>
- 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/10.1016/j.rse.2017.06.031>

- Hamsa, C. S., Kanniah, K. D., Muharam, F. M., Idris, N. H., Abdullah, Z., & Mohamed, L. (2019). Textural measures for estimating oil palm age. *International Journal of Remote Sensing*, 40(19), 7516–7537. <https://doi.org/10.1080/01431161.2018.1530813>
- Ibragimov, A., Sidique, S. F., & Tey, Y. S. (2019). Productivity for sustainable growth in Malaysian oil palm production: A system dynamics modeling approach. *Journal of Cleaner Production*, 213, 1051–1062. <https://doi.org/10.1016/j.jclepro.2018.12.113>
- Ienco, D., Interdonato, R., Gaetano, R., & Ho Tong Minh, D. (2019). Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. *ISPRS Journal of Photogrammetry and Remote Sensing*, 158, 11–22. <https://doi.org/10.1016/j.isprsjprs.2019.09.016>
- IGAC. (2021). *Instructivo elaboración del producto digital de cartografía temática grupo interno de trabajo geomática.*
- Joshi, N., Baumann, M., Ehammer, A., Fensholt, R., Grogan, K., Hostert, P., Jepsen, M. R., Kuemmerle, T., Meyfroidt, P., Mitchard, E. T. A., Reiche, J., Ryan, C. M., & Waske, B. (2016). A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. In *Remote Sensing* (Vol. 8, Issue 1). MDPI AG. <https://doi.org/10.3390/rs8010070>
- Khairunniza-Bejo, S., Shahibullah, M. S., Nabilah, A., Azmi, N., Jahari, M., Fernandez-Blanco, E., & Rivero, D. (2021). Non-Destructive Detection of Asymptomatic Ganoderma boninense Infection of Oil Palm Seedlings Using NIR-Hyperspectral Data and Support Vector Machine. *Applied Sciences 2021*, Vol. 11, Page 10878, 11(22), 10878. <https://doi.org/10.3390/APP112210878>
- Lee, J. S. H., Wich, S., Widayati, A., & Koh, L. P. (2016). Detecting industrial oil palm plantations on Landsat images with Google Earth Engine. *Remote Sensing Applications: Society and Environment*, 4, 219–224. <https://doi.org/10.1016/j.rsase.2016.11.003>
- Liaghat, S., Ehsani, R., Mansor, S., Shafri, H. Z. M., Meon, S., Sankaran, S., & Azam, S. H. M. N. (2014). Early detection of basal stem rot disease (Ganoderma) in oil palms based on hyperspectral reflectance data using pattern recognition algorithms. *International Journal of Remote Sensing*, 35(10), 3427–3439. <https://doi.org/10.1080/01431161.2014.903353>
- Li, L., Dong, J., Tenku, S. N., & Xiao, X. (2015). Mapping oil palm plantations in cameroon using PALSAR 50-m orthorectified mosaic images. *Remote Sensing*, 7(2), 1206–1224. <https://doi.org/10.3390/rs70201206>

- Li, W., Fu, H., Yu, L., & Cracknell, A. (2017). Deep learning based oil palm tree detection and counting for high-resolution remote sensing images. *Remote Sensing*, 9(1). <https://doi.org/10.3390/rs9010022>
- Lu, D., Chen, Q., Wang, G., Liu, L., Li, G., & Moran, E. (2016). A survey of remote sensing-based aboveground biomass estimation methods in forest ecosystems. In *International Journal of Digital Earth* (Vol. 9, Issue 1, pp. 63–105). Taylor and Francis Ltd. <https://doi.org/10.1080/17538947.2014.990526>
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. In *International Journal of Remote Sensing* (Vol. 28, Issue 5, pp. 823–870). Taylor and Francis Ltd. <https://doi.org/10.1080/01431160600746456>
- Mahesh, B. (2018). Machine Learning Algorithms-A Review. *International Journal of Science and Research*. <https://doi.org/10.21275/ART20203995>
- Motta, V. , D. F. , M. G. , & S. G. (2007). *Coporación Centro de Investigación en Plama de Aceite*.
- Nasiri, V., Deljouei, A., Moradi, F., Sadeghi, S. M. M., & Borz, S. A. (2022). Land Use and Land Cover Mapping Using Sentinel-2, Landsat-8 Satellite Images, and Google Earth Engine: A Comparison of Two Composition Methods. *Remote Sensing 2022, Vol. 14, Page 1977, 14(9), 1977*. <https://doi.org/10.3390/RS14091977>
- Niemeyer, J., Rottensteiner, F., & Soergel, U. (2014). Contextual classification of lidar data and building object detection in urban areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 152–165. <https://doi.org/10.1016/j.isprsjprs.2013.11.001>
- Noi Phan, T., Kuch, V., & Lehnert, L. W. (2020). Land cover classification using google earth engine and random forest classifier-the role of image composition. *Remote Sensing*, 12(15). <https://doi.org/10.3390/RS12152411>
- Nooni, I. K., Duker, A. A., Van Duren, I., Addae-Wireko, L., & Osei Jnr, E. M. (2014). Support vector machine to map oil palm in a heterogeneous environment. *International Journal of Remote Sensing*, 35(13), 4778–4794. <https://doi.org/10.1080/01431161.2014.930201>
- Oil World. (2023). *OIL WORLD ISTA Mielke GmbH: Independent Global Market Analyses & Forecasts Since 1958*. <https://www.oilworld.biz/>
- RSPO. (2007). *RSPO Principles and Criteria for Sustainable Palm Oil Production Including Indicators and Guidance*.



- Santoso, H., Gunawan, T., Jatmiko, R. H., Darmosarkoro, W., & Minasny, B. (2011). Mapping and identifying basal stem rot disease in oil palms in North Sumatra with QuickBird imagery. *Precision Agriculture*, *12*(2), 233–248. <https://doi.org/10.1007/s11119-010-9172-7>
- Santoso, H., Tani, H., & Wang, X. (2016). A simple method for detection and counting of oil palm trees using high-resolution multispectral satellite imagery. *International Journal of Remote Sensing*, *37*(21), 5122–5134. <https://doi.org/10.1080/01431161.2016.1226527>
- Sarzynski, T., Giam, X., Carrasco, L., & Huay Lee, J. S. (2020). Combining radar and optical imagery to map oil palm plantations in Sumatra, Indonesia, using the Google Earth Engine. *Remote Sensing*, *12*(7). <https://doi.org/10.3390/rs12071220>
- Shafira, N., Shaharum, N., Shafri, H., Azlina, W., Ab, W., Ghani, K., Samsatli, S., Al-Habshi, M., Yusuf, B., Zulhaidi, H., Shafri, M., Mustafa, M., & Al-Habshi, A. (2020). Oil Palm Mapping Over Peninsular Malaysia Using Google Earth Engine and Machine Learning Algorithms. *Remote Sensing Applications: Society and Environment*, *17*, 100287. <https://doi.org/10.1016/J.RSASE.2020.100287>
- Shafri, H. Z. M., Anuar, M. I., Seman, I. A., & Noor, N. M. (2011). Spectral discrimination of healthy and ganoderma-infected oil palms from hyperspectral data. *International Journal of Remote Sensing*, *32*(22), 7111–7129. <https://doi.org/10.1080/01431161.2010.519003>
- Sheykhmousa, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. In *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* (Vol. 13, pp. 6308–6325). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/JSTARS.2020.3026724>
- Srestasathiern, P., & Rakwatin, P. (2014). Oil palm tree detection with high resolution multi-spectral satellite imagery. *Remote Sensing*, *6*(10), 9749–9774. <https://doi.org/10.3390/rs6109749>
- Stehman, S. V. (1997). & Forestry, 320 Bray Hall, Syrxusr, NY 13210. In *REMOTE SENS. ENVIHON* (Vol. 62). OElsevier Science Inc.
- Sun, Y., Qin, Q., Ren, H., Zhang, T., & Chen, S. (2020). Red-Edge Band Vegetation Indices for Leaf Area Index Estimation from Sentinel-2/MSI Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, *58*(2), 826–840. <https://doi.org/10.1109/TGRS.2019.2940826>

- Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. In *ISPRS Journal of Photogrammetry and Remote Sensing* (Vol. 164, pp. 152–170). Elsevier B.V. <https://doi.org/10.1016/j.isprsjprs.2020.04.001>
- Tan, K. P., Kanniah, K. D., & Cracknell, A. P. (2013). Use of UK-DMC 2 and ALOS PALSAR for studying the age of oil palm trees in southern peninsular Malaysia. *International Journal of Remote Sensing*, *34*(20), 7424–7446. <https://doi.org/10.1080/01431161.2013.822601>
- VAS3K, B. L. O. G. (2023). *Machine Learning for Everyone — In simple words. With real-world examples. Yes, again — vas3k*. [https://vas3k.com/blog/machine\\_learning/](https://vas3k.com/blog/machine_learning/)
- Victor, B., He, Z., & Nibali, A. (2022). *A systematic review of the use of Deep Learning in Satellite Imagery for Agriculture*. <https://arxiv.org/abs/2210.01272v1>
- Webster, C. C. (1969). The Oil Palm. C. W. S. Hartley. London: Longmans, Green (1967), pp. 706, 126s. *Experimental Agriculture*, *5*(3), 261–262. <https://doi.org/10.1017/S0014479700004543>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, *236*. <https://doi.org/10.1016/j.rse.2019.111402>
- Wong-in, T., Kaewkongka, T., Cooharajanone, N., & Lipikorn, R. (2015). Automatic oil palm detection and identification from multi-scale clustering and normalized cross correlation. *Lecture Notes in Electrical Engineering*, *349*, 403–410. [https://doi.org/10.1007/978-3-662-47200-2\\_43](https://doi.org/10.1007/978-3-662-47200-2_43)
- Yang, L., Driscoll, J., Sarigai, S., Wu, Q., Chen, H., & Lippitt, C. D. (2022). Google Earth Engine and Artificial Intelligence (AI): A Comprehensive Review. *Remote Sensing 2022*, *Vol. 14*, Page 3253, *14*(14), 3253. <https://doi.org/10.3390/RS14143253>