



FACULTAD DE INGENIERÍA GEOGRÁFICA, AMBIENTAL Y ECOTURISMO

ANÁLISIS MULTITEMPORAL PARA DETERMINAR LA EXPANSIÓN DE PALMA
ACEITERA (*Elaeis guineensis*) EN EL DISTRITO NUEVA REQUENA,
PROVINCIA CORONEL PORTILLO, REGIÓN UCAYALI 2016-2022

Línea de investigación:
Procesamiento digital de imágenes y señales

Tesis para optar el Título Profesional de Ingeniero Geógrafo

Autora

Villanueva Delgado, Susy Araceli

Asesor

Zamora Talaverano, Noe Sabino

ORCID: 0000-0002-4368-8955

Jurado


Alva Velasquez, Miguel

Osorio Rojas, Eberardo Antonio

Legua Terry, Alberto Israel

Lima - Perú

2025



"ANÁLISIS MULTITEMPORAL EN GOOGLE EARTH ENGINE PARA DETERMINAR LA EXPANSIÓN DE PALMA ACEITERA (*Elaeis guineensis*) EN EL DISTRITO NUEVA REQUENA, PROVINCIA CORONEL PORTILLO, REGIÓN UCAYALI 2016-2022."

INFORME DE ORIGINALIDAD

27%

INDICE DE SIMILITUD

26%

FUENTES DE INTERNET

11%

PUBLICACIONES

9%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	hdl.handle.net Fuente de Internet	8%
2	www.forestpeoples.org Fuente de Internet	2%
3	www.slideshare.net Fuente de Internet	1%
4	repositorio.unfv.edu.pe Fuente de Internet	1%
5	repositorio.uade.edu.ar Fuente de Internet	1%
6	Submitted to Escuela Superior Politécnica del Litoral Trabajo del estudiante	1%
7	www.ssoar.info Fuente de Internet	<1%
8	repositorio.unu.edu.pe Fuente de Internet	<1%
9	www.uncuyo.edu.ar Fuente de Internet	<1%
10	issuu.com Fuente de Internet	<1%



Universidad Nacional
Federico Villarreal

VRIN | VICERRECTORADO
DE INVESTIGACIÓN

FACULTAD DE INGENIERÍA GEOGRÁFICA, AMBIENTAL Y ECOTURISMO

**ANÁLISIS MULTITEMPORAL PARA DETERMINAR LA EXPANSIÓN DE PALMA
ACEITERA (*Elaeis guineensis*) EN EL DISTRITO NUEVA REQUENA, PROVINCIA
CORONEL PORTILLO, REGIÓN UCAYALI 2016-2022.**

**Línea de investigación:
Procesamiento digital de imágenes y señales**

Tesis para optar el título profesional de Ingeniero Geógrafo

Autora:

Villanueva Delgado, Susy Araceli

Asesor:

Zamora Talaverano, Noe Sabino

ORCID: 0000-0002-4368-8955

Jurado:

Alva Velasquez, Miguel

Osorio Rojas, Eberardo Antonio

Legua Terry, Alberto Israel

Lima - Perú

2025

Dedicatoria:

A mi Dios y Salvador Jesucristo por su
redención.

A mi hijo Thiago Stephano, a mis padres
Teodora y Ángel y a mis hermanos por estar
siempre para mí.

Agradecimiento:

Agradezco al Señor por sus misericordias que son nuevas cada mañana, porque es grande en fidelidad y tan grande fue su amor que entregó su vida para darnos vida eterna.

Agradecer a mi hijo Thiago Stephano por enseñarme cada día la resiliencia, y sobre todo a ser madre.

A mis padres por ser mi soporte y por enseñarme a no rendirme.

Al equipo de la Coordinación del Sistema de Información Geográfica del Organismo de Evaluación y Fiscalización Ambiental por aportarme sus conocimientos y experiencias en SIG.

A mi alma mater, la Universidad Nacional Federico Villarreal por los conocimientos y experiencias brindadas.

ÍNDICE

Resumen	x
Abstract.....	xi
I. INTRODUCCIÓN.....	1
1.1. Descripción y planteamiento del problema de investigación	1
1.1.1. Descripción del problema	1
1.1.2. Planteamiento del problema.....	3
1.2. Antecedentes	4
1.2.1. Antecedentes Nacionales	4
1.2.2. Antecedentes internacionales.....	5
1.3. Objetivos.....	8
1.3.1. Objetivo General.....	8
1.3.2. Objetivos específicos	8
1.4. Justificación	9
1.5. Hipótesis	12
1.5.1. Hipótesis General.....	12
1.5.2. Hipótesis Específicas	12
II. MARCO TEÓRICO.....	13
2.1. Bases teóricas sobre el tema de investigación	13
2.1.1. Teledetección	13
2.1.2. Espectro Electromagnético	14
2.1.3. Tipos de Sensores	16
2.1.4. Tipos de Resoluciones	17
2.1.5. Análisis multitemporal.....	19
2.1.6. Programa Landsat	20
2.1.7. Programa Copernicus.....	21
2.1.8. Google Earth Engine.....	22

2.1.9.	Clasificación Supervisada.....	23
2.1.10.	Clasificación No Supervisada.....	24
2.1.11.	Índices de cobertura.....	24
2.1.12.	Palma Aceitera.....	26
2.1.13.	Palma Aceitera en Perú.....	28
2.2.	Marco Legal.....	30
2.2.1.	Constitución Política del Perú. 1993.....	30
2.2.2.	Ley de Áreas Naturales Protegidas. Ley n° 26834, del 4/08/97.....	30
2.2.3.	Ley General del Ambiente. Ley 28611 del 15/10/2005.....	30
2.2.4.	Ley Orgánica para el Aprovechamiento Sostenido de los Recursos Naturales. Ley n° 26821 del 26 /06/97.....	31
2.2.5.	Ley Sobre la Conservación y Aprovechamiento Sostenible de la Diversidad Biológica. Ley n° 26839 del 16/07/97.....	31
2.2.6.	Ley Forestal y de Fauna Silvestre Ley N.° 29763 del 22/07/2011.....	31
2.2.7.	Ley de Promoción de la Inversión en la Amazonía (Ley N° 27037).....	33
2.2.8.	Reglamento de la Ley Forestal y de Fauna Silvestre (Decreto Supremo N° 014-2015-MINAGRI).....	33
2.2.9.	Resolución Ministerial N° 015-2001-AG, que aprueba el Plan Nacional de Promoción de la Palma Aceitera, para el periodo comprendido entre los años 2000 al 2010.....	34
2.2.10.	Ley N° 30428 Ley que oficializa el Sistema de Cuadrículas Mineras en Coordenadas UTM WGS84.....	35
III.	MÉTODO.....	36
3.1.	Tipo de Investigación.....	36
3.2.	Ámbito temporal y espacial.....	36
3.3.	Variables.....	37
3.4.	Población y muestra.....	38
3.5.	Instrumentos.....	38

3.6.	Procedimientos.....	40
3.6.1.	Primera etapa: Preparación de datos.....	41
3.6.2.	Segunda etapa: Preprocesamiento.....	41
3.6.3.	Tercera etapa: Procesamiento.....	41
3.6.4.	Cuarta etapa: Análisis de resultados.....	58
3.7.	Análisis de datos.....	58
3.8.	Consideraciones éticas.....	58
IV.	RESULTADOS.....	59
4.1.	Arquitectura de procesamiento.....	59
4.2.	Medios Tecnológicos.....	60
4.3.	Criterios y técnicas de análisis.....	62
4.4.	Determinación de la expansión de la palma aceitera.....	66
4.5.	Mapa de Cobertura 2016.....	69
4.6.	Mapa de Cobertura 2022.....	70
V.	DISCUSIÓN DE RESULTADOS.....	71
VI.	CONCLUSIONES.....	74
VII.	RECOMENDACIONES.....	75
VIII.	REFERENCIAS.....	76
IX.	ANEXOS.....	83

ÍNDICE DE TABLAS

Tabla 1 Descripción del Espectro Electromagnético.	15
Tabla 2 Resolución Espectral y Temporal del satélite Sentinel 2.	18
Tabla 3 Franja temporal de las misiones Landsat.	20
Tabla 4 Características de la misión Sentinel.	21
Tabla 5 Necesidades ambientales básicas de la palma africana.	27
Tabla 6 Detalle de la variable independiente.	37
Tabla 7 Detalle de la variable dependiente.	38
Tabla 8 Instrumentos y Equipos.	38
Tabla 9 Procesamiento en Google Earth Engine.	42
Tabla 10 Precisión de la clasificación supervisada por algoritmo	64
Tabla 11 Estadísticas para la clasificación supervisada para el año 2016 y 2022	66

ÍNDICE DE FIGURAS

Figura 1 Componentes de un sistema de teledetección (Chuvienco, 1995).	14
Figura 2 Espectro Electromagnético.....	15
Figura 3 Sensor Pasivo.	16
Figura 4 Sensor Activo	17
Figura 5 Estudio multitemporal de la cuenca media del Río Magdalena.	20
Figura 6 Editor de Código de Google Earth Engine.....	22
Figura 7 Curva de reflectancia de una hoja verde sana.	25
Figura 8 Fases de desarrollo de la palma de aceite.....	27
Figura 9 Ámbito espacial de la investigación.....	37
Figura 10 Flujo para la detección de expansión de Palma Aceitera.	40
Figura 11 Búsqueda de imágenes por fechas.....	41
Figura 12 Script de búsqueda de imágenes del año 2016	44
Figura 13 Script de búsqueda de imágenes del año 2022	45
Figura 14 Script de la clasificación supervisada del año 2016.	47
Figura 15 Puntos de entrenamiento para la cobertura Agua.....	48
Figura 16 Puntos de entrenamiento para la cobertura Bosque denso	49
Figura 17 Puntos de entrenamiento para la cobertura Suelo desnudo	49
Figura 18 Puntos de entrenamiento para la cobertura Palma.....	50
Figura 19 Puntos de entrenamiento para la cobertura Pastizal	50
Figura 20 Puntos de entrenamiento de todas las coberturas (2016)	51
Figura 21 Clasificación Random Forest	52
Figura 22 Clasificación Support vector Machine SVM.....	53
Figura 23 Clasificación CART	54
Figura 24 Clasificación Mínima Distancia	55

Figura 25 Clasificación Naive Bayes.....	56
Figura 26 Script de la clasificación supervisada del año 2022.	57
Figura 27 Arquitectura de procesamiento de imágenes satelitales.	59
Figura 28 Resultados de la clasificación Random Forest.....	62
Figura 29 Resultados de la clasificación Support vector Machine SVM.....	62
Figura 30 Resultados de la clasificación CART.....	63
Figura 31 Resultados de la clasificación Mínima Distancia.....	63
Figura 32 Resultados de la clasificación Naive Bayes.....	64
Figura 33 Precisión de la clasificación supervisada por algoritmo.....	65
Figura 34 Porcentaje por cobertura en el año 2016.....	67
Figura 35 Porcentaje por cobertura en el año 2022.....	67
Figura 36 Área de coberturas por año.....	68
Figura 37 Mapa de clasificación supervisada del año 2016.....	69
Figura 38 Mapa de clasificación supervisada del año 2022.....	70

Resumen

El presente estudio tuvo como objetivo principal aplicar el análisis multitemporal de imágenes satelitales en Google Earth Engine para determinar la expansión del cultivo de palma aceitera (*Elaeis guineensis*) en el distrito de Nueva Requena, provincia Coronel Portillo, región Ucayali, durante el periodo 2016-2022. En este sentido, se llevó a cabo una investigación de tipo descriptiva y cuantitativa. Por un lado, se describió y caracterizó la expansión del cultivo en un periodo de siete años; por otro lado, se cuantificó el área de expansión mediante el uso de imágenes satelitales Sentinel 2 y la aplicación de técnicas específicas, como la clasificación supervisada. Los resultados obtenidos evidencian que el algoritmo de clasificación supervisada Support Vector Machine (SVM) fue el más preciso para identificar el cultivo de palma aceitera con una precisión general del 89.5%. En 2016, la superficie cubierta por plantaciones de palma aceitera ascendía a 97.33 km², representando un 4.65% del área total del distrito. Sin embargo, para el año 2022, se observó un notable incremento, alcanzando los 300.59 km² y representando el 14.36% del área total. En conclusión, mediante la aplicación del análisis multitemporal de imágenes satelitales en Google Earth Engine, se evidenció un crecimiento de 203.26 km² en la expansión de cultivo de palma aceitera en el distrito de Nueva Requena entre 2016 y 2022, lo que implica un crecimiento porcentual del 9.71% en la cobertura de palma aceitera durante este período.

Palabras clave: análisis multitemporal, imágenes satelitales, Google Earth Engine, palma aceitera, clasificación supervisada, teledetección.

Abstract

The primary objective of this study was to apply multi-temporal analysis of satellite imagery in Google Earth Engine to determine the expansion of oil palm cultivation (*Elaeis guineensis*) in Nueva Requena district, Coronel Portillo province, Ucayali region, during the 2016-2022 period. This research was both descriptive and quantitative in nature. On the one hand, it described and characterized the expansion of cultivation over a seven-year period; on the other hand, it quantified the area of expansion using Sentinel 2 satellite imagery and specific techniques such as supervised classification. The findings demonstrate that the Support Vector Machine (SVM) supervised classification algorithm achieved the highest precision in detecting oil palm cultivation, with an overall accuracy of 89.5%. In 2016, the area covered by oil palm plantations amounted to 97.33 km², representing 4.65% of the total district area. However, by 2022, a significant increase was observed, reaching 300.59 km² and representing 14.36% of the total area. In conclusion, through the application of multi-temporal analysis of satellite imagery in Google Earth Engine, a growth of 203.26 km² in the expansion of oil palm cultivation in the Nueva Requena district was evidenced between 2016 and 2022, implying a 9.71% growth in oil palm coverage during this period. This research highlights the importance of continuously monitoring changes in land use and their environmental and socioeconomic implications in the region.

Keywords: multitemporal analysis, satellite imagery, Google Earth Engine, oil palm, supervised classification, remote sensing.

I. INTRODUCCIÓN

1.1. Descripción y planteamiento del problema de investigación

1.1.1. Descripción del problema

La palma aceitera, un cultivo de gran relevancia económica en la región Ucayali, ha experimentado una expansión significativa en los últimos años. Sin embargo, este crecimiento ha desencadenado una serie de consecuencias negativas tanto para el entorno ambiental como para la calidad de vida de las comunidades locales que residen en la zona.

Desde 2002 hasta 2021, Ucayali perdió 480 000 ha de bosque primario húmedo, lo que representa 71% de pérdida de cobertura boscosa total en el mismo periodo. El área total de bosque primario húmedo en Ucayali disminuyó en 5.0% en este periodo. En Ucayali, dos provincias fueron las principales causantes del 79% de pérdida de la cobertura boscosa entre 2001 y 2021. Coronel Portillo tuvo la mayor pérdida de cobertura arbórea con 313 000 ha, mientras que Padre Abad con 232 000 ha, en comparación con el promedio de 172 ha (Global Forest Watch, 2020).

Según Dammert (2014) en su informe “Cambio de uso de suelos por agricultura a gran escala en la amazonia peruana: el caso de la palma aceitera”, el cultivo de palma presenta una serie de dificultades para el levantamiento de información, debido a las limitadas condiciones de acceso a las áreas de producción y a las restricciones por seguridad de las empresas productoras. Además, la elevada extensión del cultivo de palma también representa un obstáculo para la obtención de información detallada y precisa sobre el número de plantaciones y el área que representan. Es evidente que en los casos de instalación de proyectos agroindustriales en la amazonia cubre grandes extensiones de terreno y, en ocasiones que afecta tierras ocupadas no tituladas a comunidades campesinas y nativas. Asimismo, el cultivo de palma sustituye progresivamente áreas que eran usadas para la extracción ocasional de madera, caza y recolección, convirtiéndola en un monocultivo.

La determinación de la expansión de cultivo de palma aceitera presenta limitaciones en la capacidad de procesamiento de imágenes satelitales en periodos prolongados de análisis que limitan la generación y uso de información oportuna en la planificación y toma de decisiones. Esto debido a las dificultades de acceso a herramientas tecnológicas que usualmente se disponen en estaciones de trabajo de limitada capacidad de almacenamiento y el uso de algoritmos complejos disponibles actualmente en arquitecturas de procesamiento en la nube.

Por otro lado, la obtención de imágenes satelitales puede estar limitada debido a su escasa disponibilidad en alta resolución espacial y temporal por su elevado costo de adquisición, así como por las limitaciones climatológicas en las zonas tropicales para la toma de imágenes de satélite ópticas o multiespectrales afectadas negativamente por nubosidad.

Son escasas las investigaciones sobre la expansión de cultivos de palma aceitera (*Elaeis guineensis*) aplicando técnicas de análisis multitemporal de imágenes satelitales en Google Earth Engine, considerando su disponibilidad en periodos previos al año 2022. Es por ello por lo que el problema de esta investigación se orienta en analizar la capacidad para determinar la expansión de cultivos de palma aceitera en el distrito de Nueva Requena, provincia Coronel Portillo, región Ucayali en el periodo 2016-2022.

1.1.2. Planteamiento del problema

Problema principal

- ¿Cuál es la capacidad para determinar la expansión de cultivo de palma aceitera (*Elaeis guineensis*) mediante el análisis multitemporal de imágenes satelitales haciendo uso de la plataforma Google Earth Engine en el distrito de Nueva Requena, provincia Coronel Portillo, en la región Ucayali en el periodo 2016- 2022?

Problemas específicos

- ¿Cuál es la arquitectura tecnológica óptima para incrementar la capacidad de procesamiento de imágenes de satélite en el análisis multitemporal del área de cultivo de palma aceitera en el distrito Nueva Requena?
- ¿Cuáles son los medios tecnológicos que facilitan la determinación la expansión de cultivo de palma aceitera y su levantamiento de información automatizado?
- ¿Cuáles son los criterios y técnicas de análisis de imágenes satelitales de libre acceso, bajo condiciones climatológicas locales en el distrito Nueva Requena, para determinar con precisión la extensión de cultivo de palma aceitera?

1.2. Antecedentes

1.2.1. Antecedentes Nacionales

De Los Ríos (2022) llevó a cabo un análisis multitemporal de la pérdida de cobertura boscosa en Ucayali entre los años 2005 y 2022. Los resultados de esta investigación revelan una disminución considerable de la superficie boscosa en el sector La Merced, principalmente debido a la expansión de cultivos de palma aceitera y prácticas agrícolas inadecuadas. El estudio concluye que, entre 2005 y 2013, se perdió un 33.54% del bosque de terraza alta, con una tasa de deforestación de 476.55 hectáreas por año. Asimismo, entre 2013 y 2022, se registró una pérdida del 50.19% equivalente a una tasa de deforestación de 546.83 hectáreas por año. Ante esta situación, propone un plan de acción para reducir al mínimo la deforestación.

Ayca y Castro (2021), por su parte, analizaron los cambios en la pérdida de cubierta boscosa a lo largo del tiempo en el Centro Poblado Shambillo, ubicado en la provincia Padre Abad. Los resultados de este análisis indican que la tasa de pérdida forestal anual durante el período 2005-2020 fue de 11.3 hectáreas. Con base en estos hallazgos, los autores sugieren implementar medidas prácticas como reemplazar las palmas de aceite de 20 años, proteger la tierra cultivable y detener la deforestación del bosque primario.

En su análisis de la variación multitemporal de la cobertura vegetal entre los años 2010-2018, en la cuenca del río Neshuya en la región Ucayali, Córdova y Sánchez (2020), mediante el procesamiento de imágenes satelitales, se determinó una disminución de la cobertura forestal de 38 833 ha; mientras que el cultivo de palma aceitera tuvo un crecimiento de 47 399 ha.

En su tesis, Estimación de la pérdida de cobertura boscosa por actividades antrópicas en el distrito Nueva Requena, mediante análisis multitemporal de imágenes satelitales, Condori (2018) determinó que, en Nueva Requena, en seis años de monitoreo, desde 2011 hasta 2017, se perdió una extensión de 26 070.04 hectáreas de cobertura boscosa debido a actividades antrópicas. Esta cifra representa un 13.04% del área total del distrito. Condori concluyó que

esta pérdida de bosque es considerable y recomendó utilizar imágenes satelitales con mayor resolución espacial para obtener estimaciones más precisas de la deforestación en la zona.

1.2.2. Antecedentes internacionales

Indonesia es un actor clave en la industria global de palma aceitera, es un cultivo importante en términos económicos, pero también ha generado preocupación por su impacto en el ambiente, en el artículo “*Using Bayesian multitemporal classification to monitor tropical forest cover changes in Kalimantan, Indonesia*” (Sari et al., 2022), aplicaron la clasificación multitemporal bayesiana para aumentar la precisión de los resultados, y concluyeron que del 2000 al 2018 casi la mitad de los bosques nativos en el área de estudio se convirtieron en bosques no forestales o plantaciones de caucho, o palma aceitera, con pérdidas más altas entre 2015 y 2016; con tendencia al alza desde 2008 de grandes áreas de bosques degradados o talados, mapeados como no forestales, y fueron convertidos a plantaciones de palma. Los autores esperan que con su investigación Indonesia aplique estrategias y políticas para equilibrar el crecimiento económico junto con la conservación ambiental.

En el vecino país Brasil, un artículo publicado en *SciencDirect*, titulado: “*Long-term assessment of oil palm expansion and landscape change in the eastern Brazilian Amazon*” (De Almeida et al., 2019), estudia los cambios de uso y cobertura de tierra y sus efectos en el paisaje por el cultivo de palma aceitera, entre 1991 y 2013. Clasificaron imágenes Landsat y analizaron cambios paisajísticos en 2588,72 km² de la zona de expansión de la palma, ubicada entre los municipios de Moju, Acará y Tailândia, en el noreste de Pará, Brasil. Encontraron que, durante este período, el 47,7% del bosque primario se convirtió para otros usos, el bosque degradado aumentó un 17% y la plantación de palma aceitera aumentó un 11%. El treinta por ciento del bosque primario se convirtió en plantaciones de palma durante el período de estudio de 22 años; sin embargo, entre 2005 y 2013, la conversión de bosque primario a palma aceitera aumentó solo un 2%. Estos datos ofrecen una clara señal de advertencia de que, para el

crecimiento del cultivo de palma en el estado de Pará, los autores consideran que se debe adoptar estrategias centradas en la integridad del paisaje y desarrollar iniciativas para la regulación de grandes áreas de monocultivo, ayudando a garantizar la sostenibilidad ambiental de la región.

En la Bahía indonesia de Balikpapan, se realizó en estudio: “*Application of Sentinel-1 satellite to identify oil palm plantations in Balikpapan Bay*” (Lazecky, 2018), donde describen un enfoque para identificar aceite de palma, y una visión general sobre ventajas para el monitoreo de los cambios temporales en el medio ambiente tropical utilizando imágenes de radar, pero también restricciones debido a la ambigüedad de la identificación del tipo de cobertura. Las plantaciones se identificaron utilizando datos de Sentinel-1 SAR y Sentinel-2 en forma de promedios anuales, con el enfoque principal en la aplicabilidad de los datos SAR. Para las imágenes de Sentinel-2, solo unas pocas imágenes de 2015-2017 podrían haberse utilizado para el análisis debido a la persistente cobertura de nubes. Los datos de Sentinel-1 demostraron su capacidad para penetrar las nubes. El autor considera que la información debe tratarse como preliminar y debe evaluarse más a fondo mediante otros métodos, ya sea clasificación por datos satelitales multiespectrales, otras imágenes de radar, monitoreo local o una forma avanzada de procesamiento Sentinel-1. Sin embargo, los resultados muestran un buen potencial del uso de datos Sentinel-1 SAR de media resolución para la identificación de plantaciones de palma.

Rojas y Castiblanco (2018), en su artículo “Variabilidad espacial y análisis multitemporal sobre los cambios en las coberturas de la tierra ocasionados por la expansión del cultivo de la palma de aceite en los años 1985, 2000 y 2016 en el municipio de San Carlos de Guaroa (Colombia)”, de los tres cambios de cobertura que escogieron para su investigación, bosques de galería, áreas de uso agropecuario y cultivo de palma; determinaron que durante ese periodo, desapareció el 19.38% de los bosques de galería, lo que equivale a más de 1845.45

hectáreas, con una pérdida promedio anual de más del 3.22% (59.53 ha). En su gran mayoría, estos bosques fueron sustituidos por plantaciones de palma de aceite. Por otro lado, el área destinada al cultivo de palma de aceite aumentó en un promedio de más de 1312.56 hectáreas cada año, impulsado principalmente por políticas gubernamentales que favorecieron la expansión de este cultivo y la producción de biocombustibles en Colombia.

En su tesis de maestría, “Los impactos de la palma aceitera en Ecuador, un análisis geográfico y multitemporal de la expansión del cultivo y sus relaciones con el sistema socio ecológico de la provincia de Esmeraldas”, Angel (2022), llevó a cabo un estudio multitemporal de la expansión de este cultivo el cantón Quinindé, en la provincia de Esmeraldas a lo largo de una década, dividiendo el estudio en tres periodos: 2011, 2016 y 2020. Utilizando imágenes satelitales, corroboró un notable crecimiento del 49% en la superficie dedicada a la palma aceitera en el periodo 2011 - 2016, cercano la zona de amortiguamiento de la Reserva Ecológica Mache Chindul. Sin embargo, en 2020 se observó una disminución en esta tendencia, atribuida a una plaga que afectó a las plantaciones a nivel nacional. Los resultados obtenidos revelan que, según la normativa ecuatoriana, se tendría que cortar aproximadamente el 6% de la palma cultivada en el cantón ya que se encuentra en franjas de seguridad, mientras que, bajo estándares internacionales, más del 50% estaría ubicada en áreas protegidas cercanas a centros poblados y cuerpos de agua.

1.3. Objetivos

1.3.1. *Objetivo General*

- Aplicar el análisis multitemporal de imágenes satelitales en Google Earth Engine para determinar la expansión de cultivo de palma aceitera (*Elaeis guineensis*) en el distrito de Nueva Requena, provincia Coronel Portillo, en la región Ucayali en el periodo 2016-2022.

1.3.2. *Objetivos específicos*

- Proponer una arquitectura tecnológica óptima para aumentar la capacidad de procesamiento de imágenes satelitales en el análisis multitemporal del área de cultivo de palma aceitera en el distrito de Nueva Requena.
- Identificar los medios tecnológicos que facilitan el levantamiento de información automatizado para determinar la expansión de cultivo de palma aceitera en el distrito Nueva Requena, provincia Coronel Portillo, en la región Ucayali en el periodo 2016-2022.
- Determinar la extensión de cultivo de palma aceitera en el distrito de Nueva Requena, utilizando criterios y técnicas de análisis de imágenes de satélite de libre acceso, considerando las condiciones climatológicas locales para obtener resultados precisos.

1.4. Justificación

La diversidad del Perú se refleja en múltiples aspectos, en lo cultural y lo ecosistémico, lo que lo convierte en un país megadiverso. La mayor parte del territorio peruano, específicamente un 57.3%, está cubierto por bosques. La Amazonía peruana destaca con un 94.2% de cobertura forestal, mientras que los bosques secos y andinos representan un 4.7% y un 1.1% respectivamente (Ministerio Del Ambiente, 2022).

En este sentido, los bosques amazónicos en el Perú son impactados por la deforestación en múltiples áreas. Esta ocurre debido a diversas razones, como la tala no autorizada, el cambio de uso de suelo para agricultura y ganadería, entre otras (Centro Nacional de Planeamiento Estratégico, 2019).

Según la Junta Nacional de Palma Aceitera del Perú (2022), Ucayali es la primera región con mayor producción y área cosechada de palma, con un total de 41,992 ha el año 2021 que corresponde a un 44% del total nacional, y ha registrado un crecimiento anual lento en la producción de 19.61% en el periodo 2015-2021. En el distrito de Nueva Requena la empresa Ocho Sur S.A.C. cuenta con plantaciones de palma en el fundo Tibecocha.

Entre las principales limitaciones de la investigación, destaca la escasez de datos oficiales o institucionales sobre las tasas de deforestación causadas por el cultivo de palma aceitera y sus consecuencias en los ecosistemas. Las autoridades han llevado a cabo diversas iniciativas para frenar la pérdida de nuestros bosques, pero no siempre con resultados satisfactorios, debido a la limitación de recursos económicos, personal y logística en algunas áreas, la inmensidad de la Amazonía y, en ocasiones, la carencia de voluntad política para proteger nuestro patrimonio natural.

Por su parte, el Ministerio Público (2022) en su anuario estadístico del 2021, mostró que la Fiscalía Especializada en Materia Ambiental del distrito fiscal de Ucayali, el año 2021

ocupó el primer lugar de casos ingresados de todos los distritos fiscales, con un total de 1344 casos ingresados, de los cuales fueron atendidos 1032 que representa el 76.79 % de atención.

En otros países, como en Argentina, con la Ley de Bosques en 2008, se alcanzó una disminución del 60% en la deforestación comparado con 2007, según datos de la Secretaría de Ambiente y Desarrollo Sustentable, ley que logró detener los desmontes y bajar las tasas de deforestación por el avance de la frontera agrícola, especialmente de soja (Castilla, 2009).

Colombia, por su parte, ha promulgado una ley que penaliza hasta con cárcel el delito de la deforestación, mediante esta ley se tipifican como delitos ambientales actividades como la deforestación y la financiación de esta práctica, las cuales serán penadas con hasta 15 años de privación de la libertad; el tráfico de fauna silvestre, la inversión económica en la ocupación de ecosistemas frágiles y la apropiación indebida de tierras de propiedad nacional (Ministerio de Ambiente y Desarrollo Sostenible, 2021).

En relación con los datos accesibles de entidades que llevan a cabo vigilancia de deforestación y seguimiento a los cultivos de palma en Perú, tenemos a GEOBOSQUES, que muestra datos históricos (hasta el año 2021) a nivel de distrito de la pérdida anual de bosques, el Proyecto de Monitoreo de la Amazonía Andina (MAAP), junto con el Ministerio de Desarrollo Agrario y Riego (MIDAGRI) y el Ministerio del Ambiente, y sus entidades adscritas, generaron estudios como el Mapa Nacional de Superficie Agrícola del Perú (2020). Este mapa, generado mediante imágenes satelitales de alta resolución como RapidEye, Sentinel-2 y Google Earth, proporciona un mapeo detallado de las tierras agrícolas en todo el país, permitiendo una medición precisa de su extensión. (Ministerio de Desarrollo Agrario y Riego, 2020).

La distribución gratuita de datos de sensores como Landsat, MODIS y Sentinel ha generado una vasta cantidad de información disponible para estudios de percepción remota.

Sin embargo, la capacidad computacional necesaria para procesar estos datos ha sido un limitante, es así que para esta investigación se consideró el uso de Google Earth Engine que es en la actualidad la plataforma de procesamiento de imágenes en la nube más potente, que facilita el proceso de una serie de imágenes en cuestión de minutos y beneficia al usuario que se ve limitado por el hardware necesario para este procesamiento masivo.

En el desarrollo de la investigación para el cálculo y/o determinación de la expansión del cultivo de palma, la incidencia de errores e imprecisiones puede deberse a varios factores, como la calidad de la imagen adquirida, la resolución espacial y temporal, la presencia de nubes o sombras, la variación de la iluminación y la interferencia atmosférica que pueden tener un impacto significativo en la medición de los resultados del análisis multitemporal. Una evaluación cuidadosa de la calidad de las imágenes de satélite utilizando técnicas de corrección y calibración serán útiles para minimizar estos errores e imprecisiones y obtener resultados más precisos y confiables.

El limitado seguimiento temporal de expansión del cultivo mediante imágenes satelitales puede dificultar la identificación de los factores subyacentes de los cambios en la superficie terrestre, lo que puede ser importante para tomar decisiones fundamentadas sobre la gestión de los recursos naturales. Asimismo, existen escasos estudios específicos sobre la deforestación causada por la palma en el Perú.

En ese sentido, esta investigación se realiza fundamentalmente con el objeto de realizar el cálculo de la expansión de cultivo de palma aceitera (*Elaeis guineensis*) a través del análisis multitemporal de imágenes satelitales haciendo uso de la plataforma Google Earth Engine en el distrito de Nueva Requena, provincia Coronel Portillo, en la región Ucayali en el periodo 2016- 2022; en consecuencia, evaluar el efecto de este crecimiento del cultivo de palma en términos de deforestación.

Finalmente, el análisis multitemporal permitirá comparar los datos de diferentes períodos y detectar patrones de deforestación relacionados con la expansión del cultivo de palma. Además, este estudio podría proporcionar información valiosa para el desarrollo de estrategias y políticas que promuevan el aprovechamiento sostenible de los recursos naturales en el distrito de Nueva Requena.

1.5. Hipótesis

1.5.1. Hipótesis General

- El análisis multitemporal de imágenes satelitales en la plataforma Google Earth Engine se aplica eficazmente en la determinación de la expansión de cultivo de palma aceitera (*Elaeis guineensis*) en el distrito de Nueva Requena, provincia Coronel Portillo, en la región Ucayali en el periodo 2016- 2022.

1.5.2. Hipótesis Específicas

- Una arquitectura tecnológica óptima incrementa significativamente la capacidad de procesamiento de imágenes satelitales en el análisis multitemporal del área de cultivo de palma aceitera en el distrito de Nueva Requena.
- Los medios tecnológicos que facilitan la determinación de la expansión del cultivo de palma aceitera son óptimos para el levantamiento de información automatizado en el distrito Nueva Requena, provincia Coronel Portillo, en la región Ucayali en el periodo 2016-2022.
- La aplicación de criterios y técnicas de análisis de imágenes de satélite de libre acceso, permite una adecuada evaluación de la extensión de cultivo de palma aceitera en el distrito de Nueva Requena, considerando las condiciones climatológicas locales obteniendo resultados precisos.

II. MARCO TEÓRICO

2.1. Bases teóricas sobre el tema de investigación

2.1.1. Teledetección

Chuvieco (1995), define la teledetección como la técnica que emplea la energía solar o fuentes artificiales para estudiar la superficie terrestre a distancia. Sensores ubicados en plataformas especiales registran la energía reflejada por la superficie y estos datos son procesados por expertos para obtener imágenes que representan la realidad de dicha superficie. Chuvieco (1995), indica que un sistema de teledetección (**Figura 1**

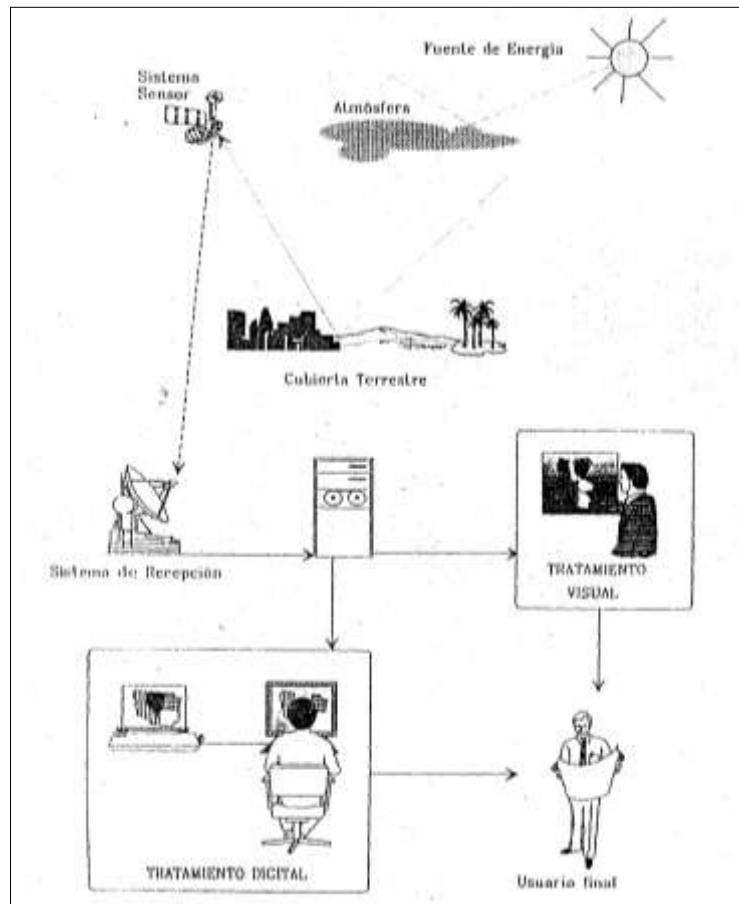
Componentes de un sistema de teledetección.) comprende lo siguiente:

- ❖ **Fuente de energía:** es la energía que es captada por el sensor. La energía que detecta el sensor puede provenir de dos fuentes: la energía solar, en lo que se conoce como teledetección pasiva; o de un haz de luz emitido por el propio satélite, denominado teledetección activa.
- ❖ **Superficie terrestre:** La superficie terrestre, compuesta por vegetación, agua, zonas urbanas y otros elementos, recibe la energía y la refleja de manera distinta según sus características.
- ❖ **Sistema sensor:** Además de la plataforma que lo soporta, el sensor capta la energía proveniente de la superficie terrestre, la codifica y la almacena o envía a una estación receptora.
- ❖ **Sistema de recepción:** es el mecanismo que recopila los datos provenientes del sensor para su posterior interpretación y evaluación por parte del personal capacitado.
- ❖ **Intérprete:** persona con suficientes conocimientos para analizar la información en forma de imágenes y para traducirla en números de acuerdo con el problema de investigación.

- ❖ **Usuario final:** es la persona que analiza y evalúa el documento producto de la interpretación, así también se encarga de elaborar los planes que se deriven (pp. 27-28).

Figura 1

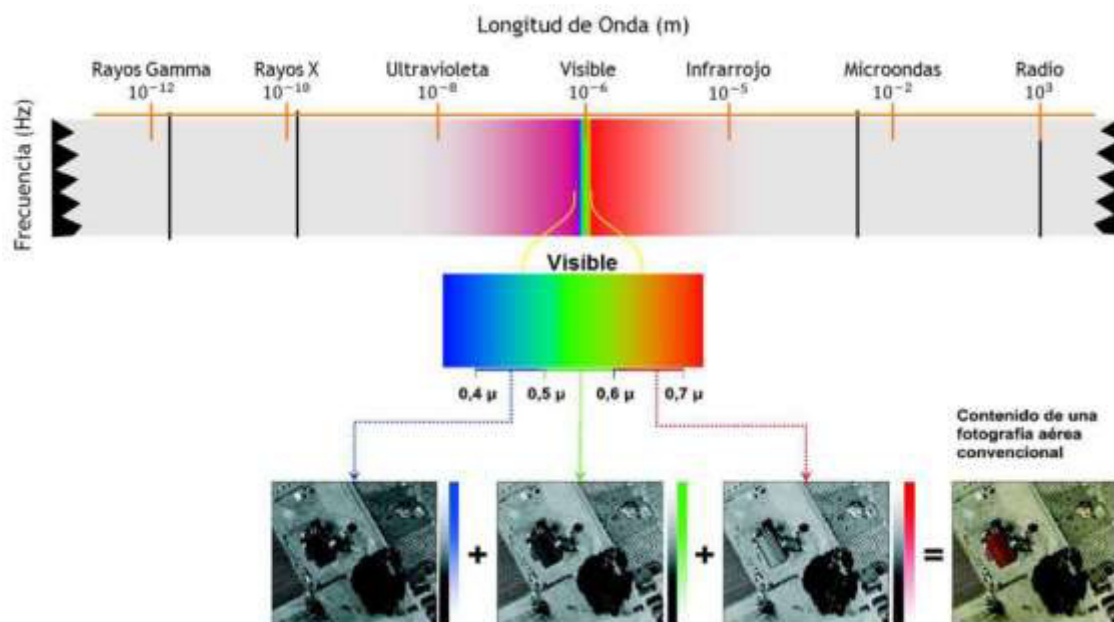
Componentes de un sistema de teledetección.



Nota: Tomado de *Componentes de un sistema de teledetección*, por Chuvieco, 1995, Fundamentos de la Teledetección Espacial.

2.1.2. Espectro Electromagnético

Para Hernández (2007), es una energía continua que se expresa en un amplio rango de longitudes de onda, desde los nanómetros hasta los metros. Es importante resaltar que la intensidad de esta energía es inversamente proporcional a su longitud de onda: a menor longitud de onda, mayor intensidad.

Figura 2*Espectro Electromagnético.*

Nota: Tomado de *Espectro electromagnético*, por Bravo, 2017, Teledetección espacial Landsat, Sentinel-2, ASTER L1T y MODIS.

Tabla 1*Descripción del Espectro Electromagnético.*

Región o Banda Espectral	Longitud	Características
Rayos Gamma	< 0,03 nm	Radiación totalmente absorbida por las capas altas de la atmósfera, lo que impide su uso en teledetección.
Rayos X	0,03 – 30 nm	
Rayos X	0,03 – 0,4 μ m	La radiación con $\lambda < 0,3 \mu$ m es absorbida en su totalidad por la capa de ozono atmosférico. La radiación con λ entre 0,3 y 0,4 μ m atraviesa la atmósfera y es detectable por fotodetectores y películas fotosensibles especiales.
Visible (azul, verde, rojo)	0,4 – 0,7 μ m	Es detectable por fotodetectores y películas fotográficas convencionales (color y blanco y negro).

Infrarrojo reflejado	0,7 – 3,0 μm	La radiación solar reflejada, sin información térmica de los materiales, con longitudes de onda entre 0,7 y 0,9 micrómetros, puede detectarse mediante películas fotosensibles y se clasifica como infrarroja.
Infrarrojo térmico	3 – 5 μm 8 – 14 μm	Pertencen a dos tipos atmosféricos en la zona térmica. Las imágenes son captadas por sensores óptico-mecánicos.
Radar (región de las microondas)	0,1 – 100 cm	Radiación de gran longitud, que pueden penetrar a través de nieblas, neblina y lluvia.
Ondas de Radio	>100 cm	Radiación con las longitudes de onda más largas del espectro. Empleado en telecomunicaciones.


Nota. Adaptada de *Características de la región espectral*, por Sánchez y Toral, 2014, Análisis de las capacidades de los sistemas Landsat y EO1 para la actualización cartográfica. Estudio de un caso práctico.

2.1.3. Tipos de Sensores

2.1.3.1. Sensores Pasivos. En la evaluación de recursos naturales, son preferibles los sensores pasivos, que captan la radiación natural emitida y reflejada por los objetos de estudio. Estas señales, producidas por la radiación solar natural, puede proporcionar una información muy rica sobre los objetos detectados (Bravo, 2017).

Figura 3

Sensor Pasivo.




Nota. Tomado de *Clasificación de Sistemas de Sensores*, por Suárez, 2018, Sistemas Espaciales de Teledetección.

2.1.3.2. Sensores Activos. El sensor emite radiación que, al incidir en el objeto, es reflejada y captada por el mismo sensor para su medición. Ejemplos: Radar, Lidar, Sonar (Bravo, 2017).

Figura 4

Sensor Activo



Nota. Tomado de *Clasificación de Sistemas de Sensores*, por Suárez, 2018, Sistemas Espaciales de Teledetección.

2.1.4. Tipos de Resoluciones

En general, los satélites tienen múltiples tipos de resolución, cada uno de los cuales se refiere a una dimensión específica de las imágenes que pueden capturar. Los tipos de resolución que describe Hernández (2007) son:

La resolución espectral. Se refiere a que partes del espectro electromagnético el sensor es sensible y cuantos rangos, o bandas espectrales, es capaz de diferenciar dentro de ella. Por ejemplo, una película fotográfica a color normal es capaz de captar la radiación entre 0,4 y 0,7 μm y dentro de esta zona distinguir 3 bandas espectrales: azul, verde y rojo.

Tabla 2*Resolución Espectral y Temporal del satélite Sentinel 2.*

Bandas	Resolución espectral (nm)	Resolución espacial (m)
Banda 1 (Aerosol)	443	60
Banda 2 (Azul)	490	10
Banda 3 (Verde)	560	10
Banda 4 (Rojo)	665	10
Banda 5 (Infrarrojo cercano - NIR)	705	20
Banda 6 (Infrarrojo cercano - NIR)	740	20
Banda 7 (Infrarrojo cercano - NIR)	783	20
Banda 8 (Infrarrojo cercano - NIR)	842	10
Banda 8a (Infrarrojo cercano - NIR)	865	20
Banda 5 (Vapor de agua)	945	60
Banda 10 (Cirrus)	1375	60
Banda 11 (Infrarrojo lejano - SWIR)	1610	20
Banda 12 (Infrarrojo lejano - SWIR)	2190	20

Nota. Adaptada de *Available Bands and Data*, por Copernicus Data Space Ecosystem, 2023, Data Sentinel-2 L2A.

La resolución radiométrica. Está definida por el número de tonos de grises (niveles digitales) que el sensor es capaz de diferenciar dentro de la banda del espectro luminoso definida por la resolución espectral. Por ejemplo, las imágenes Landsat TM identifican 256 niveles digitales (0-255) dentro de cada una de sus bandas.

La resolución espacial es función del tamaño del mínimo objeto observable y se utiliza el tamaño del píxel - lo que representa en la realidad - para definirlo. De esta forma, la

resolución espacial puede ir desde centímetros, en fotografías aéreas digitalizadas, hasta kilómetros, en imágenes del satélite NOAA.

Por último, **la resolución temporal** está definida por el intervalo de tiempo entre la obtención de una imagen y otra sobre la misma zona geográfica (pp. 15-16).

2.1.5. *Análisis multitemporal*

Para Chuvieco (1995), mediante el estudio multitemporal, se pueden identificar los cambios que ocurren en el entorno a lo largo del tiempo, tanto por causas naturales como por la intervención humana.


Ochoa (2023) define el análisis multitemporal de imágenes satelitales como una técnica utilizada para analizar variaciones en la superficie terrestre a través del tiempo. Esta técnica consiste en comparar imágenes satelitales de distintas fechas para detectar y medir los cambios en la cobertura del suelo, vegetación, agua, entre otros (Fonseca, 2020).

Para llevar a cabo un análisis multitemporal, Ochoa (2023) señala que es importante tener una buena comprensión del contexto histórico y las condiciones ambientales que afectan el área de interés. Se necesitan herramientas y técnicas de procesamiento de datos, como la corrección y normalización atmosférica, para garantizar que las imágenes o los datos sean comparables.

En resumen, el análisis multitemporal es una técnica importante para entender cómo está cambiando el medio ambiente y cómo estos cambios pueden afectar a la sociedad.

Figura 5

Estudio multitemporal de la cuenca media del Río Magdalena.



Nota. Tomada de *Generación de imágenes multiespectrales*, por Rodríguez, 2021, Análisis multitemporal utilizando imágenes Landsat para la determinación de la pérdida de la capacidad productiva en la cuenca media del río Magdalena.

2.1.6. Programa Landsat

Las imágenes Landsat son una de las misiones más icónicas en el ámbito de la exploración espacial, proporcionando imágenes satelitales desde la década de 1970. Es una iniciativa colaborativa de la NASA y el Servicio Geológico de los Estados Unidos (USGS) que proporciona la colección más extensa de imágenes satelitales de la Tierra a escala global.

Tabla 3

Franja temporal de las misiones Landsat.

Misión	Fechas de imágenes disponibles
Landsat 1	Julio 1972-enero 1978
Landsat 2	Enero 1975-febrero 1982
Landsat 3	Marzo 1978-marzo 1983
Landsat 4	Julio 1982-diciembre 1993
Landsat 5	Enero 1984-enero 2013
Landsat 7	Enero 1999-Actualidad

Landsat 8	Abril 2013-Actualidad
Landsat 9	Septiembre 2021-Actualidad

Nota. Adaptada de *Características de las imágenes Landsat*, por Gis&Beers, 2020, Todo lo que deberías saber sobre imágenes Landsat.

Los satélites más modernos de la constelación Landsat, el Landsat 9 y Landsat 8, fueron lanzados al espacio el 11 de febrero de 2013 y el 27 de septiembre de 2021, respectivamente. Estos satélites están equipados con los sensores Operational Land Imager (OLI) y Thermal Infrared Sensor (TIRS). Ambos sensores ofrecen imágenes con resoluciones de 30 m (para el espectro visible, infrarrojo cercano e infrarrojo de onda corta), 100 m (para el espectro térmico) y 15 m (pancromático). El sensor OLI incluye, además de las bandas habituales, una banda añadida para la detección de nubes cirros en la atmósfera y otra para el monitoreo de zonas costeras (Instituto Geográfico Nacional [IGN], 2022).

2.1.7. Programa Copernicus

Es el programa de observación terrestre más ambicioso jamás realizado, desarrollado para proporcionar datos precisos, actualizados y de fácil acceso con el objetivo de mejorar la gestión ambiental, entender y mitigar los efectos del cambio climático, y asegurar la protección civil (IGN, 2022). El programa Sentinel consta de dos satélites en cada misión, lo que permite satisfacer las necesidades de observación y cobertura, y proporcionar una amplia variedad de datos precisos y confiables para los servicios del programa Copernicus.

Tabla 4

Características de la misión Sentinel.

Satélites	Resolución espacial y temporal	Lanzamiento
Sentinel-1	9 – 40 m / revista cada 6 días	S1-A y S1-B en órbita
Sentinel-2	10 – 60 m/ revista cada 5 días	S2-A y S2-B en órbita

Sentinel-3	300 – 1200 / revista < 2 días.	S3-A y S3-B en órbita
Sentinel-4	8 km / revista cada 60 min	Lanzado el 2022
Sentinel-5p	7 – 68 km / revista cada 1 día	Primero lanzamiento hecho
Sentinel-5	7,5 – 50 km / revista cada 1 día	Primero lanzamiento 2021
Sentinel-6	Revista cada 10 días	Julio de 2020

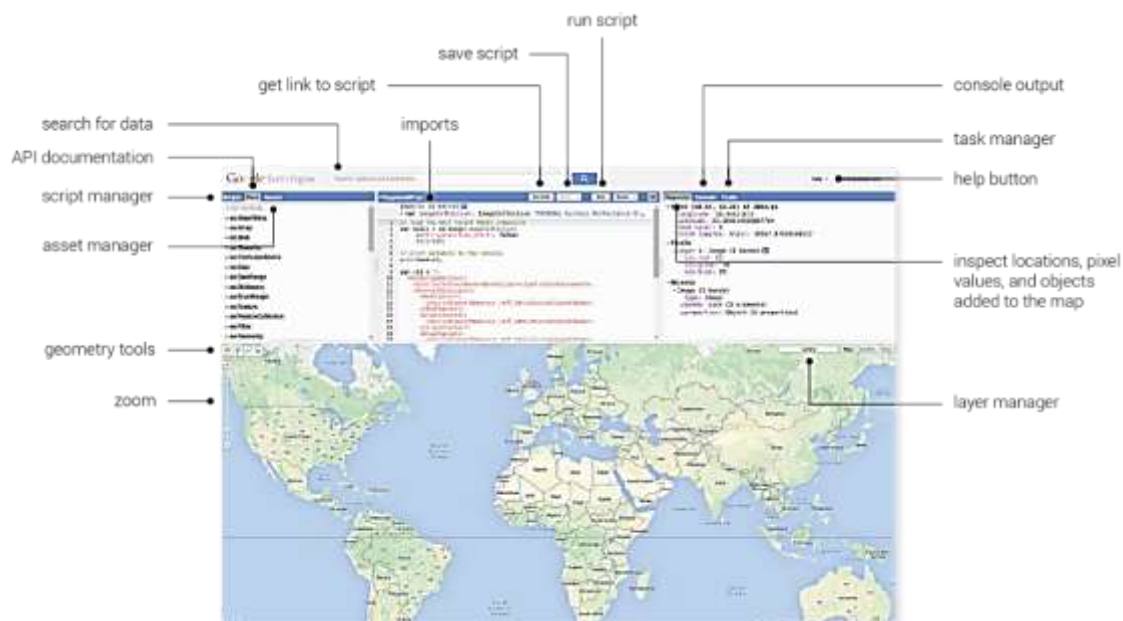
Nota. Adaptada de *Sistema Sentinel*, por Utreras, 2019, Copernicus Datos Abiertos y Gratuitos.

2.1.8. Google Earth Engine

Combina un catálogo de varios *petabytes* de imágenes satelitales y conjuntos de datos geoespaciales con herramientas de análisis a escala global en la nube. Científicos, investigadores y desarrolladores utilizan Earth Engine para detectar cambios, cartografiar tendencias y cuantificar variaciones en la superficie terrestre. Earth Engine sigue siendo de acceso gratuito para fines académicos y de investigación (Google, 2023).

Figura 6

Editor de Código de Google Earth Engine.



Nota. Obtenido de *Code Editor*, por Google, 2023, Platform Google Earth Engine.

2.1.9. Clasificación Supervisada

Emplea firmas espectrales obtenidas de las muestras de entrenamiento para clasificar una imagen (Environmental Systems Research Institute [ESRI], 2022). Esto implica la creación de muestras representativas con múltiples píxeles de la imagen para cada tipo de cobertura del suelo. Posteriormente, el software utiliza estos "sitios de entrenamiento" y los extiende a toda la imagen (Machine Learning). Estos datos se guardan en un "archivo de firma", que contiene toda la información espectral requerida para ejecutar la clasificación utilizando el algoritmo más apropiado (Ecoscript, 2020).

Tipos de clasificación supervisada:

A. Random Forest (RF)

Random Forest es un método de aprendizaje supervisado basado en la construcción de múltiples árboles de decisión, cuyos resultados se combinan mediante votación mayoritaria. Se caracteriza por su robustez frente al sobreajuste, alta precisión y capacidad de manejar datos de gran dimensión (Breiman , 2001).

B. Support Vector Machine (SVM)

Las Máquinas de Vectores de Soporte son un método supervisado que busca separar las clases mediante un hiperplano óptimo en un espacio de alta dimensión, maximizando el margen entre los vectores de soporte. Es muy utilizado en clasificación de imágenes satelitales debido a su capacidad de manejar datos no lineales (Cortes y Vapnik , 1995).

C. Classification and Regression Trees (CART)

CART es un método basado en la construcción de árboles de decisión binarios, que dividen los datos en subconjuntos homogéneos en función de variables predictoras. Es simple

de interpretar y ampliamente utilizado en clasificación temática de imágenes (Breiman et al., 1984).

D. Minimum Distance (MD)

El clasificador de Distancia Mínima asigna cada píxel a la clase cuya media espectral esté más cercana en el espacio multivariado. Es un método sencillo, eficiente y apropiado cuando las clases están bien separadas (Richards y Xiuping, 2006).

E. Naive Bayes (Bayes)

El clasificador Naïve Bayes se basa en el teorema de Bayes, asumiendo independencia condicional entre variables predictoras. Es eficiente en términos computacionales y proporciona buenos resultados en muchos problemas de clasificación (Friedman et al., 1997).

2.1.10. Clasificación No Supervisada


La clasificación no supervisada identifica clases espectrales (o grupos) en una imagen multibanda sin la participación del analista (ESRI, 2022). Se emplean algoritmos matemáticos de clasificación automática. Los más empleados son los algoritmos de agrupamiento (*clustering*), que segmentan el espacio de las variables en diversas regiones, reduciendo la varianza interna de los píxeles dentro de cada región. De esta manera, cada región define una clase espectral (Universidad de Murcia, s.f.).

2.1.11. Índices de cobertura

El estudio de las propiedades ópticas de las cubiertas vegetales implica un grado de complejidad, ya que estas no solo varían según las características intrínsecas de las plantas, sino que también dependen de factores como la altura del sol, la ubicación del sensor, las condiciones atmosféricas, el tono del suelo, la dirección de las hileras de cultivo y la geometría de la cobertura, entre otros, (Ormeño, 2006).

Figura 7

Curva de reflectancia de una hoja verde sana.



Nota. Tomado de *Curvas de reflectancia espectral de cuatro diferentes objetivos*, por Bravo, 2017, Teledetección espacial Landsat, Sentinel-2, ASTER L1T y MODIS.

El análisis de la vegetación y la identificación de las variaciones en los patrones de vegetación son fundamentales para la evaluación y el monitoreo de recursos naturales. Por lo tanto, no es sorprendente que la detección y la evaluación cuantitativa de la vegetación verde sean una de las aplicaciones principales de la teledetección para la gestión de recursos naturales y la toma de decisiones.

La clorofila absorbe energía intensamente en las bandas ubicadas en 0.45 y 0.67 μm . Por esta razón, nuestros ojos perciben la vegetación saludable como verde, debido a la fuerte absorción en las longitudes de onda azul y rojo por parte de las hojas, y la reflexión en el verde. Cuando la vegetación no está saludable, la cantidad de clorofila disminuye, lo que resulta en un aumento de la reflectancia espectral en el rojo, haciendo que las hojas adquieran un tono amarillento (combinación de verde y rojo).

2.1.12. Palma Aceitera

La palma africana (conocida también como Palma aceitera africana, Coroto de Guinea, Palmera Aabora o Palmera de Guinea) es una planta tropical adaptada a climas cálidos, originaria de la zona occidental y central de África, específicamente del golfo de Guinea, lo que le da su nombre científico *Elaeis guineensis*. Su uso se remonta a hace 5 milenios en esta zona, aunque su cultivo se expandió a otras partes de África a partir del siglo XV (Info Agro, 2020).

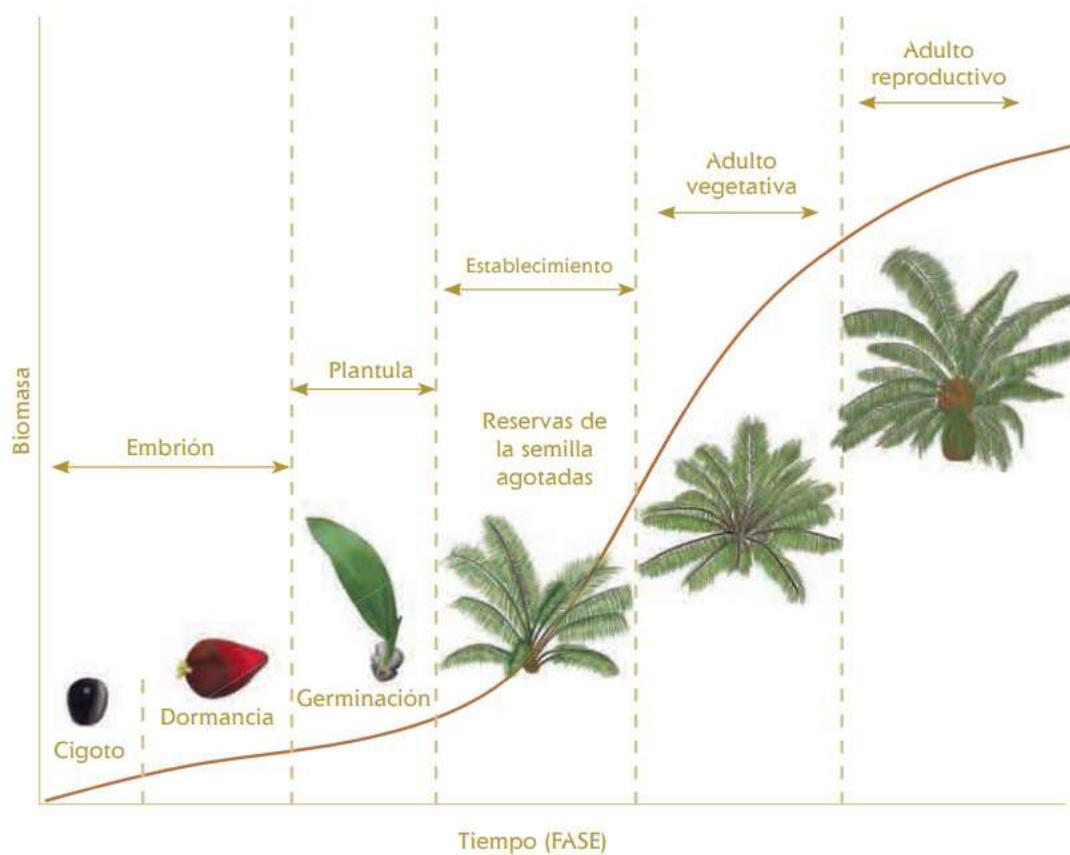
Según García y FENAPALMA (2005) el científico Hutchinson clasificó la palma aceitera de la siguiente manera:

- División = Fanerógamas
- Tipo = Angiosperma
- Clave = Monocotiledóneas
- Orden = Palmales
- Familia = Palmaceae
- Tribu = Coccoinea
- Género = *Elaeis*
- Especie = *guineensis* y oleífera

La **Figura 8** muestra el ciclo vital de una palma, que incluye cinco etapas: embrión, plántula, establecimiento, fase adulta vegetativa y reproductiva.

Figura 8

Fases de desarrollo de la palma de aceite.



Nota. Adaptada de *Phasic development*, por Tomlinson, 1990, *The Structural Biology of Palms*.

Requerimientos ambientales de la palma:

Las palmas africanas requieren condiciones específicas de clima, iluminación y disponibilidad de agua en las áreas donde se desarrollan. La siguiente tabla presenta los requisitos ambientales fundamentales para el cultivo de la palma africana.

Tabla 5

Necesidades ambientales básicas de la palma africana.

Luminosidad	Como mínimo 1800 – 2000 horas luz anuales, 5 horas por día.
Humedad ambiental	Media mensual 75-80%

Altitud	Rango de 0 a 500 msnm
Topografía	Planos o ligeramente ondulados con inclinaciones menores a 15%
Medios edáficos	La palma necesita medios edáficos, bien drenados, con un perfil de 60-100 cm de profundidad, textura franco arcilloso o franco arenoso, con pH entre 4.5 a 7.0
Temperatura media	25.5 °C
Precipitación	Igual o mayor de 1800 mm, bien distribuido en todo el año
Déficit hídrico	Inferior a 150mm/año

Nota. Adaptada de *Requerimientos ambientales de la palma africana*, por García y FENAPALMA, 2005, Manual Técnico Palma Africana.

2.1.13. Palma Aceitera en Perú

El reporte estadístico de año 2021 de la Junta Nacional de Palma Aceitera del Perú (JUNPALMA), señala que la producción de Racimo en Fruto Fresco (RFF) se concentra en las regiones Ucayali, San Martín, Loreto y Huánuco. En 2021, la producción total fue de 1,216,150 toneladas, siendo Ucayali el departamento con la mayor producción, alcanzando 572,776 toneladas, lo que equivale al 47%. Le sigue San Martín con 492,321 toneladas, representando el 41%. Estos dos departamentos constituyen el 88% de la producción nacional (Junta Nacional de Palma Aceitera del Perú [JUNPALMA], 2022).

La tasa de crecimiento anual nacional entre los años 2015 y 2021 fue de 9.76%. La región de mayor crecimiento es Ucayali con 19.23% anual; la segunda región más importante en producción de racimo de fruto fresco de palma aceitera es San Martín que ha registrado un

lento crecimiento anual de 4.09% en el mismo periodo. Además, muestra que del total de superficie cosechada de palma aceitera el año 2021, al departamento de Ucayali le corresponde 41,992 ha, el cual representa el 44%; el departamento de San Martín tiene 40,190 ha, le corresponde un 42%; los departamentos de Loreto y Huánuco tienen 9% y 4% respectivamente. El informe también precisa que, en estas cuatro regiones, se generan alrededor de 37000 empleos directos e indirectos que benefician a miles de familias, y el ingreso promedio mensual por productor es de 3134.00 soles con cinco hectáreas de palma (JUNPALMA, 2022).

El área total de palma aceitera cultivada en estas las cuatro regiones antes mencionadas es de aproximadamente de 85 000 hectáreas según el informe del Proyecto de Monitoreo de la Amazonía Andina del 2017, y de las cuales la mitad se plantó reemplazando bosques amazónicos.

2.2. Marco Legal

2.2.1. Constitución Política del Perú. 1993

Artículo 66.- Recursos Naturales

Este artículo establece que los recursos naturales, tanto renovables como no renovables, son patrimonio del país. El Estado tiene la soberanía para su extracción y aprovechamiento. La ley regula todas las condiciones para garantizar que su utilización se lleve a cabo de manera adecuada.

Artículo 68.- Conservación de la diversidad biológica y áreas naturales protegidas.

Aquí se detalla que el Estado tiene la obligación de preservar la biodiversidad existente y fomentar las áreas naturales protegidas.

2.2.2. Ley de Áreas Naturales Protegidas. Ley n° 26834, del 4/08/97

Artículo 3.- Las Áreas Naturales Protegidas

Esta ley establece que las Áreas Naturales Protegidas (ANP) son zonas continentales y/o marinas del territorio nacional, designadas específicamente como tales. Las ANP forman parte del Sistema Nacional de Áreas Naturales Protegidas por el Estado (SINANPE), en cuya gestión participan instituciones estatales, organismos regionales, entidades privadas y comunidades que intervienen directa o indirectamente en el desarrollo y administración de estas áreas.

2.2.3. Ley General del Ambiente. Ley 28611 del 15/10/2005.

Artículo 1.- Del derecho y deber fundamental

Establece en su artículo 1 que toda persona tiene el derecho a vivir en un ambiente apropiado para el pleno desarrollo de la vida, así como la obligación de apoyar a una gestión ambiental eficiente, incluyendo sus componentes, con el fin de garantizar el bienestar

individual y colectivo, la conservación de los ecosistemas y el aprovechamiento sostenible de los recursos naturales.

2.2.4. *Ley Orgánica para el Aprovechamiento Sostenido de los Recursos Naturales. Ley n° 26821 del 26 /06/97.*

Artículo 2. Este artículo señala que el Estado regula el uso sostenible de los recursos, tanto renovables como no renovables. Además, establece los principios adecuados para fomentar la inversión, tanto privada como pública, asegurando un equilibrio eficiente entre el crecimiento económico y la conservación de los recursos naturales.

Artículo 8. Indica que es el Estado quien otorga el derecho de uso sostenible de los recursos naturales, el cual se ejerce en equilibrio entre los intereses del Estado y el beneficio de la población.

Artículo 28. Respecto al aprovechamiento sostenible, en el artículo 28 se establece que consiste en la explotación eficiente de los recursos naturales, siguiendo el principio de beneficios verdaderos, evitando siempre impactos negativos en los recursos que forman parte del entorno.

2.2.5. *Ley Sobre la Conservación y Aprovechamiento Sostenible de la Diversidad Biológica. Ley n° 26839 del 16/07/97*

Artículo 3 y 4. Aquí se establece que el Estado tiene soberanía en la aplicación de normas para la conservación y el uso adecuado de la diversidad biológica. Impulsa la creación y uso de mecanismos de conservación in situ, así como de centros de conservación ex situ, los cuales deben ajustarse a las regulaciones de acceso a los recursos genéticos y a las normas básicas determinadas en la presente ley.

2.2.6. *Ley Forestal y de Fauna Silvestre Ley N.° 29763 del 22/07/2011*

Artículo 37. Prohibición de cambio de uso actual de tierras de capacidad de uso mayor forestal y de protección.

Esta ley, prohíbe cambiar el uso de tierras con capacidad de uso forestal mayor o de protección, ya sea que tengan o no cobertura vegetal, para fines agropecuarios. También se prohíbe la concesión de títulos de propiedad, constancias o certificados de tenencia de suelos públicos con capacidad de uso forestal mayor o de protección, con o sin cubierta forestal, así como la construcción de infraestructura pública de servicios, con la responsabilidad correspondiente de los funcionarios involucrados.

Sin embargo, lo anterior no impide la concesión de derechos mediante contratos, de manera excepcional y bajo requisitos precisos y rigurosos de sostenibilidad, en áreas que hayan sido zonificadas y designadas para tratamiento especial.

Artículo 38. Uso de tierras de capacidad de uso mayor para cultivo en limpio o cultivos permanentes con cobertura forestal actual.

Esta ley establece que, cuando existan bosques en suelos de dominio público clasificados con capacidad de uso mayor para cultivo permanente o en limpio, según lo indicado en el Reglamento de Clasificación de Tierras por su Capacidad de Uso Mayor, el Servicio Nacional Forestal y de Fauna Silvestre (SERFOR) puede autorizar el cambio de uso actual para permitir actividades agropecuarias. Esto debe realizarse considerando la zonificación ecológico-económica, con la aprobación del gobierno local o regional correspondiente y el consentimiento del MINAM, siguiendo los procedimientos administrativos pertinentes. En el caso de suelos privados con cobertura vegetal de masa boscosa, el cambio de uso debe ser autorizado por la autoridad forestal y de fauna silvestre regional, respaldado por un informe técnico de microzonificación. En todos estos casos, se

debe reservar al menos el 30% de la masa boscosa existente en tierras con aptitud para la agricultura.

2.2.7. Ley de Promoción de la Inversión en la Amazonía (Ley N° 27037)

Artículo 3. Define los objetivos de la ley, que incluyen promover la inversión en la Amazonía, fomentar el desarrollo sostenible de la región, proteger el medio ambiente y los recursos naturales, y garantizar la participación de las comunidades locales en los proyectos.

Artículo 6. Establece los beneficios y incentivos que se otorgarán a los inversionistas que realicen actividades económicas en la Amazonía, como la exoneración o reducción de impuestos, la facilidad de acceso a financiamiento y la simplificación de trámites administrativos.

Artículo 8. Establece la obligación de los inversionistas de presentar un estudio de impacto ambiental y social para obtener la aprobación de sus proyectos, asegurando que se lleven a cabo de manera sostenible y respetando el equilibrio ecológico de la región.

Artículo 10. Establece que las actividades económicas en la Amazonía deben respetar los derechos de las comunidades locales y promover su desarrollo integral, asegurando su participación y beneficiándolas de manera equitativa.

Artículo 12. Establece la creación de un fondo de promoción de inversiones en la Amazonía, con el objetivo de financiar proyectos que impulsen el desarrollo económico sostenible de la región.

2.2.8. Reglamento de la Ley Forestal y de Fauna Silvestre (Decreto Supremo N° 014-2015-MINAGRI)

El objetivo principal del reglamento es establecer disposiciones detalladas para la conservación, el manejo sostenible y la utilización de los recursos forestales y de fauna

silvestre, considerando tanto los aspectos ambientales como los socioeconómicos. Algunos de los artículos importantes son:

Artículo 4. Establece los criterios para la clasificación de los bosques de acuerdo a su vocación, considerando su importancia para la conservación, producción, protección y recuperación.

Artículo 10. Establece los requisitos para la obtención de la autorización de aprovechamiento forestal, que incluyen la presentación de un plan de manejo forestal sostenible.

Artículo 16. Regula la concesión forestal y establece los requisitos y procedimientos para su otorgamiento, así como las obligaciones y derechos del concesionario.

Artículo 24. Establece las escenarios y requisitos para la autorización de caza y captura de fauna silvestre, así como las prohibiciones y limitaciones aplicables.

Artículo 32. Regula el comercio y transporte de productos forestales y de fauna silvestre, estableciendo los requisitos y documentos necesarios, así como las responsabilidades de los operadores.

Artículo 45. Establece las medidas y procedimientos para el control y fiscalización forestal, así como las sanciones administrativas aplicables en caso de infracción de las disposiciones establecidas.

2.2.9. Resolución Ministerial N° 015-2001-AG, que aprueba el Plan Nacional de Promoción de la Palma Aceitera, para el periodo comprendido entre los años 2000 al 2010.

Esta Resolución que declara de interés nacional la palma, tiene como “principal objetivo promover el desarrollo sostenible y socioeconómico de la región amazónica y contribuir a la

recuperación de los suelos deforestados por la agricultura migratoria y por el desarrollo de actividades ilícitas, en áreas con capacidad de uso mayor para el establecimiento de plantaciones de esta especie” (Artículo 1).

2.2.10. Ley N° 30428 Ley que oficializa el Sistema de Cuadrículas Mineras en Coordenadas UTM WGS84

Esta ley oficializa el uso del Sistema Geodésico Horizontal Oficial, que se refiere al WGS84, basándose en la Red Geodésica Geocéntrica Nacional (REGGEN), sustentada en SIRGAS. Fue aprobada por el Congreso de la República y publicada el 30 de abril de 2016 y establece que las coordenadas UTM de los vértices de las concesiones, petitorios y demás figuras mineras deben estar referidas al WGS84 y se deben inscribir junto a sus equivalentes en el sistema anterior (PSAD56).

III. MÉTODO

3.1. Tipo de Investigación

Para Hernández et al. (2014), según el propósito de la investigación, tenemos una investigación de tipo descriptiva, que se realiza para describir y caracterizar un fenómeno o situación específica, en nuestro caso porque se busca determinar el crecimiento del cultivo de palma en un periodo de siete años y describir su evolución en la área de estudio; y según el enfoque, por la naturaleza de los datos es una investigación cuantitativa, ya que se utiliza imágenes de satélite para medir el área de expansión y efectuar un análisis estadístico de los datos obtenidos para representarlos en gráficos y mapas.

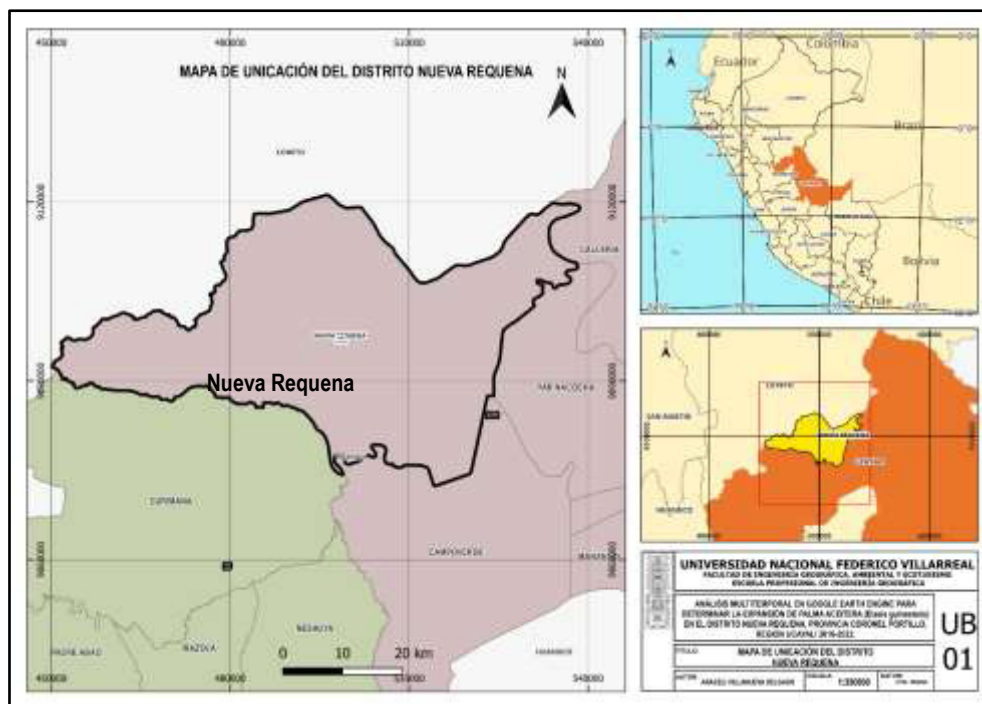
La investigación se puede considerar de tipo aplicada y de diseño no experimental longitudinal, ya que su objetivo es analizar un problema ambiental específico y proporcionar datos relevantes para la toma de decisiones. Además, la investigación utiliza herramientas y técnicas específicas, como la teledetección y el análisis espacial, para obtener resultados concretos que puedan aplicarse en la práctica.

3.2. Ámbito temporal y espacial

El estudio se desarrolló en el distrito Nueva Requena, provincia Coronel Portillo, región Ucayali; en el periodo comprendido entre el 2016 a 2022.

Figura 9

Ámbito espacial de la investigación.



3.3. Variables

Las variables se presentan en la **Tabla 6** y **Tabla 7**, donde se detalla la variable independiente y dependiente, con sus dimensiones e indicadores respectivos.

Tabla 6

Detalle de la variable independiente.

Variable independiente	Dimensiones	Indicadores
Análisis multitemporal de imágenes satelitales.	Fuente de datos	Tipo de sensor
		Resolución espacial
		Resolución temporal
	Procesamiento	Plataforma Google Earth Engine
		Capacidad de procesamiento
	Técnicas de análisis	Algoritmos de clasificación
Calidad de información	Índices espectrales	
	Precisión de la clasificación	
		Coeficiente de Kappa

Tabla 7 *Detalle de la variable dependiente.*

Variable dependiente	Dimensiones	Indicadores
Determinación de la expansión del cultivo de palma aceitera.	Dinámica temporal	Tasa de expansión anual
		Crecimiento acumulado (2016-2022)
	Cambio de uso de suelo	Áreas deforestadas
	Cobertura de cultivos	Área cultivada Densidad de plantaciones

3.4. Población y muestra

La extensión territorial del distrito de Nueva Requena constituye la población de esta investigación, la cual es: 2 857,34 km², es decir: 285 734 ha. Esto representa el 2,79% de la superficie de la región Ucayali. No aplica muestreo, dado que el análisis abarca la totalidad del área de estudio. Se trata de un muestreo no probabilístico, donde la muestra coincide con la población.

3.5. Instrumentos

Los instrumentos que se necesitaron se detallan en la **Tabla 8**.

Tabla 8

Instrumentos y Equipos.

N°	Instrumentos/Equipos	Cantidad	Unidad
1	Computadora portátil	1	Unidad
2	Disco duro externo SSD	1	Unidad
3	Microsoft Office 365	1	Unidad
4	ArcGIS Pro	1	Unidad
5	Google Collab	50	Gigabytes

Computadora portátil: Utilizada para acceder y procesar datos satelitales en Google Earth Engine, facilitando el análisis multitemporal de la expansión de palma aceitera en el distrito Nueva Requena.

Disco duro externo SSD: Almacena datos generados para el análisis temporal de la expansión del cultivo, asegurando un acceso rápido y eficiente a la información que emplea para el desarrollo de esta tesis.

Microsoft Office 365: Empleado para la realización de la investigación y la plasmar el análisis de resultados sobre la expansión de la palma aceitera, facilitando la comunicación del objetivo del estudio.

ArcGIS Pro: Permite realizar análisis geoespaciales avanzados para identificar y mapear el crecimiento del cultivo de palma aceitera en el tiempo, proporcionando herramientas de cálculo para la detección de cambios.

Google Collab: Ofrece recursos computacionales en la nube para ejecutar scripts de Python en Google Earth Engine, facilitando el procesamiento de grandes conjuntos de datos y la implementación de algoritmos para el análisis multitemporal de la expansión de la palma aceitera.

En resumen, la conjunción de estos instrumentos permite procesar y analizar grandes datasets de imágenes satelitales, realizar análisis estadísticos y espaciales, crear visualizaciones y compartir tu trabajo con otros investigadores.

3.6. Procedimientos.

La elaboración de esta investigación se inicia con una exhaustiva revisión bibliográfica que abarca antecedentes internacionales y nacionales relevantes, con el objetivo de evaluar la viabilidad del estudio desde una perspectiva técnica y presupuestaria. Posteriormente, se procede a la recopilación y procesamiento de la información pertinente, evaluando los métodos y herramientas apropiadas para asegurar la calidad de los datos. Después, se realiza la formulación detallada de los aspectos metodológicos, que abarcan desde la estructura de antecedentes hasta la descripción, planteamiento y formulación de problemas, objetivos, hipótesis, variables e indicadores, justificación y marco teórico. Y como se muestra en la

Figura 10.

Figura 10

Flujo para la detección de expansión de Palma Aceitera.



3.6.1. Primera etapa: Preparación de datos.

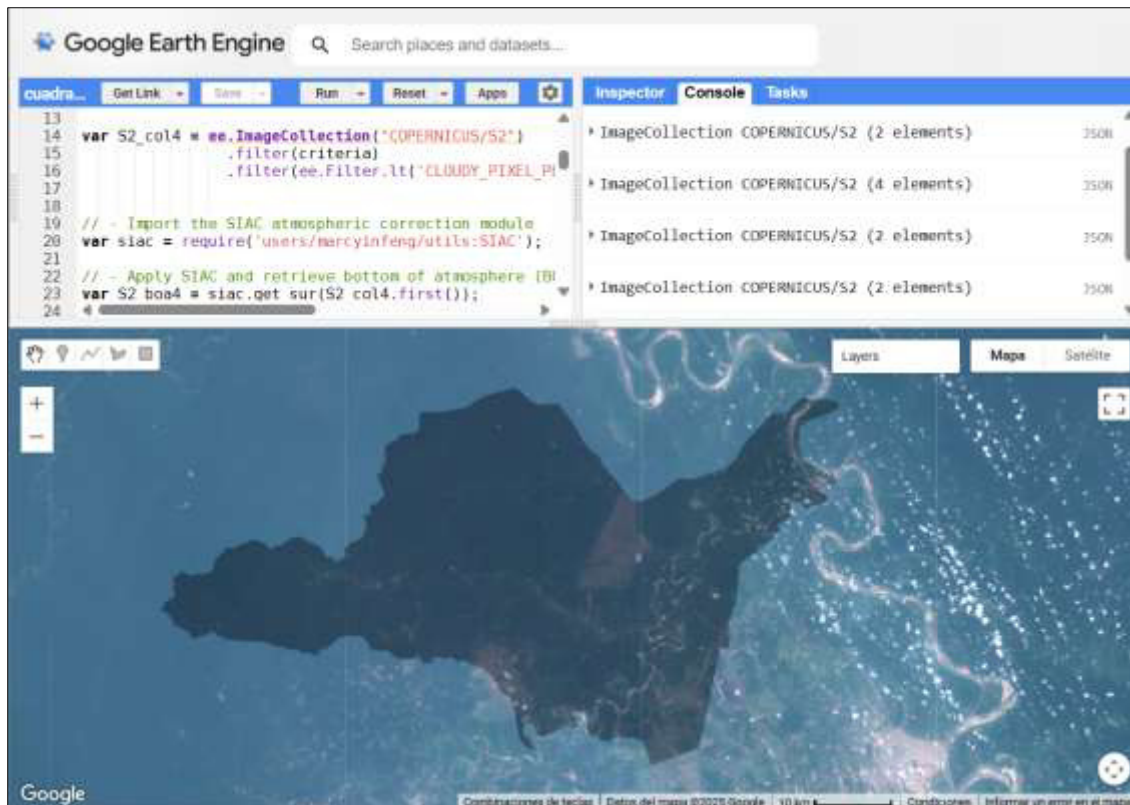
- Definición del área de estudio.
- Adquisición, revisión y captura de datos.
- Revisión de metodologías de detección de áreas de cultivo de palma.

3.6.2. Segunda etapa: Preprocesamiento

- Configuración del entorno de trabajo en Google Earth Engine.
- Temporalidad de imágenes.

Figura 11

Búsqueda de imágenes por fechas



3.6.3. Tercera etapa: Procesamiento.

- Selección de imágenes satelitales según periodo requerido.
- Clasificación supervisada tomando puntos de entrenamiento (ver **Figura 21**).

Tabla 9*Procesamiento en Google Earth Engine.*

Proceso	Descripción
1. Búsqueda de escenas Sentinel 2	Al comenzar con la clasificación supervisada en Google Earth Engine, lo primero que hacemos es buscar las imágenes satelitales Sentinel 2 correspondiente al nivel 1C, dentro del área de interés, distrito Nueva Requena. Ver Figura 12 y Figura 13 .
2. Filtros	Una vez que has obtenidas las escenas Sentinel 2 deseadas, aplicamos los filtros según las necesidades específicas. Estos filtros incluyen el rango de fechas de búsqueda, el porcentaje de cobertura nubosa, la selección de bandas, entre otros. Ver Figura 12 y Figura 13 .
3. Ajustes de visualización	Después de aplicar los filtros necesarios, ajustamos la visualización de las imágenes para poder interpretar mejor la información. Esto implica cambiar la combinación de bandas para resaltar características relevantes y ajustar la escala de colores para mejorar el contraste. Ver Figura 12 y Figura 13 .
4. Clases de entrenamiento	El siguiente paso es definir las clases de entrenamiento para la clasificación supervisada. Identificamos las diferentes categorías o clases de cobertura que se desea distinguir en el análisis y son: Cuerpo de agua, Bosque, Pastizal, Cultivo de Palma y Suelo Desnudo. Luego, seleccionamos puntos representativos de cada clase en las imágenes y las etiquetas como datos de entrenamiento. Ver Figura 14 y Figura 26 .
5. Clasificación supervisada	Una vez preparadas las clases de entrenamiento, procedemos a realizar la clasificación supervisada. Utilizamos un

algoritmo específico, como *Random Forest*, *Support Vector Machine (SVM)*, entre otros; para entrenar un modelo utilizando los datos de entrenamiento que se etiquetó previamente. Este modelo utiliza la información espectral de las imágenes para asignar automáticamente las clases a cada píxel en el área de estudio. Ver **Figura 14** y **Figura 26**.

-
6. Exportar ráster Finalmente, después de obtener los resultados de la clasificación supervisada del algoritmo que mejor haya clasificado, exportamos el ráster clasificado para su uso y análisis en un SIG. Esto implica seleccionar el formato de salida adecuado (.tif), definir la resolución (10m).
-

Figura 12

Script de búsqueda de imágenes del año 2016

```

// COLECCIÓN DE SENTINEL 2
var s2 = ee.ImageCollection('COPERNICUS/S2')
    .filterDate('2016-08-01', '2016-10-31')
    .filterMetadata('CLOUD_COVERAGE_ASSESSMENT', 'less_than', 10)
    .filterBounds(table)
    .median()

//SIMBOLOGÍA FALSO COLOR
var viz = {'bands':['B12', 'B11', 'B4'],
    'gamma': 1,
    'max': 3971.787232904865,
    'min': -826.5563177792135,
    'opacity': 1}

var mosaic = s2.select(['B12', 'B11', 'B4']).clip(table);

// VISUALIZAR EL MAPA
Map.addLayer(s2, viz, 'Median Nueva Requena', false)
Map.addLayer(table, '', 'Nueva Requena - Buffer_100m', false)
print(s2);
Map.centerObject(table, 10);

```

Para ambos años se definen las mismas variables, ya que los scripts se ejecutan de manera independiente dentro de la plataforma de Google Earth Engine, y solo se cambian parámetros como la fecha, valores para la visualización, nombres de elementos de la leyenda, entre otros.

Para el año 2016, la composición de la imagen(*median*) se realizó con imágenes del 1 de agosto del 2016 al 31 de octubre del 2016. Del mismo modo, para el año 2022, la composición de la imagen(*median*) se realizó con imágenes del 1 de agosto del 2022 al 31 de octubre del 2022.

Figura 13

Script de búsqueda de imágenes del año 2022

```

// COLECCIÓN DE SENTINEL 2
var s2 = ee.ImageCollection('COPERNICUS/S2')
    .filterDate('2022-08-01', '2022-10-31')
    .filterMetadata('CLOUD_COVERAGE_ASSESSMENT', 'less_than', 10)
    .filterBounds(table)
    .median()

//SIMBOLOGÍA FALSO COLOR

var viz = {'bands':['B12', 'B11', 'B4'],
    'gamma': 1,
    'max': 4832,
    'min': 1000,
    'opacity': 1}

var mosaic = s2.select(['B12', 'B11', 'B4']).clip(table);

//VISUALIZAR EL MAPA
Map.addLayer(s2, viz, 'Median Nueva Requena', false)
Map.addLayer(table, '', 'Nueva Requena - Buffer_100m', false)
print(s2);
Map.centerObject(table, 10);

```

La variable “s2” devuelve la colección de imágenes de Sentinel 2 filtrada por las fechas, cobertura de nubes y áreas de interés establecidas. La variable “viz” realiza la combinación de bandas, y es donde se define los mínimos y máximos para la visualización de la escena en color natural. La variable “mosaic” junta los *tiles* o escenas de la variable “s2” que en el caso de Nueva Requena abarcan cuatro, y hace el corte en función de los límites del distrito. Finalmente, en la consola del *Code Editor* de Google Earth Engine se puede mostrar la colección de imágenes que “s2” devuelve, y se agrega al mapa el mosaico con los parámetros de visualización establecidos.

La selección de criterios y técnicas de análisis apropiados para imágenes satelitales ópticas de libre acceso ha sido crucial para garantizar la calidad y fiabilidad de los resultados obtenidos. Considerando la resolución espacial, la temporalidad, las condiciones climatológicas locales, entre otros del distrito de Nueva Requena, se evaluaron diferentes algoritmos y métodos de clasificación (**Figura 14** y **Figura 26**), seleccionando aquellos que presentaron mayor precisión en la identificación del cultivo de palma aceitera, como se presentan a continuación.

Análisis multitemporal en Google Earth Engine

Una vez evaluados los resultados de la búsqueda de imágenes óptimas de la colección Sentinel 2 del nivel 1C, se procede con la clasificación supervisada. El código de las figuras **Figura 14** y **Figura 26** muestran un proceso de clasificación supervisada para los años 2016 y 2022 utilizando diferentes algoritmos de aprendizaje automático en Google Earth Engine.

Figura 14

Script de la clasificación supervisada del año 2016.

```

// LASFICACIÓN SUPERVISADA
// ENTRENAMIENTO

var training = ee.FeatureCollection([Agua, Bosque_denso, Suelo_exp, Palma, Pastizal]).flatten();

var sample = mosaic.sampleRegions(training, ["Clase"], 30);

// CLASSIFY RANDOM FOREST
// Make a Random Forest classifier and train it.
var classifierRF = ee.Classifier.smileRandomForest(20)
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_RF = mosaic.classify(classifierRF);

Map.addLayer(classified_RF, {min:1, max:5, palette:["#49f1ff", "#579280", "#f2895a", "ffffd", "#87b67a"]}, "classified_RF");

// CLASSIFY SVM
// Make a Random Forest classifier and train it.
var classifierSVM = ee.Classifier.libsvm()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_SVM = mosaic.classify(classifierSVM);

Map.addLayer(classified_SVM, {min:1, max:5, palette:["#49f1ff", "#579280", "#f2895a", "ffffd", "#87b67a"]}, "classified_SVM");

// CLASSIFY CART
// Make a Random Forest classifier and train it.
var classifierCART = ee.Classifier.smileCart()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_CART = mosaic.classify(classifierCART);

Map.addLayer(classified_CART, {min:1, max:5, palette:["#49f1ff", "#579280", "#f2895a", "ffffd", "#87b67a"]}, "classified_CART");

// CLASSIFY MD
// Make a Random Forest classifier and train it.
var classifierMD = ee.Classifier.minimumDistance()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_MD = mosaic.classify(classifierMD);

Map.addLayer(classified_MD, {min:1, max:5, palette:["#49f1ff", "#579280", "#f2895a", "ffffd", "#87b67a"]}, "classified_MD");

// CLASSIFY BAYES
// Make a Random Forest classifier and train it.
var classifierBayes = ee.Classifier.smileNaiveBayes()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_Bayes = mosaic.classify(classifierBayes);

Map.addLayer(classified_Bayes, {min:1, max:5, palette:["#49f1ff", "#579280", "#f2895a", "ffffd", "#87b67a"]}, "classified_Bayes");

// Exporta la imagen cortada a Google Drive
Export.image.toDrive({
  image: classified_SVM,
  description: 'classified_SVM_2016',
  folder: 'NUEVA REQUENA',
  region: table,
  scale: 10,
  crs: 'EPSG:4326'
});


```

Entrenamiento:

Se crea una colección de características (training) que contiene las clases de interés para la clasificación (como Agua, Bosque denso, Suelo expuesto, Palma y Pastizal). Esta colección se aplanará para obtener una lista de características individuales. Durante la clasificación, el modelo extrapola las firmas aprendidas a toda la imagen, asignando cada píxel a una clase mediante reglas de decisión, La precisión dependerá de la calidad de las muestras, características (bandas óptimas, índices espectrales o texturas) y parámetros del clasificador.

Agua**Figura 15**

Puntos de entrenamiento para la cobertura Agua



Nota. Fuente: Google Earth Engine.

Bosque denso

Figura 16

Puntos de entrenamiento para la cobertura Bosque denso



Nota. Fuente: Google Earth Engine.

Suelo desnudo

Figura 17

Puntos de entrenamiento para la cobertura Suelo desnudo



Nota. Fuente: Google Earth Engine.

Palma

Figura 18

Puntos de entrenamiento para la cobertura Palma




Nota. Fuente: Google Earth Engine.

Pastizal

Figura 19

Puntos de entrenamiento para la cobertura Pastizal




Nota. Fuente: Google Earth Engine.

Totalidad de puntos por clases

Figura 20

Puntos de entrenamiento de todas las coberturas (2016)



Nota. Fuente: Google Earth Engine.

Se realiza un muestreo de regiones “sample” en la imagen de entrada “Mosaic” utilizando la colección de entrenamiento “training”. Se especifica la propiedad de clasificación (“Clase”) y el tamaño de píxel para el muestreo (30 metros).

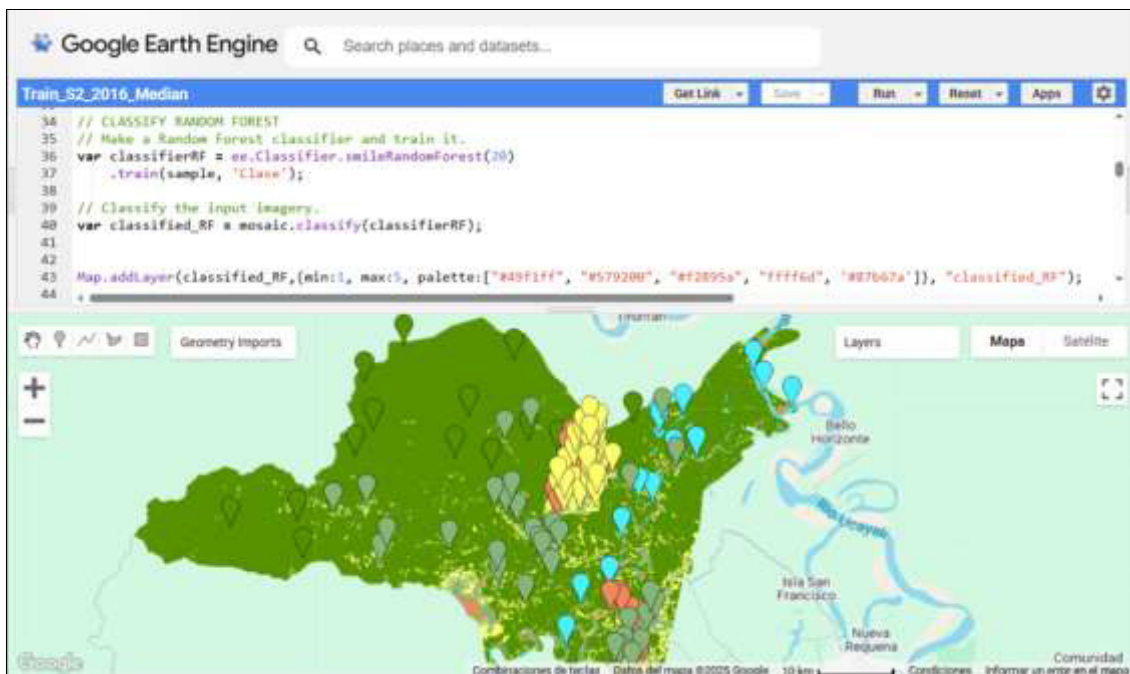
Clasificación Supervisada:

Clasificación con Random Forest (RF):

Se crea un clasificador de Random Forest (classifierRF) con 20 árboles y se entrena utilizando la colección de muestras “sample” y la propiedad de clasificación ("Clase"). Se clasifica la imagen de entrada “Mosaic” utilizando el clasificador RF entrenado, generando la imagen clasificada “classified_RF”.

Figura 21

Clasificación Random Forest

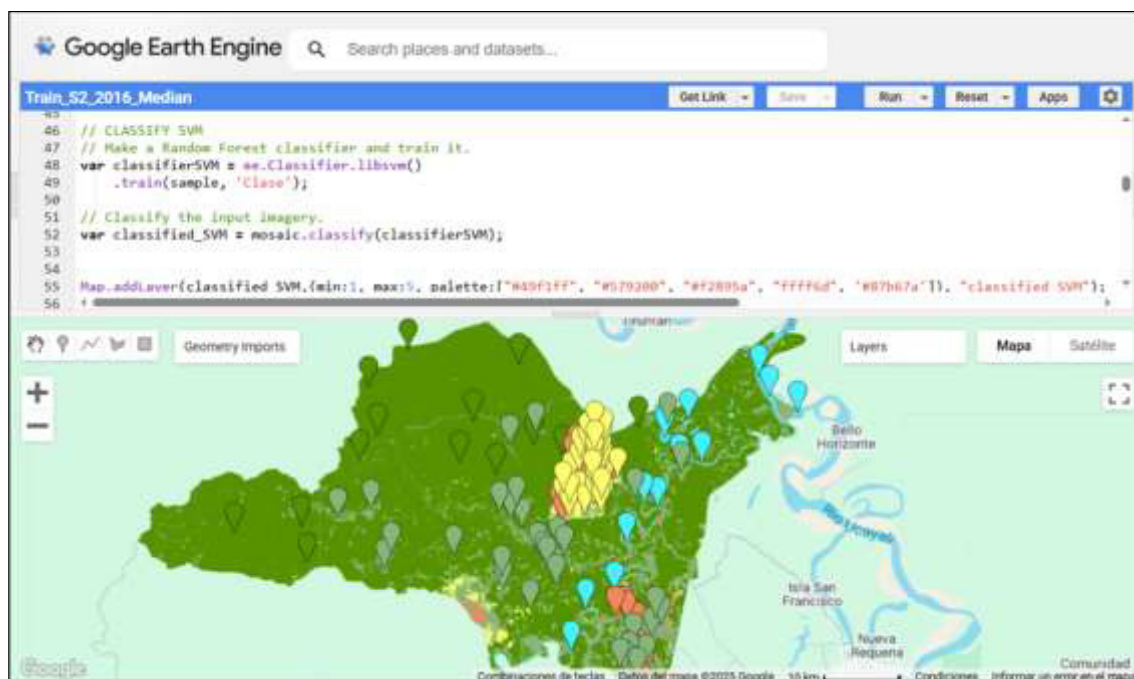


Clasificación con Support Vector Machine (SVM):

Se crea un clasificador SVM (classifierSVM) utilizando el método `ee.Classifier.libsvm()` y se entrena de manera similar al RF con la colección de muestras. Se clasifica la imagen de entrada con el clasificador SVM, generando la imagen clasificada “classified_SVM” (Figura 37 y Figura 38).

Figura 22

Clasificación Support vector Machine SVM

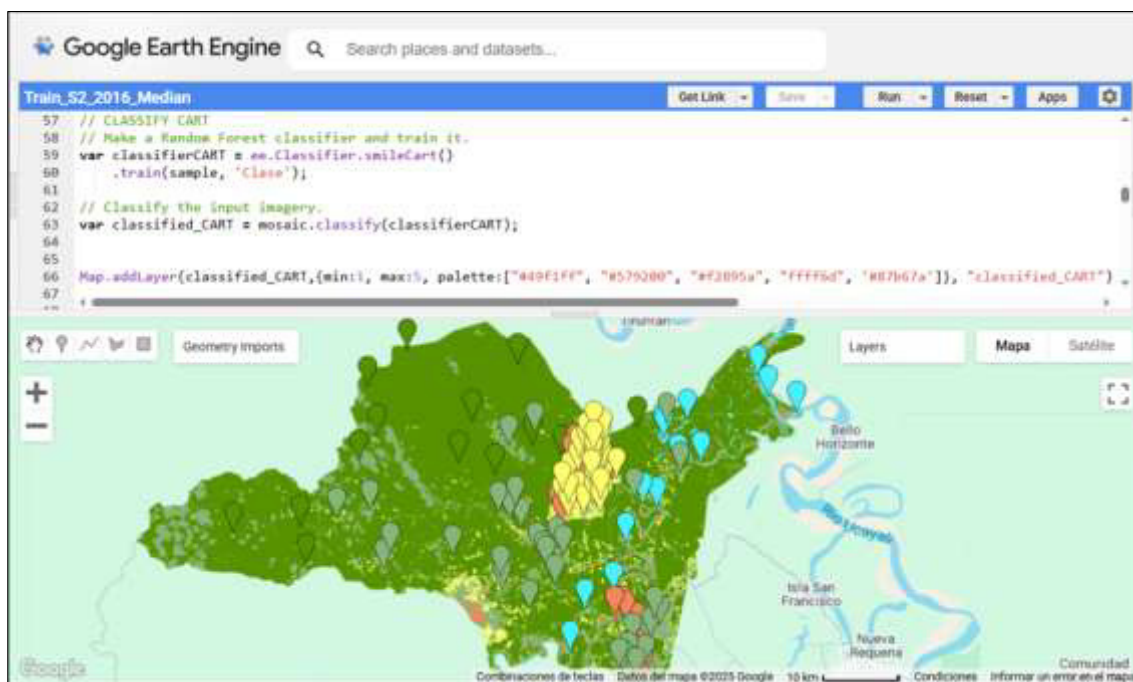


Clasificación con Classification and Regression Trees (CART):

Se crea un clasificador CART (`classifierCART`) utilizando el método `ee.Classifier.smileCart()` y se entrena de manera similar al RF con la colección de muestras. Se clasifica la imagen de entrada con el clasificador CART, generando la imagen clasificada “`classified_CART`”.

Figura 23

Clasificación CART

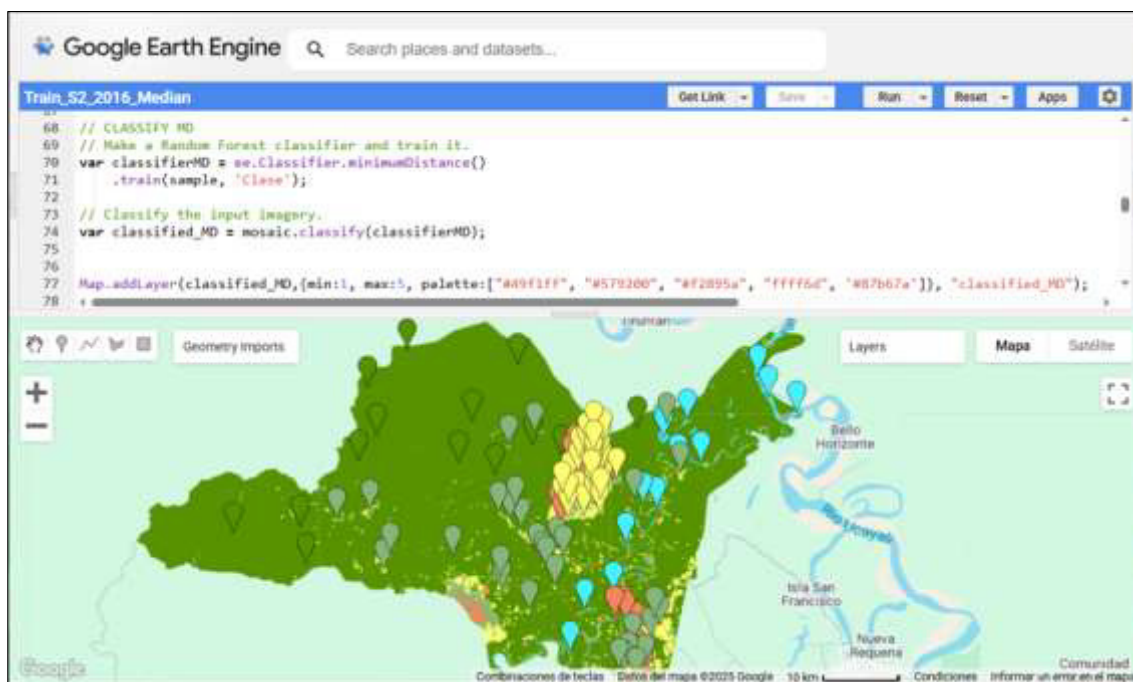


Clasificación con Mínima Distancia (MD):

Se crea un clasificador de Mínima Distancia (classifierMD) utilizando el método `ee.Classifier.minimumDistance()` y se entrena de manera similar al RF con la colección de muestras. Se clasifica la imagen de entrada con el clasificador MD, generando la imagen clasificada (`classified_MD`).

Figura 24

Clasificación Mínima Distancia

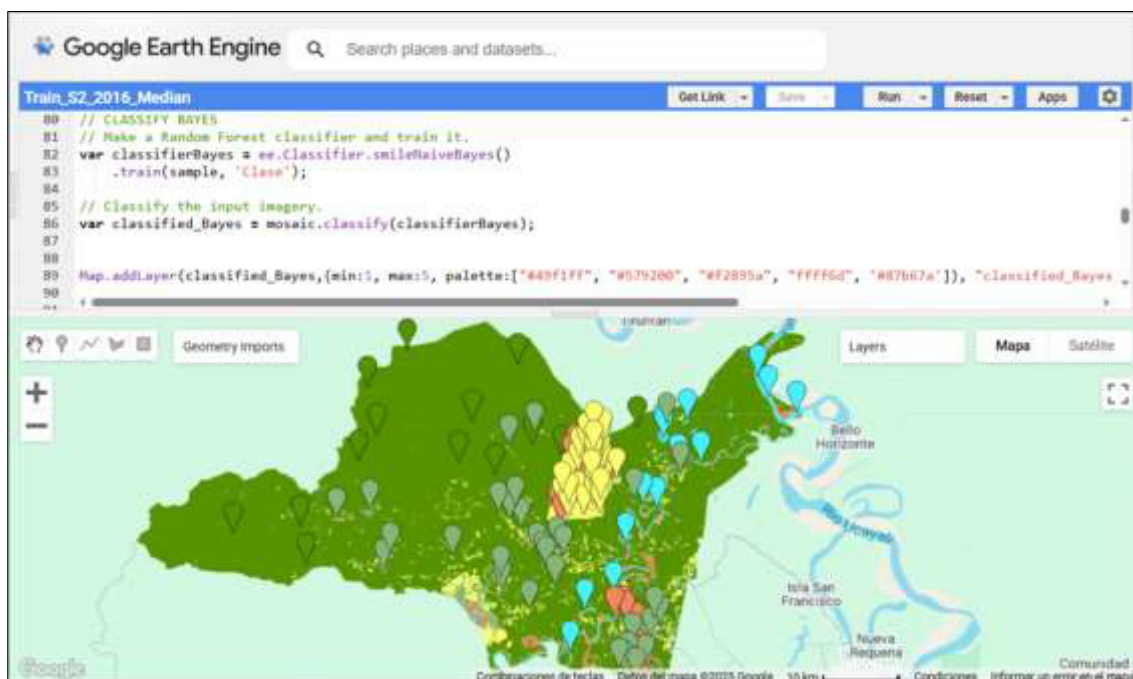


Clasificación con Naive Bayes:

Se crea un clasificador Naive Bayes (`classifierBayes`) utilizando el método `ee.Classifier.smileNaiveBayes()` y se entrena de manera similar al RF con la colección de muestras. Se clasifica la imagen de entrada con el clasificador Naive Bayes, generando la imagen clasificada “`classified_Bayes`”.

Figura 25

Clasificación Naive Bayes



Finalmente, cada imagen clasificada se agrega como una capa al mapa (`Map.addLayer`) utilizando una paleta de colores para visualizar las clases identificadas para posteriormente poder ser exportado a Google Drive asociado a la cuenta de Google Earth Engine.

Es importante tener en cuenta que cada clasificador (RF, SVM, CART, MD, Bayes) tiene sus propias características y supuestos, por lo que es recomendable evaluar el rendimiento de cada uno para el conjunto de datos específico antes de tomar decisiones finales sobre la clasificación.

Figura 26

Script de la clasificación supervisada del año 2022.

```

// LASFICACIÓN SUPERVISADA
// ENTRENAMIENTO

var training = ee.FeatureCollection([Agua, Bosque_denso, Suelo_exp, Palma, Pastizal]).flatten();

var sample = mosaic.sampleRegions(training, ['Class'], 30);

// CLASSIFY RANDOM FOREST
// Make a Random Forest classifier and train it.
var classifierRF = ee.Classifier.smileRandomForest(20)
  .train(sample, 'Class');

// Classify the input imagery.
var classified_RF = mosaic.classify(classifierRF);

Map.addLayer(classified_RF, {min:1, max:5, palette:['#49f1ff', '#579280', '#f2895a', 'ffff6d', '#87b67a']}, 'classified_RF');

// CLASSIFY SVM
// Make a Random Forest classifier and train it.
var classifierSVM = ee.Classifier.libsvm()
  .train(sample, 'Class');

// Classify the input imagery.
var classified_SVM = mosaic.classify(classifierSVM);

Map.addLayer(classified_SVM, {min:1, max:5, palette:['#49f1ff', '#579280', '#f2895a', 'ffff6d', '#87b67a']}, 'classified_SVM');

// CLASSIFY CART
// Make a Random Forest classifier and train it.
var classifierCART = ee.Classifier.smileCart()
  .train(sample, 'Class');

// Classify the input imagery.
var classified_CART = mosaic.classify(classifierCART);

Map.addLayer(classified_CART, {min:1, max:5, palette:['#49f1ff', '#579280', '#f2895a', 'ffff6d', '#87b67a']}, 'classified_CART');

// CLASSIFY MD
// Make a Random Forest classifier and train it.
var classifierMD = ee.Classifier.minimumDistance()
  .train(sample, 'Class');

// Classify the input imagery.
var classified_MD = mosaic.classify(classifierMD);

Map.addLayer(classified_MD, {min:1, max:5, palette:['#49f1ff', '#579280', '#f2895a', 'ffff6d', '#87b67a']}, 'classified_MD');

// CLASSIFY BAYES
// Make a Random Forest classifier and train it.
var classifierBayes = ee.Classifier.smileNaiveBayes()
  .train(sample, 'Class');

// Classify the input imagery.
var classified_Bayes = mosaic.classify(classifierBayes);

Map.addLayer(classified_Bayes, {min:1, max:5, palette:['#49f1ff', '#579280', '#f2895a', 'ffff6d', '#87b67a']}, 'classified_Bayes');

// Exports la imagen cortada a Google Drive
Export.image.toDrive({
  image: classified_SVM,
  description: 'classified_SVM_2022',
  folder: 'NUEVA REQUENA',
  region: table,
  scale: 10,
  crs: 'EPSG:4326'
});

```

3.6.4. Cuarta etapa: Análisis de resultados.

- Análisis de los resultados con los algoritmos de clasificación supervisada: Después de que la exportación se haya completado, se descargaron los archivos GeoTIFF resultantes desde Google Drive o desde la carpeta de salida especificada. Luego, en ArcGIS, se cargaron los archivos GeoTIFF exportados como una capa ráster y se realizó el cálculo de superficie de las diferentes clases de la clasificación supervisada para ambos años utilizando herramientas como la herramienta "Zonal Statistics" o la herramienta "Calculate Geometry" para obtenerlas. Los resultados se muestran en la **Tabla 11**.
- Cálculo de las áreas clasificadas.
- Control de calidad de resultados obtenidos.
- Generación de estadísticas.

3.7. Análisis de datos

Tras la obtención de los datos, su preparación, filtrado de metadatos, entre otros; se procedió con la ejecución de los *scripts* en Google Earth Engine con la metodología adecuada, para luego presentar los resultados de manera efectiva utilizando mapas, tablas, gráficos u otras herramientas visuales que resalten las tendencias y los patrones identificados en el análisis. Finalmente se analizó e interpretó los resultados obtenidos, sus implicaciones y cómo se relacionan con los objetivos de esta investigación.

3.8. Consideraciones éticas

Esta investigación es transparente y accesible para que otros investigadores, tomadores de decisiones y el público en general puedan comprender y evaluar los resultados, libre de sesgo o conflicto de intereses. La divulgación abierta y el acceso a los datos y métodos utilizados fomentan la confianza y permiten una revisión crítica sobre la expansión del cultivo de palma aceitera.

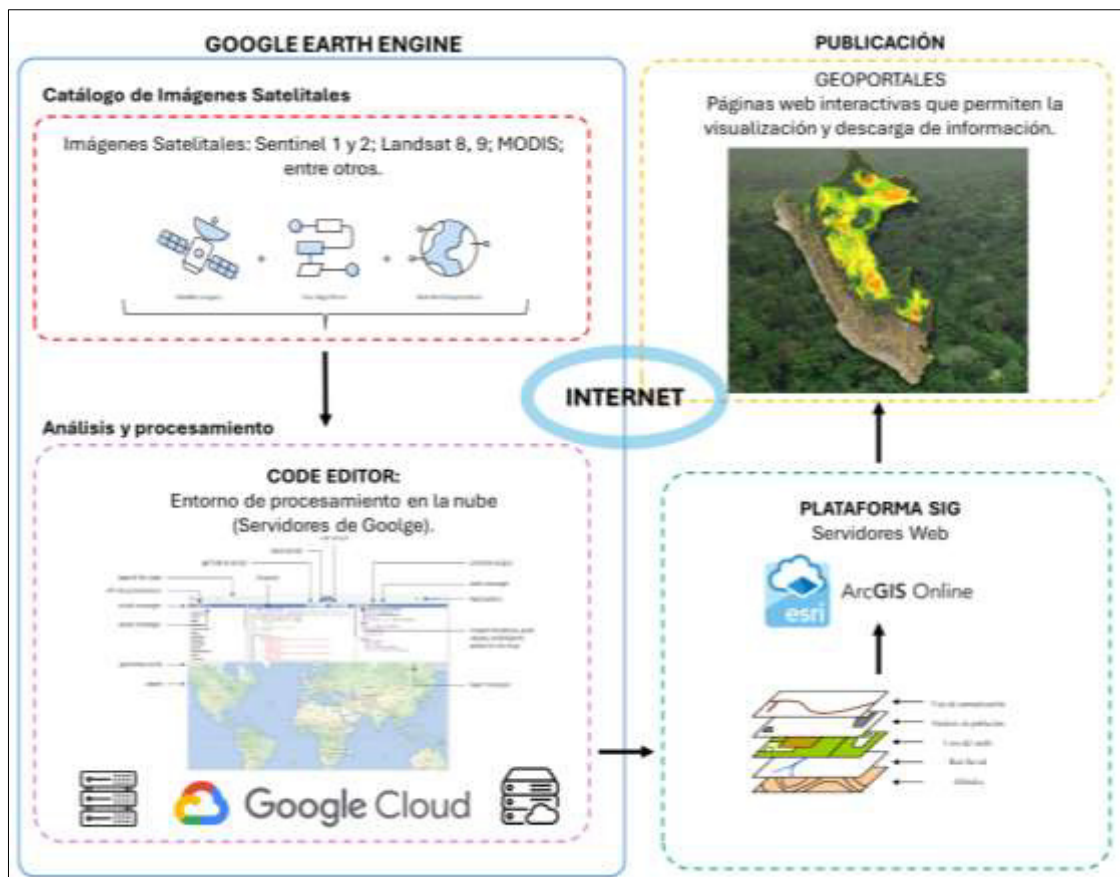
IV. RESULTADOS

4.1. Arquitectura de procesamiento.

Con el fin de optimizar el procesamiento de grandes volúmenes de imágenes satelitales y agilizar el análisis multitemporal del cultivo de palma aceitera, se propuso una arquitectura tecnológica eficiente que se muestra en la **Figura 27**.

Figura 27

Arquitectura de procesamiento de imágenes satelitales.



La arquitectura de procesamiento de imágenes satelitales abarcó el procesamiento y análisis en Google Earth Engine, utilizando su Code Editor, el cual opera sobre servidores de Google Cloud para garantizar el almacenamiento, el procesamiento en la nube y la escalabilidad de los datos. Esto permitió obtener resultados del crecimiento de la palma aceitera en el periodo establecido.

El flujo completo comprende la subida de datos procesados a un servidor de mapas web en una plataforma SIG (ArcGIS Online), desde donde se gestiona la organización de capas temáticas y la información para su difusión. Finalmente, la publicación en un Geoportal posibilita la visualización y descarga de la información de manera accesible para los usuarios finales. Este flujo de trabajo está diseñado para ser iterativo, de modo que se puedan integrar futuras actualizaciones del estudio multitemporal conforme se disponga de nuevos datos satelitales o se requiera un mayor nivel de detalle en el análisis.

Los resultados de esta investigación evidencian que la arquitectura seleccionada permite aumentar significativamente la capacidad de procesamiento, reduciendo considerablemente los tiempos de ejecución y mejorando la precisión de los resultados obtenidos.

4.2. Medios Tecnológicos

La identificación de medios tecnológicos adecuados para el levantamiento de información automatizado ha sido fundamental para el desarrollo de este estudio. Los resultados obtenidos demuestran que el empleo Google Earth Engine en el procesamiento (**Tabla 9**) junto con ArcGIS Pro para diseñar mapas y mostrarlos en servidores; facilitan la generación de información geoespacial precisa y actualizada sobre la distribución espacial del cultivo de palma aceitera.

Clasificación Supervisada en Google Earth Engine

Ventajas:

- **Escalabilidad:** Permite procesar grandes volúmenes de datos satelitales de manera eficiente, lo que es fundamental para analizar áreas extensas como el distrito de Nueva Requena.

- **Automatización:** Ofrece una amplia gama de herramientas y algoritmos que permiten automatizar gran parte del proceso de clasificación, desde la selección de las bandas espectrales hasta la generación de mapas de cobertura.
- **Actualización constante:** Se actualiza continuamente con nuevas imágenes y algoritmos, lo que garantiza que los análisis estén basados en la información más reciente.
- **Acceso gratuito:** Ofrece un acceso gratuito con ciertas limitaciones, lo que la hace accesible para investigadores con recursos limitados.
- **Reproducibilidad:** Los scripts de clasificación se pueden compartir y reproducir, lo que facilita la verificación y comparación de resultados.
- **Integración con otras herramientas:** Se puede integrar con otras herramientas de análisis espacial y visualización, lo que permite realizar análisis más complejos.

Desventajas:

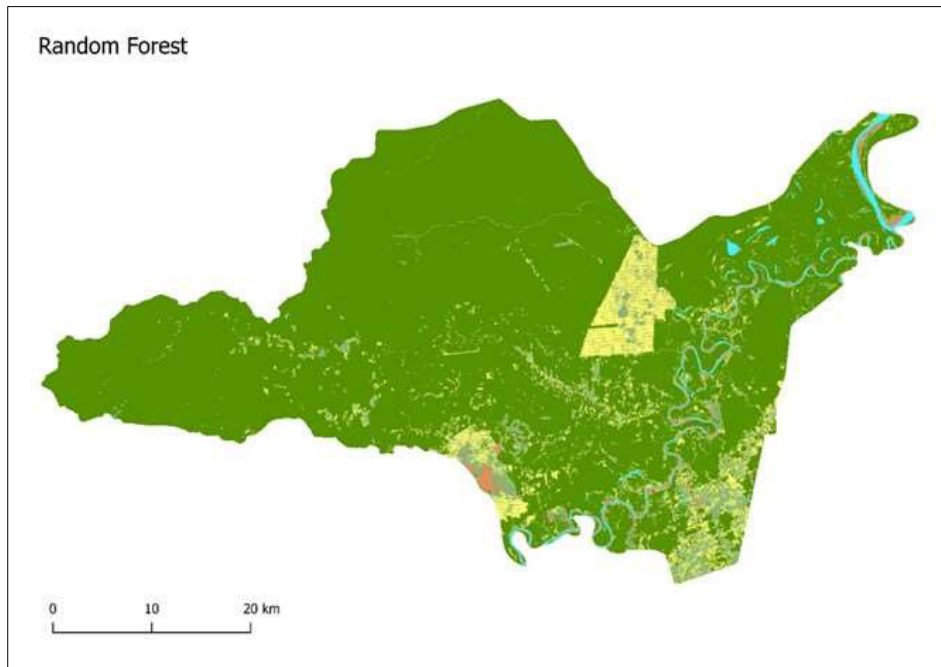
- **Requiere conocimientos técnicos:** Es necesario tener conocimientos de programación y teledetección para utilizar la plataforma de manera efectiva.
- **Dependencia de la nube:** Los resultados dependen de la estabilidad y disponibilidad de la plataforma en la nube.
- **Calidad de la clasificación:** La precisión de la clasificación depende en gran medida de la calidad de las imágenes y de la selección de las muestras de entrenamiento.

4.3. Criterios y técnicas de análisis

Clasificación con Random Forest (RF):

Figura 28

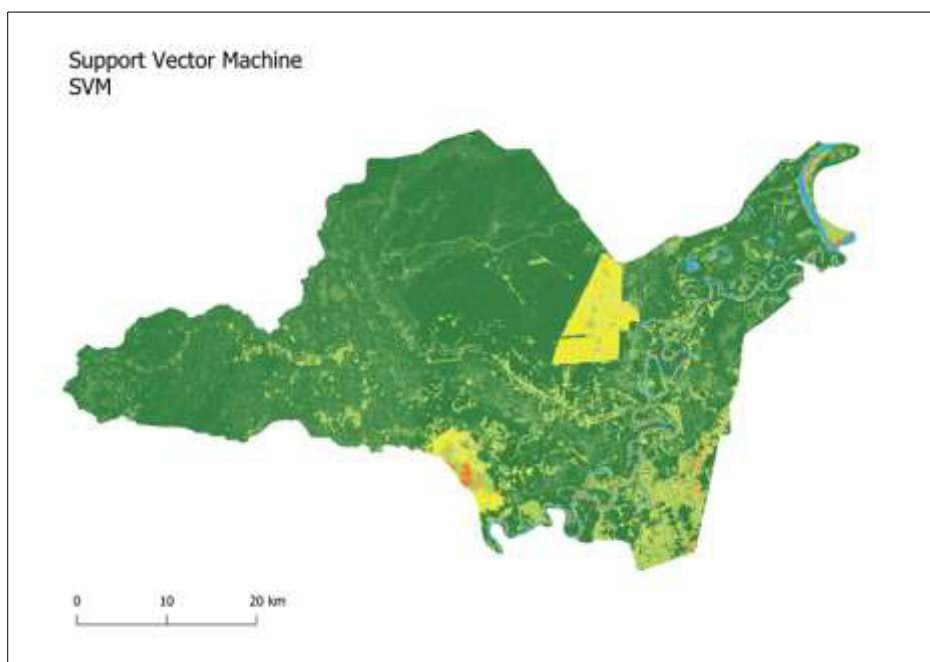
Resultados de la clasificación Random Forest

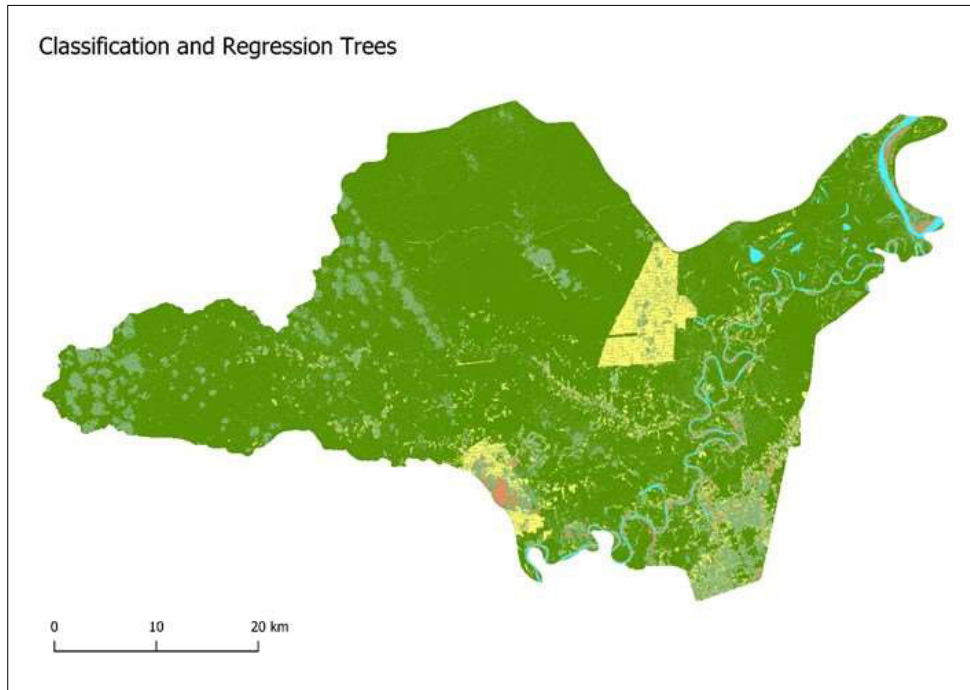
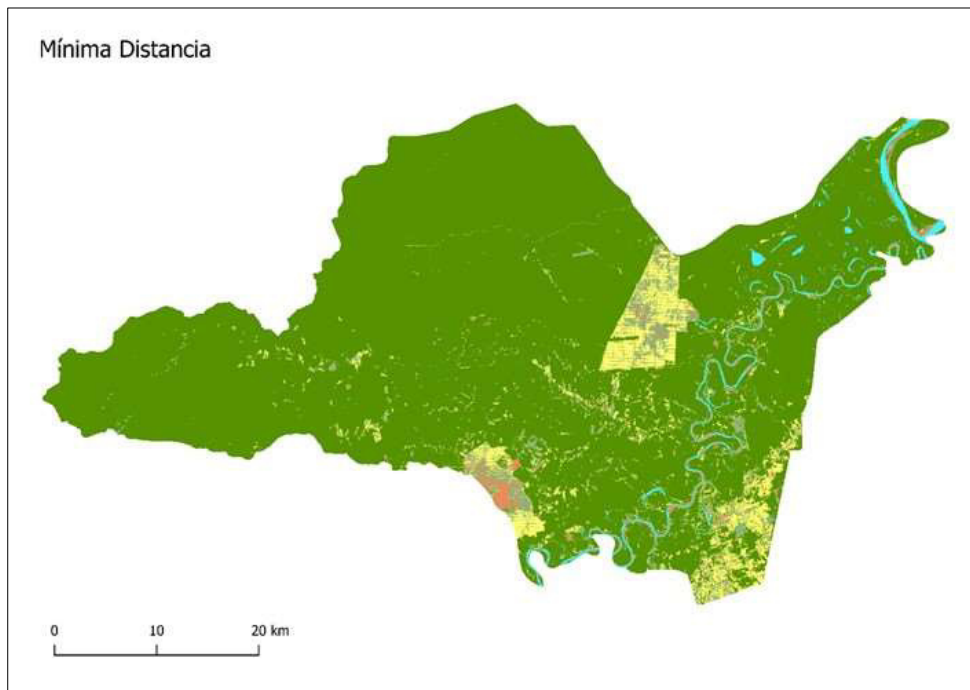


Clasificación con Support Vector Machine (SVM):

Figura 29

Resultados de la clasificación Support vector Machine SVM

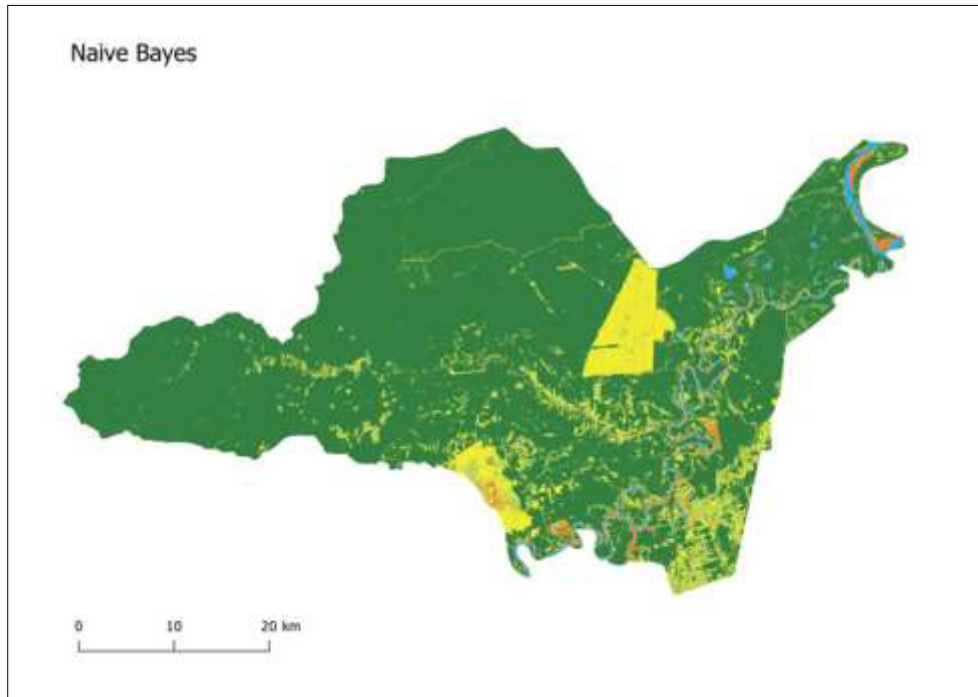


Clasificación con Classification and Regression Trees (CART):**Figura 30***Resultados de la clasificación CART***Clasificación con Mínima Distancia (MD):****Figura 31***Resultados de la clasificación Mínima Distancia*

Clasificación con Naive Bayes:

Figura 32

Resultados de la clasificación Naive Bayes



De la evaluación de la clasificación supervisada por los diferentes algoritmos, se determinó que el Support Vector Machine (SVM) es el que mejor ha clasificado las cinco clases entrenadas, con una precisión general del 89.5% como se muestra en la **Tabla 10**.


Tabla 10

Precisión de la clasificación supervisada por algoritmo

Algoritmo de clasificación	Precisión General	Coficiente de Kappa
<i>Random Forest</i>	0.842	0.797
<i>SVM</i>	0.895	0.864
<i>CART</i>	0.789	0.727
<i>MD</i>	0.737	0.665
<i>Bayes</i>	0.825	0.777

Figura 33

Precisión de la clasificación supervisada por algoritmo



4.4. Determinación de la expansión de la palma aceitera

Tabla 11

Estadísticas para la clasificación supervisada para el año 2016 y 2022

ANÁLISIS MULTITEMPORAL EN GOOGLE EARTH ENGINE PARA DETERMINAR LA EXPANSIÓN DE PALMA ACEITERA (<i>Elaeis guineensis</i>) EN EL DISTRITO NUEVA REQUENA, PROVINCIA CORONEL PORTILLO, REGIÓN UCAYALI 2016-2022.							
Estadísticas básicas para la clasificación supervisada Nueva Requena							
Área del distrito Nueva Requena (km ²): 2092.58							
2016				2022			
Clase	Tipo	Area (km ²)	Porcentaje	Clase	Tipo	Area (km ²)	Porcentaje
1	Agua	34.06	1.63%	1	Agua	43.21	2.06%
2	Bosque	1635.57	78.16%	2	Bosque	1227.89	58.68%
3	Suelo desnudo	24.63	1.18%	3	Suelo desnudo	61.89	2.96%
4	Palma	97.33	4.65%	4	Palma	300.59	14.36%
5	Pastizal	300.99	14.38%	5	Pastizal	459.00	21.93%
Total		2092.58	100.00%	Total		2092.58	100.00%


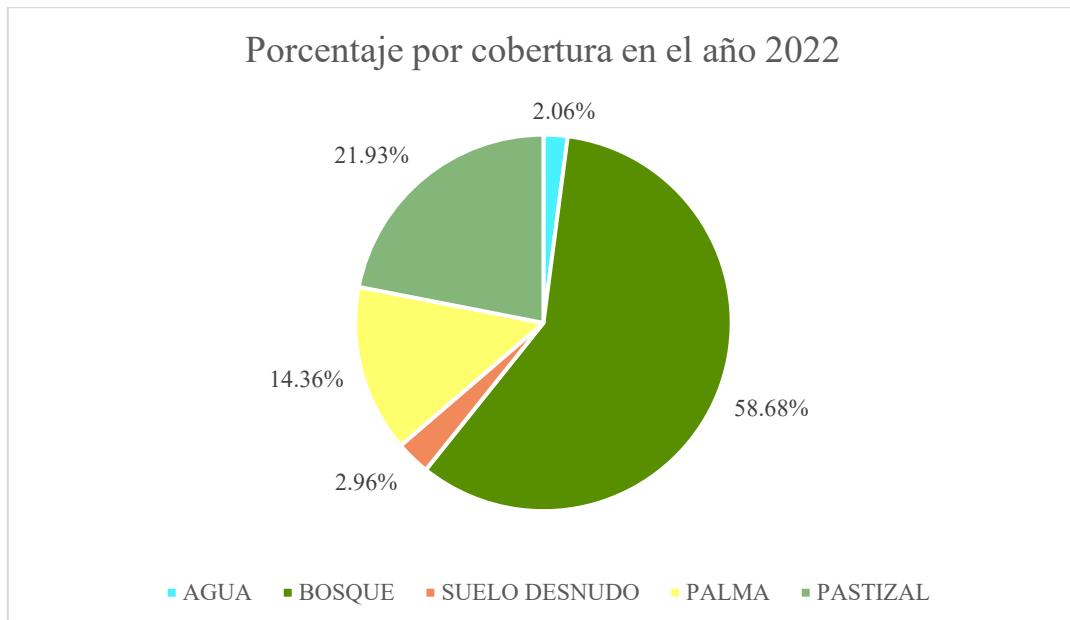
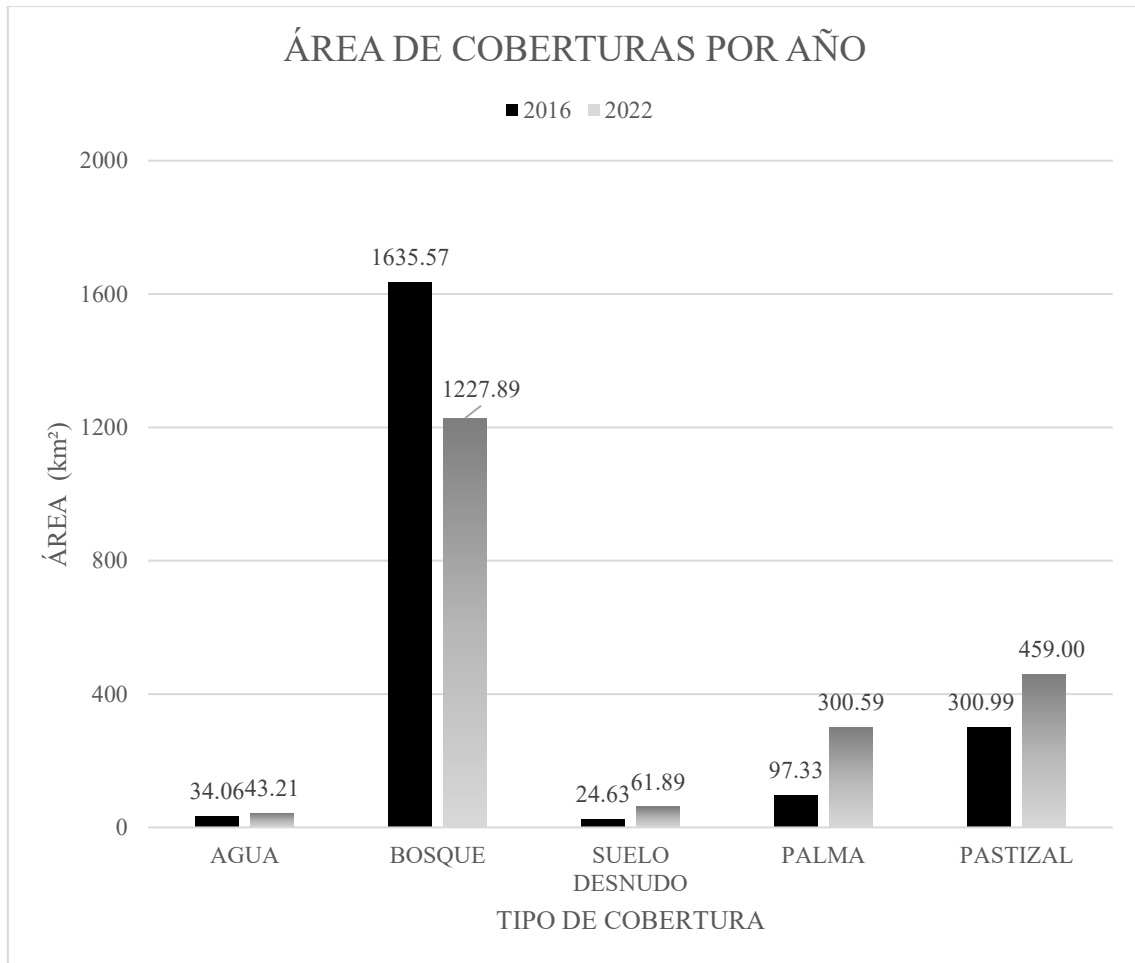
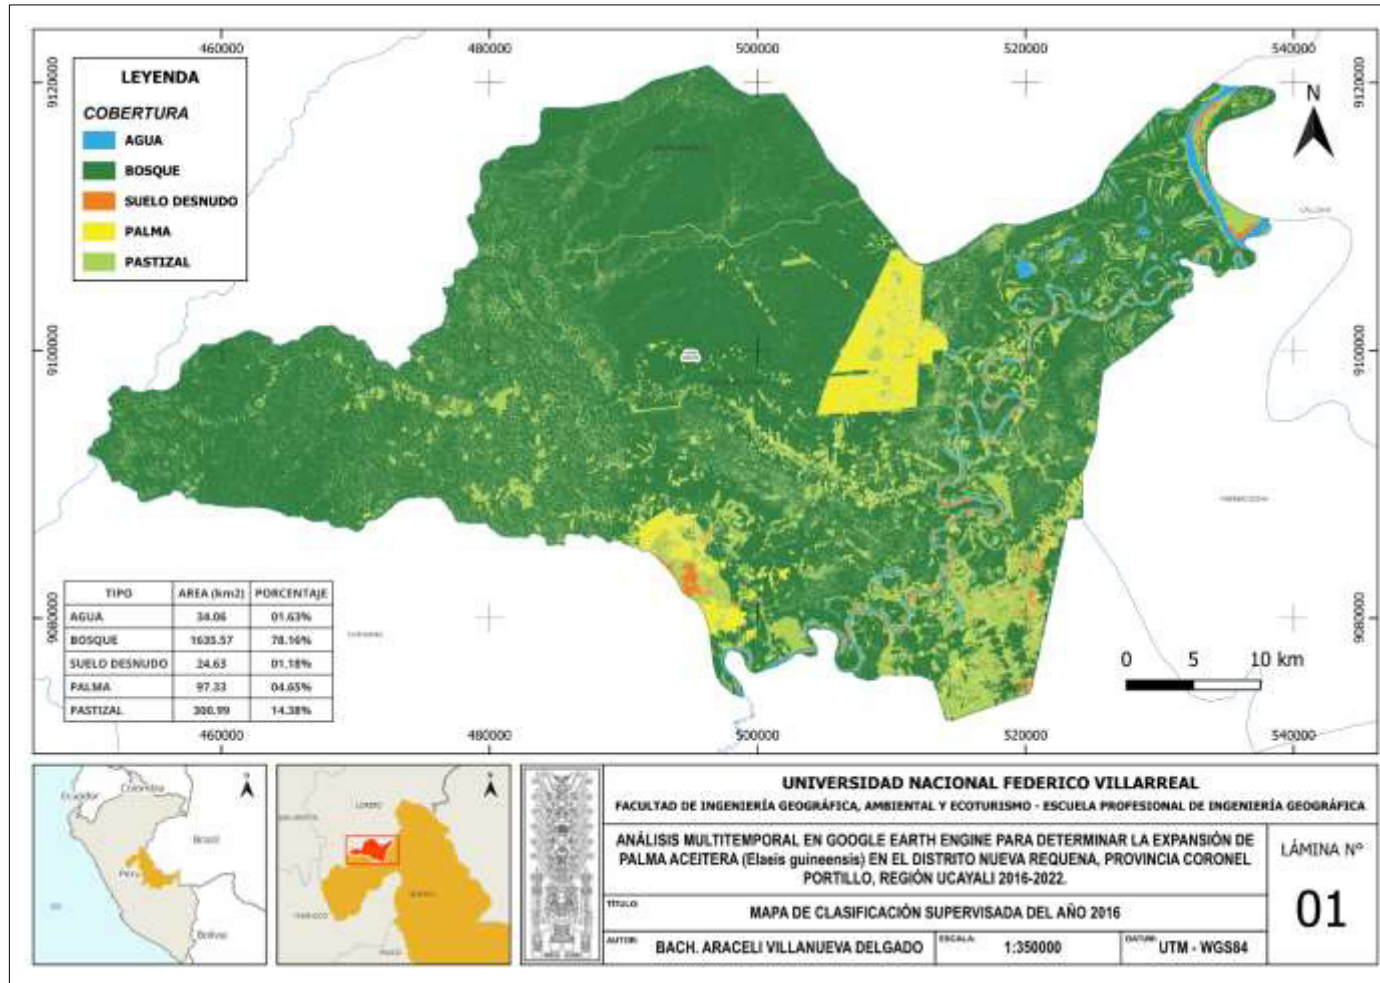
Figura 34*Porcentaje por cobertura en el año 2016***Figura 35***Porcentaje por cobertura en el año 2022*

Figura 36*Área de coberturas por año*

4.5. Mapa de Cobertura 2016

Figura 37

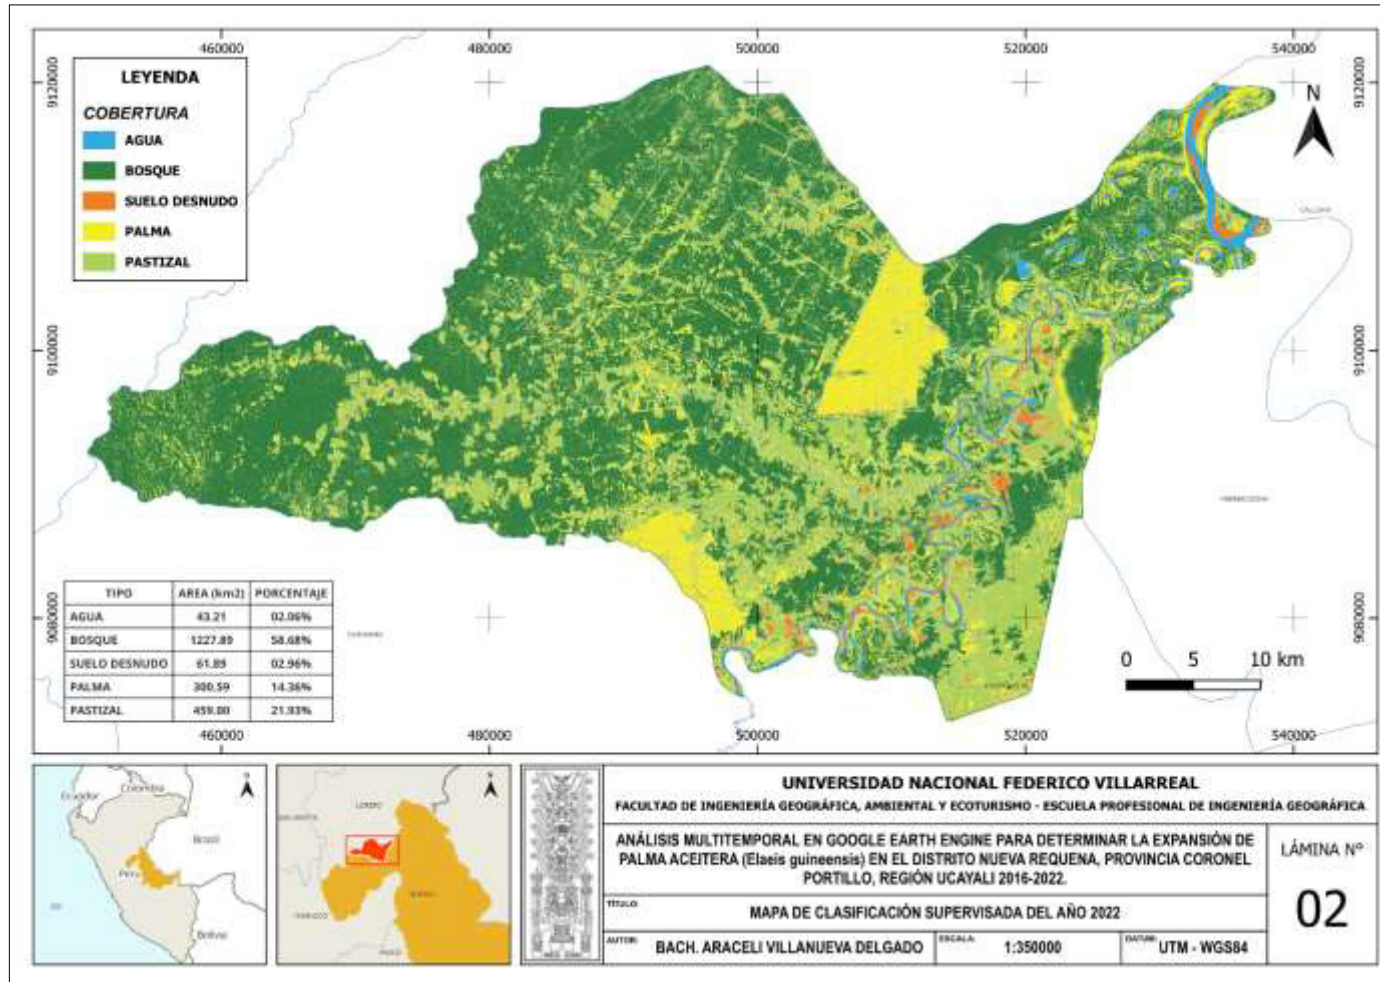
Mapa de clasificación supervisada del año 2016



4.6. Mapa de Cobertura 2022

Figura 38

Mapa de clasificación supervisada del año 2022



V. DISCUSIÓN DE RESULTADOS

En su tesis, Estimación de la pérdida de cobertura boscosa por actividades antrópicas en el distrito Nueva Requena, mediante análisis multitemporal de imágenes satelitales; Condori (2018), encontró que, en el distrito de Nueva Requena, durante un período de seis años (2011-2017), la pérdida de cobertura boscosa debido a actividades humanas fue de 26,070.04 hectáreas, lo que equivale al 13.04% del área total del distrito. Este análisis se realizó utilizando imágenes satelitales de Landsat 5 y 8. El estudio concluyó que esta pérdida es muy significativa y sugirió el uso de imágenes con mayor resolución espacial para obtener estimaciones más precisas de la pérdida de cobertura boscosa.

Es importante mencionar que la pérdida significativa de cobertura boscosa en la región de Ucayali es un fenómeno que ha sido documentado en múltiples estudios. Los resultados obtenidos en este trabajo coinciden con hallazgos similares realizados por Los Ríos (2022), quien también identificó una pérdida significativa de bosques en Ucayali debido al crecimiento del cultivo de palma aceitera y prácticas agrícolas no sostenibles, concluyendo una tasa de deforestación de 546.86 ha/ año, entre el 2013 y el 2022, en contraste la tasa de decrecimiento de la cobertura Bosque denso de la presente investigación es de aproximadamente 6794 ha/año en el periodo 2016 - 2022.

Asimismo, estudios como el de Ayca y Castro (2021) en la provincia de Padre Abad, entre el 2005 y 2020 se estima una tasa de deforestación en menor cuantía, a razón de 11.3 ha/año, aun así, resaltan la necesidad de medidas prácticas para mitigar la deforestación y promover prácticas agrícolas responsables.

Córdova y Sánchez (2020) concluyeron que entre el periodo de su estudio (2010-2018) de la variación multitemporal de la cuenca del río Neshuya, el cultivo de palma aceitera tuvo una tasa de crecimiento de aproximadamente de 5924 ha/año. Dicha cuenca espacialmente es

contigua al distrito de Nueva Requena, y se evidencia que cuantitativamente las tasas son muy próximas y a nivel espacial el incremento del cultivo se puede ser considerado de escala regional.

Al comparar nuestros resultados con investigaciones internacionales, se evidencia una problemática internacional relacionada con la expansión de la palma aceitera. En Indonesia, Sari et al. (2022) aplicaron técnicas de clasificación multitemporal para monitorear cambios en la cobertura forestal, encontrando una alta conversión de bosques nativos en plantaciones de palma aceitera, que es un claro ejemplo de lo que podría suceder en un futuro no muy lejano en el distrito de Nueva Requena.

En cuanto a las herramientas tecnológicas utilizadas, la plataforma Google Earth Engine ha demostrado ser fundamental para el análisis multitemporal de imágenes satelitales y la estimación precisa de la expansión del cultivo de palma y la deforestación asociada haciendo uso de las imágenes Sentinel 2. Esto concuerda con estudios como el de Lazecky (2018) en Indonesia, donde se utilizó además imágenes de radar de Sentinel 1 para identificar plantaciones de palma, mostrando el potencial de estas tecnologías para el monitoreo ambiental.

En términos de recomendaciones y acciones futuras, es crucial adoptar medidas efectivas para la conservación de los bosques y la gestión sostenible de la tierra. Esto podría incluir la implementación de políticas de uso del suelo más restrictivas, programas de restauración y reforestación, así como el fomento de prácticas agrícolas sostenibles que reduzcan el impacto ambiental de la expansión de cultivos.

En resumen, los resultados de esta investigación, respaldados por estudios previos a nivel local e internacional, subrayan la necesidad urgente de abordar la deforestación asociada con el crecimiento del cultivo de palma aceitera mediante acciones concretas y políticas

ambientales efectivas. La integración de tecnologías avanzadas y el conocimiento científico son herramientas clave para la toma de decisiones fundamentadas y la conservación de los ecosistemas en el Perú y a nivel global.

VI. CONCLUSIONES

- Los objetivos planteados en este estudio se cumplieron satisfactoriamente. Se logró aplicar el análisis multitemporal de imágenes satelitales en Google Earth Engine para determinar la expansión de cultivos de palma aceitera en el distrito de Nueva Requena entre 2016 y 2022, evidenciando un crecimiento de 203.26 km², esto implica un crecimiento porcentual del 9.71% en la cobertura de palma aceitera durante este período.
- La arquitectura tecnológica seleccionada, basada en Google Earth Engine, demostró ser óptima para aumentar la capacidad de procesamiento de imágenes satelitales, reduciendo significativamente los tiempos de ejecución y mejorando la precisión de los resultados.
- La identificación de medios tecnológicos adecuados, como la combinación de Google Earth Engine y ArcGIS Pro, permitió el levantamiento de información automatizado y la generación de información geoespacial precisa y actualizada. En comparación con los métodos tradicionales, la clasificación supervisada en Google Earth Engine ofrece ventajas significativas en términos de escalabilidad, automatización, acceso gratuito y capacidad de integración con otras herramientas. Sin embargo, es importante destacar que la precisión de la clasificación depende mayormente de la calidad de las imágenes y de la selección de muestras de entrenamiento.
- La selección de criterios y técnicas de análisis apropiados, considerando las condiciones climatológicas locales, resultó fundamental para garantizar la calidad y fiabilidad de los resultados obtenidos. El algoritmo de clasificación supervisada Support Vector Machine (SVM) demostró ser el más preciso para identificar el cultivo de palma aceitera, con una precisión general del 89.5%.

VII. RECOMENDACIONES

- Desarrollar estrategias y políticas para equilibrar el crecimiento económico con la conservación ambiental, considerando la expansión del cultivo de palma. Dado que se ha determinado un aumento significativo en la expansión del cultivo de palma aceitera y una pérdida considerable de área boscosa.
- Continuar con el monitoreo multitemporal utilizando imágenes satelitales y plataformas como Google Earth Engine para evaluar los cambios en el uso del suelo a lo largo del tiempo. Esto permitirá detectar de manera temprana cualquier tendencia de expansión de cultivos y tomar medidas correctivas oportunas.
- Incluir programas de reforestación, regulaciones ambientales más estrictas y acciones para promover prácticas agrícolas sostenibles.
- Capacitar a los profesionales que toman decisiones en la región en el uso de herramientas de análisis espacial y plataformas como Google Earth Engine. Esto permitirá sacar provecho al máximo las capacidades de análisis y monitoreo que ofrecen estas tecnologías, facilitando la toma de decisiones más informadas y basadas en evidencia científica.

VIII. REFERENCIAS

- Angel, J. (2022). *Los impactos de la palma aceitera en Ecuador: Un análisis geográfico y multitemporal de la expansión del cultivo y sus relaciones con el sistema socioecológico de la provincia de Esmeraldas* [Tesis de maestría, Universidad Andina Simón Bolívar]. UASB-Digital. <https://repositorio.uasb.edu.ec/handle/10644/8922>
- Ayca, K., y Castro, Y. (2021). *Análisis de la variación multitemporal de la pérdida de cobertura boscosa en el C. P. de Shambillo A y B – Padre Abad en el periodo 2005 a 2020* [Tesis de pregrado, Universidad Peruana Unión]. RENATI. <https://repositorio.upeu.edu.pe/items/0ed00361-f147-4d84-8162-23b4dc9ce654>
- Bravo, N. (2017). *Teoría: Teledetección espacial Landsat, Sentinel-2, Aster LIT y Modis* (1ª ed.). Geomática Ambiental S.R.L.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L., Friedman, J., Olshen, R., y Stone, C. (1984). *Classification and regression trees*. Chapman and Hall/CRC.
- Castilla, J. (27 de octubre de 2009). Argentina reduce ritmo deforestación, pero duplica tasa global. *Reuters*. <https://www.reuters.com/article/ambiente-argentina-deforestacion-idARN2724626520091027>
- Centro Nacional de Planeamiento Estratégico. (2019). *Amazonía peruana: dinámicas territoriales y retos para el desarrollo sostenible*. CEPLAN. https://www.ceplan.gob.pe/documentos_/amazonia-peruana-dinamicas-territoriales-y-retos-para-el-desarrollo-sostenible/
- Chuvieco, E. (1995). *Fundamentos de la teledetección espacial* (2ª ed.). Ediciones Rialp.

- Condori, W. (2018). *Estimación de la pérdida de cobertura boscosa por actividades antrópicas en el distrito Nueva Requena, mediante análisis multitemporal de imágenes satelitales, 2018* [Tesis de pregrado, Universidad César Vallejo]. Repositorio UCV. <https://repositorio.ucv.edu.pe/handle/20.500.12692/20512>
- Constitución Política del Perú [Const.]. Arts. 66 y 68, 29 de diciembre de 1993 (Perú).
- Copernicus Data Space Ecosystem. (2023). *Data Sentinel-2 L2A*. Copernicus Data Space Ecosystem. <https://documentation.dataspace.copernicus.eu/APIs/SentinelHub/Data/S2L2A.html>
- Córdova, J., y Sánchez, L. (2020). *Análisis de la variación multitemporal de la cobertura vegetal entre los años 2010-2018, en la cuenca del río Neshuya, Ucayali, Perú* [Tesis de pregrado, Universidad Nacional de Ucayali]. RENATI. <https://repositorio.unu.edu.pe/items/03b57cdd-dc8f-414e-bfc5-ad6e0d9c3093>
- Cortes, C., y Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Dammert, J. L. (2014). *Cambio de uso de suelos por agricultura a gran escala en la Amazonía andina: El caso de la palma aceitera*. International Resources Group/Engility.
- De Almeida, A., Guimarães, I., y Ferraz, S. (2019). Long-term assessment of oil palm expansion and landscape change in the eastern Brazilian Amazon. *Land Use Policy*, 81, 357-369. <https://doi.org/10.1016/j.landusepol.2019.104321>
- De Los Ríos, A. R. (2022). *Análisis multitemporal por pérdida de cobertura boscosa 2005-2020 por palma aceitera para minimizar la deforestación Ucayali 2021* [Tesis de pregrado, Universidad César Vallejo]. RENATI. <https://repositorio.ucv.edu.pe/handle/20.500.12692/88702>

- Decreto Supremo N.º 014-2015-MINAGRI. Reglamento de la Ley Forestal y de Fauna Silvestre. (8 de abril de 2015). <https://www.gob.pe/institucion/minagri/normas-legales/292792-014-2015-minagri>
- Ecoscript. (1 de septiembre de 2020). *Técnicas de clasificación de imágenes en la teledetección*. Ecoscript. <https://ecoscript.org/tecnicasclasificacionimagenes/>
- Environmental Systems Research Institute [ESRI]. (2022). *¿Qué es la clasificación de imagen?* ArcGIS Desktop. <https://desktop.arcgis.com/es/arcmap/latest/extensions/spatial-analyst/image-classification/what-is-image-classification-.htm>
- Fonseca, J. J. (2020). *Análisis multitemporal mediante imágenes Landsat. Caso de estudio: Cambio de área laderas de la ciénaga de Tumaradó, Parque Natural Los Katíos* [Tesis de especialización en geomática, Universidad Militar Nueva Granada]. Repositorio UMNG. <https://repository.umng.edu.co/items/7dd54497-bffd-4714-a23b-cbde6b5016c9>
- Friedman, N., Geiger, D., & Goldszmidt, M. (1997). Bayesian network classifiers. *Machine Learning*, 29(2-3), 131-163. <https://doi.org/10.1023/A:1007465528199>
- García, L., y FENAPALMA. (2005). *Manual técnico palma africana*. Federación Nacional de Palmicultores de Honduras.
- Gis&Beers. (22 de febrero de 2020). *Todo lo que deberías saber sobre imágenes Landsat*. Gis&Beers. <http://www.gisandbeers.com/lo-deberias-saber-imagenes-landsat/>
- Global Forest Watch. (2020). *Ucayali, Peru: Deforestation rates & statistics*. Global Forest Watch. <https://www.globalforestwatch.org/dashboards/country/PER/26/2/>
- Google. (2023). *Google Earth Engine*. Google. <https://earthengine.google.com/>

Hernández, J. (2007). Procesamiento digital de imágenes. En J. Hernández, *Manejo y conservación de recursos forestales* (pp. 15-16). Editorial Universitaria.

Hernández, R., Fernández, C., y Baptista, M. del P. (2014). *Metodología de la investigación* (6ª ed.). McGraw-Hill.

Info Agro. (13 de marzo de 2020). *El cultivo de la palma africana*. Info Agro. https://infoagro.com/herbaceos/oleaginosas/palma_africana_aceitera_coroto_de_guinea_aabora.htm

Instituto Geográfico Nacional [IGN]. (15 de marzo de 2022). *Plan Nacional de Teledetección*. IGN. <https://pnt.ign.es/satelites-sentinel>

Junta Nacional de Palma Aceitera del Perú [JUNPALMA]. (2022). *Palma aceitera en el Perú: Reporte estadístico 2021*. JUNPALMA. <https://junpalmaperu.org/wp-content/uploads/2022/06/Reporte-Estadistico-2021.pdf>

Lazecky, M. (2018). Application of Sentinel-1 satellite to identify oil palm plantations in Balikpapan Bay. *IOP Conference Series: Earth and Environmental Science*, 169(1), 012064. <https://iopscience.iop.org/article/10.1088/1755-1315/169/1/012064/pdf>

Ley N.º 26821, Ley Orgánica para el Aprovechamiento Sostenible de los Recursos Naturales. (26 de junio de 1997). <https://www.gob.pe/institucion/minam/normas-legales/3578-26821>

Ley N.º 26834, Ley de Áreas Naturales Protegidas. (4 de julio de 1997). <https://www.gob.pe/institucion/congreso-de-la-republica/normas-legales/3571-26834>

Ley N.º 26839, Ley sobre la Conservación y Aprovechamiento Sostenible de la Diversidad Biológica. (16 de julio de 1997). <https://www.leyes.congreso.gob.pe/Documentos/Leyes/26839.pdf>

Ley N.º 27037, Ley de Promoción de la Inversión en la Amazonía. (30 de diciembre de 1998).

<https://www.gob.pe/institucion/congreso-de-la-republica/normas-legales/292638-27037>

Ley N.º 28611, Ley General del Ambiente. (15 de octubre de 2005).

<https://www.minam.gob.pe/wp-content/uploads/2013/06/ley-general-del-ambiente.pdf>

Ley N.º 29763, Ley Forestal y de Fauna Silvestre. (22 de julio de 2011).

<https://www.leyes.congreso.gob.pe/Documentos/Leyes/29763.pdf>

Ley N.º 30428, Ley que oficializa el Sistema de Cuadrículas Mineras en Coordenadas UTM WGS84. (30 de abril de 2016).

<https://www.leyes.congreso.gob.pe/Documentos/Leyes/30428.pdf>

Ministerio de Ambiente y Desarrollo Sostenible. (4 de agosto de 2021). *¡Es ley! La deforestación ya es delito y será penalizada hasta con 15 años de cárcel*. Ministerio de Ambiente y Desarrollo Sostenible de Colombia.

<https://www.minambiente.gov.co/asuntos-legislativos/es-ley-la-deforestacion-ya-es-delito-y-sera-penalizada-hasta-con-15-anos-de-carcel/>

Ministerio de Desarrollo Agrario y Riego. (21 de diciembre de 2020). *Superficie agrícola del Perú*. MIDAGRI. <https://siea.midagri.gob.pe/portal/informativos/superficie-agricola-peruana>

Ministerio del Ambiente. (2022). *Perú, país de bosques*. MINAM.

<https://www.minam.gob.pe/programa-bosques/peru-pais-de-bosques/>

Ministerio Público. (15 de marzo de 2022). *Anuario estadístico del Ministerio Público 2021*.

Ministerio Público Fiscalía de la Nación.

<https://www.gob.pe/institucion/mpfn/informes-publicaciones/2818743-anuario-estadistico-del-ministerio-publico-2021>

Ochoa, F. (16 de enero de 2023). *¿Qué es un análisis multitemporal?* El Blog de Franz.

<https://acolita.com/que-es-un-analisis-multitemporal/>

Ochoa, F. (7 de marzo de 2023). *Multitemporal analysis*. GIS-Crack.

<https://giscrack.com/multitemporalanalysis/>

Ormeño, S. (2006). *Teledetección fundamental* (3ª ed.). Universidad Politécnica.

Resolución Ministerial N.º 015-2001-AG. Plan Nacional de Promoción de la Palma Aceitera

2000-2010. (19 de enero de 2001). <https://faolex.fao.org/docs/pdf/per31489.pdf>

Richards, J., y Xiuping, J. (2006). *Remote sensing digital image analysis* (4ª ed.). Springer.

Rodríguez, L. D. (2021). *Análisis multitemporal utilizando imágenes Landsat para la determinación de la pérdida de la capacidad productiva en la cuenca media del Río Magdalena* [Tesis de especialización en geomática, Universidad Militar Nueva Granada].
Repositorio UMNG.

<https://repository.umng.edu.co/server/api/core/bitstreams/25e48e0c-f6a5-4539-9085-e93a74e30f9d/content>

Rojas, J. C., y Castiblanco, C. (2018). Variabilidad espacial y análisis multitemporal sobre los cambios en las coberturas de la tierra ocasionados por la expansión del cultivo de la palma de aceite en los años 1985, 2000 y 2016 en el municipio de San Carlos de Guaroa (Colombia). *Gestión y Ambiente*, 21(1), 58-68.

<https://doi.org/10.15446/ga.v21n1.69096>

- Sánchez García, A., y Toral Ruiz, N. (2014). *Análisis de las capacidades de los sistemas Landsat y EO1 para la actualización cartográfica: Estudio de un caso práctico*. Universidad Politécnica de Madrid.
- Sari, I., Weston, C., Newnham, G., y Volkova, G. (2022). Using Bayesian multitemporal classification to monitor tropical forest cover changes in Kalimantan, Indonesia. *International Journal of Digital Earth*, 15(1), 2061-2077. <https://doi.org/10.1080/17538947.2022.2146219>
- Suárez, J. (2018). *Sistemas espaciales de teledetección*. DocsPlayer. <https://docplayer.es/73373940-Tema-iii-sistemas-espaciales-de-teledeteccion.html>
- Tomlinson, P. (1990). *The structural biology of palms*. Oxford University Press.
- Universidad de Murcia. (s.f.). *Introducción a las técnicas de clasificación*. Universidad de Murcia. <https://www.um.es/geograf/sigmur/teledet/clasific.html>
- Utreras, F. (27 de junio de 2019). *Copernicus: Datos abiertos y gratuitos* [Diapositiva]. IDE.cl. https://www.ide.cl/descargas/Workshop_2019/Presentaciones/10.CopernicusDatosAbiertosyGratuitos-Florencio-Utreras.pdf

IX. ANEXOS

Anexo A: Matriz de consistencia

Anexo B: Mapa de Cobertura 2016

Anexo C: Mapa de Cobertura 2022

Anexo D: Scripts de Google Earth Engine

SCRIPT PARA LA CLASIFICACIÓN SUPERVISADA EN GOOGLE EARTH ENGINE

Clasificación supervisada 2016

```

// COLECCIÓN DE SENTINEL 2
var s2 = ee.ImageCollection('COPERNICUS/S2')
    .filterDate('2016-08-01', '2016-10-31')
    .filterMetadata('CLOUD_COVERAGE_ASSESSMENT', 'less_than', 10)
    //.filter(ee.Filter.inList('MGRS_TILE', ['18LWR', '18LVR', '18MVS',
'18MWS']))
    .filterBounds(table)
    .median()

//SIMBOLOGÍA FALSO COLOR

var viz = {'bands':['B12', 'B11', 'B4'],
    'gamma': 1,
    'max': 3971.787232904865,
    'min': -826.5563177792135,
    'opacity': 1}

var mosaic = s2.select(['B12', 'B11', 'B4']).clip(table);

//-----MAPA-----//
Map.addLayer(s2, viz, 'Median Nueva Requena', false)
Map.addLayer(table, '', 'Nueva Requena - Buffer_100m', false)
print(s2);
Map.centerObject(table, 10);

// -----CLASIFICACIÓN SUPERVISADA -----
// ENTRENAMIENTO

var training = ee.FeatureCollection([Agua, Bosque_denso, Suelo_exp, Palma,
Pastizal]).flatten();

var sample = mosaic.sampleRegions(training, ["Clase"], 30);

// CLASSIFY RANDOM FOREST
// Make a Random Forest classifier and train it.
var classifierRF = ee.Classifier.smileRandomForest(20)
    .train(sample, 'Clase');

// Classify the input imagery.
var classified_RF = mosaic.classify(classifierRF);

Map.addLayer(classified_RF, {min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a",
"ffff6d", "#87b67a"]}, "classified_RF");

// CLASSIFY SVM
// Make a Random Forest classifier and train it.
var classifierSVM = ee.Classifier.libsvm()
    .train(sample, 'Clase');

// Classify the input imagery.
var classified_SVM = mosaic.classify(classifierSVM);

```

```

Map.addLayer(classified_SVM,{min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a",
"ffff6d", '#87b67a']}, "classified_SVM");

// CLASSIFY CART
// Make a Random Forest classifier and train it.
var classifierCART = ee.Classifier.smileCart()
    .train(sample, 'Clase');

// Classify the input imagery.
var classified_CART = mosaic.classify(classifierCART);

Map.addLayer(classified_CART,{min:1, max:5, palette:["#49f1ff", "#579200",
"#f2895a", "ffff6d", '#87b67a']}, "classified_CART");

// CLASSIFY MD
// Make a Random Forest classifier and train it.
var classifierMD = ee.Classifier.minimumDistance()
    .train(sample, 'Clase');

// Classify the input imagery.
var classified_MD = mosaic.classify(classifierMD);

Map.addLayer(classified_MD,{min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a",
"ffff6d", '#87b67a']}, "classified_MD");

// CLASSIFY BAYES
// Make a Random Forest classifier and train it.
var classifierBayes = ee.Classifier.smileNaiveBayes()
    .train(sample, 'Clase');

// Classify the input imagery.
var classified_Bayes = mosaic.classify(classifierBayes);

Map.addLayer(classified_Bayes,{min:1, max:5, palette:["#49f1ff", "#579200",
"#f2895a", "ffff6d", '#87b67a']}, "classified_Bayes");

//throw('stop')

// Exporta la imagen cortada a Google Drive
Export.image.toDrive({
  image: classified_SVM,
  description: 'classified_SVM',
  folder: 'NUEVA REQUENA',
  region: table,
  scale: 10,
  crs: 'EPSG:4326'
});

```

Clasificación supervisada 2022

```
// COLECCIÓN DE SENTINEL 2
var s2 = ee.ImageCollection('COPERNICUS/S2')
  .filterDate('2022-08-01', '2022-10-31')
  .filterMetadata('CLOUD_COVERAGE_ASSESSMENT', 'less_than', 10)
  //.filter(ee.Filter.inList('MGRS_TILE', ['18LWR', '18LVR', '18MVS', '18MWS']))
  .filterBounds(table)
  .median()

//SIMBOLOGÍA FALSO COLOR

var viz = {'bands':['B12', 'B11', 'B4'],
  'gamma': 1,
  'max': 4832,
  'min': 1000,
  'opacity': 1}

var mosaic = s2.select(['B12', 'B11', 'B4']).clip(table);

//-----MAPA-----//
Map.addLayer(s2, viz, 'Median Nueva Requena', false)
Map.addLayer(table, '', 'Nueva Requena - Buffer_100m', false)
print(s2);
Map.centerObject(table, 10);

// -----CLASIFICACIÓN SUPERVISADA -----
// ENTRENAMIENTO

var training = ee.FeatureCollection([Agua, Bosque_denso, Suelo_exp, Palma,
Pastizal]).flatten();

var sample = mosaic.sampleRegions(training, ["Clase"], 30);

// CLASSIFY RANDOM FOREST
// Make a Random Forest classifier and train it.
var classifierRF = ee.Classifier.smileRandomForest(20)
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_RF = mosaic.classify(classifierRF);

Map.addLayer(classified_RF, {min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a", "ffff6d",
"#87b67a"]}, "classified_RF");

// CLASSIFY SVM
// Make a Random Forest classifier and train it.
var classifierSVM = ee.Classifier.libsvm()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_SVM = mosaic.classify(classifierSVM);

Map.addLayer(classified_SVM, {min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a", "ffff6d",
"#87b67a"]}, "classified_SVM");

// CLASSIFY CART
// Make a Random Forest classifier and train it.
var classifierCART = ee.Classifier.smileCart()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_CART = mosaic.classify(classifierCART);
```

```
Map.addLayer(classified_CART,{min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a", "ffff6d",
'#87b67a']}, "classified_CART");

// CLASSIFY MD
// Make a Random Forest classifier and train it.
var classifierMD = ee.Classifier.minimumDistance()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_MD = mosaic.classify(classifierMD);

Map.addLayer(classified_MD,{min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a", "ffff6d",
'#87b67a']}, "classified_MD");

// CLASSIFY BAYES
// Make a Random Forest classifier and train it.
var classifierBayes = ee.Classifier.smileNaiveBayes()
  .train(sample, 'Clase');

// Classify the input imagery.
var classified_Bayes = mosaic.classify(classifierBayes);

Map.addLayer(classified_Bayes,{min:1, max:5, palette:["#49f1ff", "#579200", "#f2895a",
"ffff6d", '#87b67a']}, "classified_Bayes");

// Exporta la imagen cortada a Google Drive
Export.image.toDrive({
  image: classified_SVM,
  description: 'classified_SVM_2022',
  folder: 'NUEVA REQUENA',
  region: table,
  scale: 10,
  crs: 'EPSG:4326'
});
throw('stop')
```

Anexo E: Cuadro de coordenadas de puntos de entrenamiento.

TABLA DE COORDENADAS DE PUNTOS DE ENTRENAMIENTO

Clase	Tipo	Longitud	Latitud	Índice
1	Agua	-74.8216769	-8.08424799	0
1	Agua	-74.8192737	-8.08900671	1
1	Agua	-74.7907779	-8.06793193	2
1	Agua	-74.7747322	-8.11785673	3
1	Agua	-74.8016115	-8.12019832	4
1	Agua	-74.7053941	-8.01405852	5
1	Agua	-74.6937212	-8.03819566	6
1	Agua	-74.6587023	-8.0572324	7
1	Agua	-74.8279263	-8.17192415	8
1	Agua	-74.8444058	-8.16640176	9
1	Agua	-74.8647104	-8.21480929	10
1	Agua	-74.8803555	-8.27290883	11
1	Agua	-74.9138184	-8.29275315	12
1	Agua	-74.9320707	-8.34350529	13
2	Bosque denso	-75.0503515	-8.068616	0
2	Bosque denso	-74.9770435	-8.09764786	1
2	Bosque denso	-74.942368	-8.11056384	2
2	Bosque denso	-75.1655252	-8.08439659	3
2	Bosque denso	-75.1881845	-8.11634694	4
2	Bosque denso	-75.0665253	-8.11777165	5
2	Bosque denso	-75.0222551	-8.13276683	6
2	Bosque denso	-75.2508919	-8.23801798	7
2	Bosque denso	-74.8506892	-8.07512215	8
2	Bosque denso	-74.9951025	-8.00076916	9
2	Bosque denso	-75.1760336	-8.02796673	10
2	Bosque denso	-75.1284393	-7.98347346	11
2	Bosque denso	-75.2578755	-8.19449922	12
2	Bosque denso	-75.339243	-8.20180523	13
3	Suelo expuesto	-74.9474409	-8.18047807	0
3	Suelo expuesto	-74.9381938	-8.17757537	1
3	Suelo expuesto	-74.8905143	-8.13780681	2

3	Suelo expuesto	-74.8813304	-8.13827412	3
3	Suelo expuesto	-74.9247588	-8.10846692	4
3	Suelo expuesto	-74.9182696	-8.14303024	5
3	Suelo expuesto	-74.8990209	-8.08929908	6
3	Suelo expuesto	-74.9307893	-8.11996131	7
3	Suelo expuesto	-74.9426929	-8.19165616	8
3	Suelo expuesto	-74.8632879	-8.31164182	9
3	Suelo expuesto	-74.8580093	-8.31958262	10
3	Suelo expuesto	-74.8537993	-8.32055782	11
3	Suelo expuesto	-74.8678803	-8.30284373	12
3	Suelo expuesto	-74.8655655	-8.30757691	13
3	Suelo expuesto	-74.8425978	-8.37296011	14
3	Suelo expuesto	-74.8494792	-8.35355559	15
3	Suelo expuesto	-74.8781403	-8.30303724	16
4	Palma	-74.942718	-8.16953058	0
4	Palma	-74.9148231	-8.1738635	1
4	Palma	-74.9236636	-8.16341343	2
4	Palma	-74.915853	-8.18028294	3
4	Palma	-74.9053817	-8.16702937	4
4	Palma	-74.931805	-8.14087262	5
4	Palma	-74.8863147	-8.13959848	6
4	Palma	-74.8943786	-8.13261446	7
4	Palma	-74.9222563	-8.12814181	8
4	Palma	-74.8942755	-8.1262725	9
4	Palma	-74.876189	-8.13709192	10
4	Palma	-74.9218016	-8.11270173	11
4	Palma	-74.8950225	-8.11686532	12
4	Palma	-74.9125451	-8.10629579	13
4	Palma	-74.8932331	-8.1007725	14
4	Palma	-74.8929757	-8.09074542	15
4	Palma	-74.9110001	-8.09397451	16
4	Palma	-74.9030178	-8.08105799	17
4	Palma	-74.9043053	-8.13184153	18

4	Palma	-74.9040478	-8.11952102	19
4	Palma	-74.9030178	-8.10354629	20
4	Palma	-74.9343678	-8.18257558	21
4	Palma	-74.9330694	-8.16651676	22
4	Palma	-74.9417383	-8.15266799	23
4	Palma	-74.9054053	-8.15161021	24
4	Palma	-74.9059202	-8.13920535	25
4	Palma	-74.8971073	-8.17761926	26
4	Palma	-74.8957805	-8.16143944	27
5	Pastizal	-74.948844	-8.22024618	0
5	Pastizal	-74.9716749	-8.22593771	1
5	Pastizal	-74.9918378	-8.19600051	2
5	Pastizal	-75.0052273	-8.18589085	3
5	Pastizal	-74.9978713	-8.17118938	4
5	Pastizal	-75.0181824	-8.17708757	5
5	Pastizal	-74.9654595	-8.23731144	6
5	Pastizal	-74.9614254	-8.24232317	7
5	Pastizal	-75.0141294	-8.27030611	8
5	Pastizal	-75.0157602	-8.25357295	9
5	Pastizal	-74.9495607	-8.26482412	10
5	Pastizal	-74.940786	-8.22883669	11
5	Pastizal	-75.1573221	-8.24484082	12
5	Pastizal	-75.1739684	-8.17450618	13
5	Pastizal	-75.2140998	-8.18436125	14
5	Pastizal	-75.1498511	-8.22645762	15
5	Pastizal	-75.0740056	-8.22957797	16
5	Pastizal	-74.9812994	-8.2945342	17
5	Pastizal	-74.8558186	-8.16110157	18
5	Pastizal	-74.7987686	-8.13055918	19
5	Pastizal	-74.8152504	-8.0710296	20
5	Pastizal	-74.9743479	-8.081737	21
5	Pastizal	-75.0067662	-8.09752545	22
5	Pastizal	-74.8507611	-8.36201431	23

5	Pastizal	-74.8614041	-8.35386207	24
5	Pastizal	-74.8571126	-8.33432999	25
5	Pastizal	-74.8342816	-8.3273608	26
5	Pastizal	-74.8418798	-8.35906242	27
5	Pastizal	-74.8625408	-8.35659976	28
5	Pastizal	-74.8679481	-8.36615899	29
5	Pastizal	-74.8737846	-8.36390868	30
5	Pastizal	-74.8526723	-8.37438629	31
5	Pastizal	-74.82412	-8.31262183	32
5	Pastizal	-74.8304184	-8.30252765	33
Total				107

CÓDIGO DE PUNTOS DE ENTRENAMIENTO EN JAVA SCRIPT

```

var table = ee.FeatureCollection("users/Clasificaciones_Araceli/Nueva_Requena_100m"),
    Agua =
    /* color: #49f1ff */
    /* shown: false */
    ee.FeatureCollection(
      [ee.Feature(
        ee.Geometry.Point([-74.82167692673877, -8.08424798670318]),
        {
          "Clase": 1,
          "system:index": "0"
        }
      ),
      ee.Feature(
        ee.Geometry.Point([-74.81927366746143, -8.089006711719216]),
        {
          "Clase": 1,
          "system:index": "1"
        }
      ),
      ee.Feature(
        ee.Geometry.Point([-74.79077787888721, -8.06793193206508]),
        {
          "Clase": 1,
          "system:index": "2"
        }
      ),
      ee.Feature(
        ee.Geometry.Point([-74.77473217040401, -8.117856732320146]),
        {
          "Clase": 1,
          "system:index": "3"
        }
      ),
      ee.Feature(
        ee.Geometry.Point([-74.80161150677654, -8.120198318607407]),
        {
          "Clase": 1,
          "system:index": "4"
        }
      ),
      ee.Feature(
        ee.Geometry.Point([-74.70539414825846, -8.01405852251552]),
        {
          "Clase": 1,
          "system:index": "5"
        }
      ),
      ee.Feature(
        ee.Geometry.Point([-74.69372117462565, -8.038195663633353]),
        {
          "Clase": 1,
          "system:index": "6"
        }
      )
    ]
  )

```

```

    }},
    ee.Feature(
      ee.Geometry.Point([-74.65870225372721, -8.057232396048805]),
      {
        "Clase": 1,
        "system:index": "7"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.82792632499948, -8.171924145165987]),
      {
        "Clase": 1,
        "system:index": "8"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.84440581718698, -8.16640176130498]),
      {
        "Clase": 1,
        "system:index": "9"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.86471044223211, -8.21480928978888]),
      {
        "Clase": 1,
        "system:index": "10"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.88035546294546, -8.272908833829373]),
      {
        "Clase": 1,
        "system:index": "11"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.91381838168518, -8.292753148037024]),
      {
        "Clase": 1,
        "system:index": "12"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.93207073993354, -8.343505285017324]),
      {
        "Clase": 1,
        "system:index": "13"
      }
    )
  ])),
  Bosque_denso =
  /* color: #579200 */
  /* shown: false */
  ee.FeatureCollection(
    [ee.Feature(
      ee.Geometry.Point([-75.05035150153708, -8.06861600072077]),
      {
        "Clase": 2,
        "system:index": "0"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.97704354959805, -8.097647858205152]),
      {
        "Clase": 2,
        "system:index": "1"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.94236795145352, -8.110563837061388]),
      {
        "Clase": 2,
        "system:index": "2"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-75.16552517175414, -8.084396589521392]),
      {
        "Clase": 2,
        "system:index": "3"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-75.18818447351195, -8.116346938553706]),
      {

```

```

        "Clase": 2,
        "system:index": "4"
    })),
    ee.Feature(
        ee.Geometry.Point([-75.06652527478737, -8.11777165381886]),
        {
            "Clase": 2,
            "system:index": "5"
        })),
    ee.Feature(
        ee.Geometry.Point([-75.02225511393016, -8.132766830452075]),
        {
            "Clase": 2,
            "system:index": "6"
        })),
    ee.Feature(
        ee.Geometry.Point([-75.25089190202654, -8.238017976037723]),
        {
            "Clase": 2,
            "system:index": "7"
        })),
    ee.Feature(
        ee.Geometry.Point([-74.85068915149114, -8.075122152630296]),
        {
            "Clase": 2,
            "system:index": "8"
        })),
    ee.Feature(
        ee.Geometry.Point([-74.99510253532287, -8.000769161915295]),
        {
            "Clase": 2,
            "system:index": "9"
        })),
    ee.Feature(
        ee.Geometry.Point([-75.17603362663147, -8.02796672707061]),
        {
            "Clase": 2,
            "system:index": "10"
        })),
    ee.Feature(
        ee.Geometry.Point([-75.12843929996795, -7.9834734641430565]),
        {
            "Clase": 2,
            "system:index": "11"
        })),
    ee.Feature(
        ee.Geometry.Point([-75.25787546789249, -8.19449922246016]),
        {
            "Clase": 2,
            "system:index": "12"
        })),
    ee.Feature(
        ee.Geometry.Point([-75.33924296056827, -8.20180522948291]),
        {
            "Clase": 2,
            "system:index": "13"
        }
    ])),
    Suelo_exp =
    /* color: #f2895a */
    /* shown: false */
    ee.FeatureCollection(
        [ee.Feature(
            ee.Geometry.Point([-74.94744085768748, -8.180478067542177]),
            {
                "Clase": 3,
                "system:index": "0"
            })),
            ee.Feature(
                ee.Geometry.Point([-74.93819382530879, -8.177575373302941]),
                {
                    "Clase": 3,
                    "system:index": "1"
                })),
            ee.Feature(

```

```
    ee.Geometry.Point([-74.89051430832794, -8.137806808326513]),
    {
      "Clase": 3,
      "system:index": "2"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.88133042466094, -8.138274123328893]),
    {
      "Clase": 3,
      "system:index": "3"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.9247587663981, -8.108466918203842]),
    {
      "Clase": 3,
      "system:index": "4"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.91826962318436, -8.143030242827614]),
    {
      "Clase": 3,
      "system:index": "5"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.89902085459798, -8.089299084433112]),
    {
      "Clase": 3,
      "system:index": "6"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.93078928020239, -8.119961307670705]),
    {
      "Clase": 3,
      "system:index": "7"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.9426928945541, -8.19165615838022]),
    {
      "Clase": 3,
      "system:index": "8"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.86328791835848, -8.31164182446564]),
    {
      "Clase": 3,
      "system:index": "9"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.85800933101717, -8.319582620551133]),
    {
      "Clase": 3,
      "system:index": "10"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.85379930882507, -8.3205578238742]),
    {
      "Clase": 3,
      "system:index": "11"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.86788034528551, -8.302843725621758]),
    {
      "Clase": 3,
      "system:index": "12"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.86556545073802, -8.307576908254347]),
    {
      "Clase": 3,
      "system:index": "13"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.84259781805989, -8.372960109576292]),
    {
```

```

        "Clase": 3,
        "system:index": "14"
    }},
    ee.Feature(
        ee.Geometry.Point([-74.84947916836177, -8.353555589553455]),
        {
            "Clase": 3,
            "system:index": "15"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.8781402901588, -8.303037237240314]),
        {
            "Clase": 3,
            "system:index": "16"
        }))]},
Palma =
/* color: #ffff6d */
/* shown: false */
ee.FeatureCollection(
    [ee.Feature(
        ee.Geometry.Point([-74.94271804338722, -8.169530576627045]),
        {
            "Clase": 4,
            "system:index": "0"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.91482306963233, -8.173863496450384]),
        {
            "Clase": 4,
            "system:index": "1"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.92366363054542, -8.163413433269342]),
        {
            "Clase": 4,
            "system:index": "2"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.91585303789405, -8.180282941080149]),
        {
            "Clase": 4,
            "system:index": "3"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.90538169389991, -8.167029369084805]),
        {
            "Clase": 4,
            "system:index": "4"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.9318050086808, -8.140872617512695]),
        {
            "Clase": 4,
            "system:index": "5"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.88631474378822, -8.139598479878913]),
        {
            "Clase": 4,
            "system:index": "6"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.89437859904467, -8.132614456846206]),
        {
            "Clase": 4,
            "system:index": "7"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.92225632444158, -8.128141807065083]),
        {
            "Clase": 4,
            "system:index": "8"
        }},
    ee.Feature(

```

```
    ee.Geometry.Point([-74.89427551999822, -8.126272496548523]),
    {
      "Clase": 4,
      "system:index": "9"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.87618902015184, -8.137091923764158]),
    {
      "Clase": 4,
      "system:index": "10"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.92180164442016, -8.112701730944641]),
    {
      "Clase": 4,
      "system:index": "11"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.89502246961547, -8.116865324099946]),
    {
      "Clase": 4,
      "system:index": "12"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.91254505206678, -8.106295791232197]),
    {
      "Clase": 4,
      "system:index": "13"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.89323314715955, -8.10077250294301]),
    {
      "Clase": 4,
      "system:index": "14"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.89297565509412, -8.090745416719658]),
    {
      "Clase": 4,
      "system:index": "15"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.9110000996742, -8.093974505631524]),
    {
      "Clase": 4,
      "system:index": "16"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.90301784564588, -8.081057994800522]),
    {
      "Clase": 4,
      "system:index": "17"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.90430530597303, -8.131841526417656]),
    {
      "Clase": 4,
      "system:index": "18"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.9040478139076, -8.119521023912498]),
    {
      "Clase": 4,
      "system:index": "19"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.90301784564588, -8.103546292483445]),
    {
      "Clase": 4,
      "system:index": "20"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.93436775470603, -8.182575581922457]),
    {
```

```

        "Clase": 4,
        "system:index": "21"
    }},
    ee.Feature(
        ee.Geometry.Point([-74.93306935756554, -8.166516758629697]),
        {
            "Clase": 4,
            "system:index": "22"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.94173825710168, -8.152667987255064]),
        {
            "Clase": 4,
            "system:index": "23"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.90540526456866, -8.151610212054992]),
        {
            "Clase": 4,
            "system:index": "24"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.90592024869952, -8.139205351124994]),
        {
            "Clase": 4,
            "system:index": "25"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.8971072886522, -8.177619264069191]),
        {
            "Clase": 4,
            "system:index": "26"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.89578046925489, -8.161439441623418]),
        {
            "Clase": 4,
            "system:index": "27"
        }
    ]]),
Pastizal =
/* color: #87b67a */
/* shown: false */
ee.FeatureCollection(
    [ee.Feature(
        ee.Geometry.Point([-74.94884395327355, -8.220246179008543]),
        {
            "Clase": 5,
            "system:index": "0"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.97167491640832, -8.225937710721787]),
        {
            "Clase": 5,
            "system:index": "1"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.99183775405021, -8.19600050676126]),
        {
            "Clase": 5,
            "system:index": "2"
        }},
    ee.Feature(
        ee.Geometry.Point([-75.00522734145255, -8.185890848822751]),
        {
            "Clase": 5,
            "system:index": "3"
        }},
    ee.Feature(
        ee.Geometry.Point([-74.99787127874255, -8.171189382098246]),
        {
            "Clase": 5,
            "system:index": "4"
        }},
    ee.Feature(

```

```
    ee.Geometry.Point([-75.01818237911766, -8.177087566420628]),
    {
      "Clase": 5,
      "system:index": "5"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.96545946982408, -8.237311437958002]),
    {
      "Clase": 5,
      "system:index": "6"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.96142542746568, -8.242323172151309]),
    {
      "Clase": 5,
      "system:index": "7"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-75.01412942774051, -8.270306106347542]),
    {
      "Clase": 5,
      "system:index": "8"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-75.01576021082157, -8.253572947771108]),
    {
      "Clase": 5,
      "system:index": "9"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.9495606783675, -8.264824122431468]),
    {
      "Clase": 5,
      "system:index": "10"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.940786001528, -8.22883668819486]),
    {
      "Clase": 5,
      "system:index": "11"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-75.1573221216506, -8.244840819511438]),
    {
      "Clase": 5,
      "system:index": "12"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-75.17396835506224, -8.174506177027594]),
    {
      "Clase": 5,
      "system:index": "13"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-75.21409976481605, -8.184361254450563]),
    {
      "Clase": 5,
      "system:index": "14"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-75.14985106291361, -8.226457624776083]),
    {
      "Clase": 5,
      "system:index": "15"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-75.07400557551097, -8.229577972090908]),
    {
      "Clase": 5,
      "system:index": "16"
    }
  )),
  ee.Feature(
    ee.Geometry.Point([-74.98129936600611, -8.294534202886675]),
    {
```

```
        "Clase": 5,
        "system:index": "17"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.85581855825534, -8.161101570529034]),
    {
      "Clase": 5,
      "system:index": "18"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.79876860230563, -8.1305591823248]),
    {
      "Clase": 5,
      "system:index": "19"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.81525043874416, -8.071029599981978]),
    {
      "Clase": 5,
      "system:index": "20"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.97434792483898, -8.081737003080868]),
    {
      "Clase": 5,
      "system:index": "21"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-75.00676617220279, -8.097525452610808]),
    {
      "Clase": 5,
      "system:index": "22"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.85076112038934, -8.362014308694956]),
    {
      "Clase": 5,
      "system:index": "23"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.86140412576043, -8.35386207441033]),
    {
      "Clase": 5,
      "system:index": "24"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.8571125913366, -8.334329987176309]),
    {
      "Clase": 5,
      "system:index": "25"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.83428162820184, -8.327360801608158]),
    {
      "Clase": 5,
      "system:index": "26"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.8418798444997, -8.359062419628156]),
    {
      "Clase": 5,
      "system:index": "27"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.86254080259124, -8.356599764843075]),
    {
      "Clase": 5,
      "system:index": "28"
    }
  ),
  ee.Feature(
    ee.Geometry.Point([-74.86794813596526, -8.3661589934124]),
    {
      "Clase": 5,
      "system:index": "29"
    }
  )
}
```

```
    }},
    ee.Feature(
      ee.Geometry.Point([-74.87378462278167, -8.363908678033074]),
      {
        "Clase": 5,
        "system:index": "30"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.85267228378243, -8.374386294940434]),
      {
        "Clase": 5,
        "system:index": "31"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.82411996902168, -8.312621834529025]),
      {
        "Clase": 5,
        "system:index": "32"
      }
    ),
    ee.Feature(
      ee.Geometry.Point([-74.83041842736583, -8.30252765077268]),
      {
        "Clase": 5,
        "system:index": "33"
      }
    )
  ]]);
```