

UNIVERSIDAD NACIONAL COSTA RICA
CAMPUS OMAR DENGO
FACULTAD DE CIENCIAS DE LA TIERRA Y EL MAR
ESCUELA DE CIENCIAS GEOGRÁFICAS

LICENCIATURA EN CIENCIAS GEOGRÁFICAS CON ÉNFASIS EN
ORDENAMIENTO DEL TERRITORIO

**ANÁLISIS GEOESPACIAL DE LOS USOS DE LA TIERRA Y ESTADOS DE LOS
CULTIVOS MEDIANTE GOOGLE EARTH ENGINE PARA EL
ORDENAMIENTO TERRITORIAL Y LA SOSTENIBILIDAD AGRÍCOLA EN LA
ZONA NORTE DE CARTAGO**

Trabajo final de graduación, en modalidad Tesis, sometido a consideración del Tribunal Examinador de la Escuela de Ciencias Geográficas de la Universidad Nacional para optar al grado de Licenciatura en Ciencias Geográficas con énfasis en Ordenamiento del Territorio

Sustentantes:

Elizabeth Meneses Climent
Godofredo de Jesús Rojas Mata

Heredia, Costa Rica.

Julio, 2025.

MIEMBROS DEL TRIBUNAL EXAMINADOR

Trabajo de graduación aprobado por el Tribunal Examinador de la Escuela de Ciencias Geográficas de la Universidad Nacional, para optar al grado de Licenciatura en Ciencias Geográficas con énfasis en Ordenamiento del Territorio

M.Sc. Betsy Cedeño Montoya

Representante del Decanato Decano de la Facultad de Ciencias de la Tierra y el Mar

M.Sc. Luis Sandoval Murillo,

Representante de la Dirección de la Escuela de Ciencias Geográficas

M.Sc. Marvin Alfaro Sánchez

Tutor

M.Sc. Melvin Lizano Araya

Asesor

Lic. Christian Vargas Bolaños

Asesor

RESUMEN

El acelerado desarrollo de los sectores urbanos en la parte norte de la provincia de Cartago, Costa Rica, está afectando considerablemente las tierras agrarias productivas. La ausencia de una planificación adecuada en el crecimiento urbano ha resultado en la transformación de terrenos fértiles en espacios destinados a residencias y negocios, lo que ha reducido la superficie destinada a la producción alimentaria. Esta situación representa un riesgo no solo para la seguridad alimentaria de la zona, sino también para la sustentabilidad del sector agrícola. Adicionalmente, la escasez de información actualizada respecto a la condición de los cultivos y el manejo del suelo limita la habilidad de los administradores territoriales para hacer elecciones fundamentadas.

El empleo de tecnologías geoespaciales avanzadas, como Google Earth Engine (GEE), ayudará a monitorizar la cobertura del suelo y la salud de los cultivos. Considerando que la agricultura es un aspecto fundamental de la economía de Costa Rica, particularmente, la provincia de Cartago se destaca como una de las principales regiones agrícolas donde es vital preservar los suelos para prevenir su conversión en zonas urbanas. La investigación pone de manifiesto que el uso de herramientas como el NDVI, así como la clasificación supervisada y no supervisada de imágenes satelitales, junto con el análisis a lo largo del tiempo y en múltiples escalas permite identificar con precisión las áreas de conflicto y sugerir enfoques más sostenibles para la gestión del territorio.

La metodología empleada combina el análisis de imágenes satelitales de Sentinel-2 mediante GEE y se complementa con verificaciones en el campo usando un receptor GPS con una precisión de 1,5 metros en tiempo real utilizando su antena integrada. Se crearon algoritmos en JavaScript para evaluar el NDVI y llevar a cabo clasificaciones vinculadas a la cobertura del suelo, lo que permite obtener un análisis exhaustivo y actualizado sobre la cobertura del terreno y las dinámicas agrícolas. La adopción de un método que considera diversas temporalidades y escalas permitió identificar alteraciones prolongadas y fluctuaciones a nivel local. Del mismo modo, se llevó a cabo una recolección de datos de forma ordenada en el terreno para corroborar los resultados con el fin de garantizar la exactitud de los mapas creados y mejorar la utilidad de la información geoespacial.

El fin de la investigación fue generar insumos técnicos y científicos que apoyen la planificación territorial orientada a la sostenibilidad agrícola. Los resultados evidencian una pérdida progresiva de cobertura agrícola debido a la expansión urbana no planificada, especialmente, en distritos como Tierra Blanca, Pacayas y Cot donde se detectó una marcada fragmentación del paisaje productivo. Las clasificaciones supervisadas y no supervisadas confirmaron patrones de sustitución de la cobertura del suelo y el análisis espacial identificó núcleos urbanos como focos de presión sobre tierras agrícolas clave. Así mismo, el uso de tecnologías geoespaciales, como GEE y el NDVI, proporciona información estratégica tanto para la toma de decisiones como para el fortalecimiento de la gestión territorial sostenible en la región.

DEDICATORIA

A mi familia, que siempre estuvo apoyándome y animándome.

A los amores de mi vida: mi esposo, Michael, por tu apoyo incondicional y,

 Mi preciosa hija, Emma, esto es por ti.

 Y a Dios gracias infinitas.

EMC.

A Dios.

A mi familia, por su apoyo incondicional.

A mi esposa, Danalys, por ser el motor de mi vida.

Y a Bati y Robin, por ser esa luz que necesitábamos.

GRM.

AGRADECIMIENTOS

A mis papás, Jorge y Ana, un gran agradecimiento porque gracias al regalo de la educación que me brindaron en mi etapa Universitaria he llegado a este gran logro y a la culminación de diversas etapas. A mi esposo, Michael, que siempre estuvo apoyándome y ayudándome en mis horas de lectura nocturna para no dormirme, en fin, por siempre estar ahí... gracias. A mi hija hermosa, Emma, gracias por existir y ayudar a mamita en los días que estaba trabajando en la tesis: te amo, mi chiquita preciosa. A mis hermanas, que se alegraron de que volviera a retomar mi tesis, gracias por las buenas vibras siempre. Al comité asesor gracias por siempre estar ayudándonos y brindándonos su valioso conocimiento. A mi mejor amigo y compañero de tesis, Godofredo, siempre te voy a agradecer el apoyo, la ayuda, la comprensión y las explicaciones exhaustivas; qué más puedo decir que gracias infinitas porque logramos nuestro objetivo de años: hacer nuestro trabajo de tesis juntos. A todas las personas que nos brindaron su ayuda en este camino ¡muchas gracias! Y gracias a Dios por todo lo que logramos.

Elizabeth Meneses Climent

A mi esposa, Danalys Núñez Gámez, por su comprensión, apoyo y por motivarme a esforzarme al máximo. A mi madre, Sara Mata Solano, y a mi padre, Godofredo Rojas Quirós, quienes me inspiraron a fijar nuevos objetivos y a enfrentar desafíos. A mi hermana, Paula, por ser una mentora y guía constante en todas las fases de mi vida. A mi tío y padrino, Alejandro, por sus consejos y estar siempre en mi vida. A mi colega, compañera de tesis y mejor amiga, ¡gracias, lo hemos conseguido! Al Comité Asesor por su tiempo, apoyo y orientación, les agradezco mucho. A todas las personas que nos dieron el apoyo y sus aportes. A Dios, quien me proporcionó fortaleza y resiliencia.

Godofredo Rojas Mata

TABLA DE CONTENIDOS

MIEMBROS DEL TRIBUNAL EXAMINADOR	ii
RESUMEN	iii
DEDICATORIA.....	iv
AGRADECIMIENTOS.....	v
ÍNDICE DE FIGURAS	ix
ÍNDICE DE TABLAS.....	x
ÍNDICE DE MAPAS	x
ACRÓNIMOS	xi
1. INTRODUCCIÓN	1
1.1. Planteamiento del Problema	1
1.2. Justificación	3
1.3. Objetivos.....	6
1.3.1. Objetivo general	6
1.3.2. Objetivos específicos.....	6
2. ÁREA DE ESTUDIO.....	7
3. MARCO TEÓRICO.....	10
3.1. Expansión Urbana y sus Efectos en el Uso de la Tierra	10
3.2. Ordenamiento Territorial.....	11
3.3. Sostenibilidad de las Tierras Agrícolas.....	11
3.4. Sistemas de Información Geográfica (SIG), Teledetección y Tecnologías Avanzadas.....	12
Enfoque Multitemporal	14
Enfoque Multiescalar	14
3.5. Google Earth Engine.....	15
Índice de Vegetación de Diferencia Normalizada (NDVI).....	16
Clasificación Supervisada y No Supervisada.....	17
Imágenes Sentinel-2	18
4. METODOLOGÍA	20
4.1. Tipo de investigación.....	21
4.2. Enfoque Multiescalar y Multitemporal.....	21

4.3.	Definición de Variables Clave y Parámetros Iniciales	24
4.4.	Recolección de datos de campo	26
4.5.	Implementación de GEE	32
4.6.	Estructura del código para GEE.....	33
4.6.1.	Selección de Datos y Área de Estudio:.....	33
4.6.2.	Preprocesamiento de Imágenes:	35
4.6.3.	Análisis de Imágenes:.....	35
4.6.4.	Visualización e Interpretación de Resultados:	40
4.6.5.	Exportación de Resultados:	40
4.7.	Análisis Espacial de los Patrones y Tendencias de los datos obtenidos	41
4.7.1.	Cartografía y Análisis Espacial Integrado:.....	41
4.7.2.	Evaluación y Diagnóstico de la Fragmentación:	44
4.7.3.	Propuestas de Ordenamiento y Gestión Territorial	45
5.	RESULTADOS Y DISCUSIÓN.....	46
5.1.	Datos obtenidos utilizando GEE.....	46
Datos de referencia, puntos de muestreo en campo	46	
Código para el Cálculo del NDVI.....	48	
Código para la Clasificación Supervisada.....	49	
Código para la Clasificación No Supervisada.....	51	
5.2.	Cartografía y Análisis Espacial Integrado a partir de los datos de GEE	52
Análisis del mapa de NDVI	52	
Mapeo según clasificación supervisada y no supervisada	60	
Generación de patrones espaciales.....	71	
5.3.	Evaluación y Diagnóstico de la Fragmentación.....	77
Evaluación de la Fragmentación del Paisaje.....	77	
Diagnóstico de los centros poblados principales.....	80	
5.4.	Propuestas de Ordenamiento y Gestión Territorial.....	84
Interpretación Geográfica Contextualizada.....	84	
6.	CONCLUSIONES	90
7.	RECOMENDACIONES	92
8.	REFERENCIAS	94

9. ANEXOS.....	108
Anexo 1. Bandas de los satélites Sentinel-2	108
Anexo 2. Muestra de los puntos para la verificación de campo	109
Anexo 3. Datos en campo con Trimble TDC 600	110
Anexo 4. Registro fotográfico de las categorías de entrenamiento	111
Anexo 5. Pasos preliminares para utilizar GEE.....	114
Anexo 6. NDVI para la zona de estudio	122
Anexo 7. Clasificación supervisada para la zona de estudio	125
Anexo 8. Clasificación No Supervisada para la zona de estudio.....	128

ÍNDICE DE FIGURAS

Figura 1. Clasificación de la teledetección.....	13
Figura 2. Espectro electromagnético visible	13
Figura 3. Catálogo de datos públicos de GEE.....	15
Figura 4. Porcentajes de irradiación de cada banda espectral	17
Figura 5. Satélite Sentinel-2 y la representación de sus 13 bandas	18
Figura 6. Selección de trabajo por medio de latitud, longitud y elevación central	29
Figura 7. Constelaciones disponibles según el equipo a utilizar	30
Figura 8. Orbitas de los satélites de la constelación GPS.....	30
Figura 9. Condiciones atmosféricas y la mejor hora para la toma de datos	31
Figura 10. Creación del repositorio de trabajo	33
Figura 11. Carga de archivo a la plataforma GEE.....	34
Figura 12. Diagrama de flujo para determinar el NDVI	36
Figura 13. Diagrama de flujo para la clasificación supervisada.....	37
Figura 14. Diagrama de flujo Índice de Moran Global	42
Figura 15. Diagrama de flujo Índice de Moran Local	43
Figura 16. Diagrama de flujo Índice de Getis-Ord G_i^*	43
Figura 17. Porcentaje de las muestras según el área de estudio	47
Figura 18. Aplicación del NDVI de la zona de estudio en GEE	48
Figura 19. Clasificación supervisada para la zona de estudio	50
Figura 20. Clasificación No Supervisada para la zona de estudio	51
Figura 21. Parámetros NDVI con respecto al estado de los cultivos	52
Figura 22. Área sin cobertura NDVI de los distritos al sur de la zona de estudio.	55
Figura 23. Porcentaje de las categorías según el área de estudio	62
Figura 24. Porcentaje y áreas de los patrones del método <i>K-means</i>	66
Figura 25. Índice de Moran (Global).....	73

ÍNDICE DE TABLAS

Tabla 1. Distritos del área de investigación.....	8
Tabla 2. Variables de análisis geoespacial y su vinculación con los objetivos específicos	25
Tabla 3. Valores utilizados para el cálculo del NDVI utilizando imágenes Sentinel-2	35
Tabla 4. Diferencia entre Supervisada y No Supervisada	40
Tabla 5. Cantidades de muestra según categorías	46
Tabla 6. Kilómetros cuadrados por categoría de cobertura.....	62
Tabla 7. Datos obtenidos del Índice de Moran Global	74
Tabla 8. Área por clase de uso del suelo por distrito.....	77
Tabla 9. Estadísticas de NDVI por zona.....	78

ÍNDICE DE MAPAS

Mapa 1. Delimitación del área de investigación.....	9
Mapa 2. NDVI de la zona de estudio.....	53
Mapa 3. NDVI, detalles de la zona de estudio	56
Mapa 4. Delimitación del área de investigación.....	60
Mapa 5. Clasificación Supervisada detalles de la zona de estudio.....	63
Mapa 6. Clasificación Supervisada detalles de la zona de estudio.....	65
Mapa 7. Clasificación Supervisada vs Clasificación No Supervisada	69
Mapa 8. Índice de Moran Local (Local Moran's I o LISA) de la zona de estudio	74
Mapa 9. Índice Getis-Ord G_i^* (<i>Hotspot Analysis</i>) de la zona de estudio.....	75
Mapa 10. Áreas de Conflicto Agro-Urbano	80

ACRÓNIMOS

API	Interfaz de Programación de Aplicaciones (<i>Application Programming Interface</i>)
CGR	Contraloría General de la República
CRTM	Costa Rica Transversal de Mercator
DEM	Modelo Digital de Elevación (MDE) (<i>Digital elevation model</i>)
EVI	Índice de vegetación mejorado (<i>Enhanced Vegetation Index</i>)
FAO	<i>Food and Agriculture Organization</i>
FONAFIFO	Fondo Nacional de Financiamiento Forestal
GAM	Gran Área Metropolitana
GEE	<i>Google Earth Engine</i>
GeoJSON	Notación de objetos geográficos basados en JavaScript (<i>Geographic JavaScript Object Notation</i>)
GPS	Sistema de Posicionamiento Global (<i>Global Positioning System</i>)
IGN	Instituto Geográfico Nacional de Costa Rica
IMN	Instituto Meteorológico Nacional de Costa Rica
INDER	Instituto de Desarrollo Rural
INEC	Instituto Nacional de Estadística y Censo
INVU	Instituto Nacional de Vivienda y Urbanismo
JS	<i>JavaScript</i>
KML	<i>Keyhole Markup Language</i>
ML	Aprendizaje automático (<i>Machine learning</i>)
MAG	Ministerios de Agricultura y Ganadería
MINAE	Ministerio de Ambiente y Energía
MIVAH	Ministerio de Vivienda y Asentamientos Humanos
NDVI	Índice de vegetación de diferencia normalizada (<i>Normalized Difference Vegetation Index</i>)
NDWI	Índice de agua de diferencia normalizada (<i>Normalized Difference Water Index</i>)
NIR	Análisis de infrarrojo cercano (<i>Near InfraRed spectroscopy</i>)

OGC	<i>Open Geospatial Consortium</i>
ONG	Organizaciones No Gubernamentales
QGIS	<i>Quantum Geographic Information System</i>
RED	Espectro rojo o rojo visible
RNP	Registro Nacional de la Propiedad
ROI	Región de Interés (<i>Region Of Interest</i>)
SAVI	Índice de vegetación ajustado al suelo (<i>Soil-Adjusted Vegetation Index</i>)
SHP	<i>Shapefile</i>
SIG	Sistema de Información Geográfica
SNIT	Sistema Nacional de Información Territorial
SVM	Máquina de Vectores de Soporte (<i>Support Vector Machine</i>)
TIFF	<i>Tagged Image File Format</i>
UMC	Unidad Mínima de Cartografía
WFS	Servicios de entidades en la web (<i>Web Feature Service</i>)
WGS	Servicio de Mapas Web (<i>Web Map Service</i>).
ZIP	Formato de compresión sin pérdida

1. INTRODUCCIÓN

1.1. Planteamiento del Problema

A nivel global, los procesos de urbanización acelerada han tenido un impacto significativo sobre el uso del suelo, esto ha provocado la reducción de áreas agrícolas y el deterioro de los ecosistemas. Según la FAO (2021), más de un tercio de las tierras cultivables en el mundo ya se encuentran degradadas debido a prácticas insostenibles y al avance urbano no planificado, lo que representa una amenaza directa para la seguridad alimentaria mundial. En América Latina, esta dinámica es especialmente crítica en regiones con alta densidad poblacional donde la presión por suelo urbano ha desplazado la actividad agrícola hacia zonas marginales, lo cual afecta la sostenibilidad del sector (Baldini et al., 2019, Buzai 2018, Dreby y Rodríguez-Pacas, 2020).

En Costa Rica, el Valle Central ha sido testigo de un crecimiento urbano acelerado con transformaciones significativas en la cobertura del suelo. La mayor concentración demográfica y económica del país se localiza en esta región, lo que ha llevado a una conversión creciente de suelos agrícolas en áreas urbanas (INEC, 2018). Aunque existen instrumentos de planificación territorial, como los planes reguladores y el Plan Nacional de Desarrollo Urbano, su alcance ha sido limitado fuera del núcleo de la Gran Área Metropolitana (GAM) y esto deja a regiones como la zona norte de Cartago expuestas a procesos de expansión urbana desordenada (Barboza-Navarro et al., 2021).

La zona norte de la provincia de Cartago enfrenta una creciente presión urbana que está desplazando las actividades agrícolas hacia terrenos marginales y menos productivos. Este fenómeno compromete la sostenibilidad agrícola y la viabilidad del uso de la tierra en la región. La expansión urbana, en ausencia de una planificación territorial eficaz, ha conducido a la conversión de áreas fértiles en zonas residenciales y comerciales. Como resultado, la disponibilidad de terrenos para la producción agrícola se ha reducido significativamente, lo cual afecta tanto la productividad como la seguridad alimentaria. Además, esta transformación de la cobertura del suelo ha generado procesos de degradación, disminución de la calidad de este y reducción de los recursos hídricos esenciales, lo que compromete la capacidad de mantener una producción agrícola sostenible a largo plazo.

El problema central radica en la falta de un ordenamiento territorial que regule el crecimiento urbano y garantice la preservación de las tierras agrícolas en la región. La planificación territorial vigente en la zona norte de Cartago no ha logrado equilibrar la expansión urbana con la conservación de los espacios productivos, lo cual ha intensificado la presión sobre las áreas fértiles y ha generado un deterioro progresivo del entorno rural. A ello se suma la limitada disponibilidad de datos actualizados sobre la calidad del suelo, el estado de los cultivos y los patrones de ocupación del territorio. Esta falta de información restringe la capacidad de los gestores territoriales y los productores agrícolas para tomar decisiones fundamentadas que permitan un desarrollo equilibrado y sostenible.

Ante esta problemática, es necesario fortalecer las estrategias de gestión territorial mediante el uso de información geoespacial y herramientas de análisis espacial. La integración de datos actualizados sobre la cobertura del suelo y los recursos agrícolas permitiría optimizar la planificación territorial, mejorar la productividad agrícola y minimizar los impactos negativos de la expansión urbana. Un enfoque basado en la gestión sostenible del territorio contribuiría a mitigar los efectos del crecimiento urbano no planificado y a promover un desarrollo equilibrado que beneficie tanto a la agricultura como a la población urbana en la zona norte de Cartago.

En este contexto, resulta fundamental analizar cómo han evolucionado el uso del suelo y la condición de las tierras agrícolas en dicha región, y de qué manera el uso de herramientas avanzadas como GEE puede proporcionar insumos técnicos y científicos que apoyen la formulación de estrategias de ordenamiento territorial sostenibles y basadas en evidencia.

1.2. Justificación

En Costa Rica, la producción agrícola es un pilar fundamental de la economía, dado que contribuye significativamente a la seguridad alimentaria y al bienestar socioeconómico, especialmente, en el Valle Central, donde se genera cerca del 80 % de la producción de hortalizas a nivel nacional (Gaitán-Álvarez, 2013). Sin embargo, el crecimiento urbano, comercial e industrial ha comenzado a desplazar las áreas agrícolas tradicionales hacia terrenos marginales o con condiciones subóptimas, lo que compromete la sostenibilidad del sector (Vargas y Nienhuis, 2012). En la zona norte de Cartago, esta presión sobre las tierras agrícolas evidencia la necesidad urgente de estrategias de ordenamiento territorial que integren criterios de sostenibilidad y protección del recurso agrícola. Optimizar el uso de las tierras fértiles remanentes no solo es crucial para satisfacer la demanda del mercado nacional, sino también para preservar estas áreas ante la expansión urbana (Barboza-Navarro et al., 2021).

La zona norte de Cartago, conocida por ser una de las principales áreas productoras de hortalizas, verduras y legumbres, ha experimentado una rápida conversión de tierras agrícolas en desarrollos residenciales y comerciales. Esto genera un conflicto crítico entre el crecimiento urbano y la conservación agrícola, ya que las tierras de alta productividad están siendo reemplazadas para usos urbanos, esto afecta la resiliencia del sector agrícola local y la disponibilidad de recursos naturales como los suelos fértiles y los recursos hídricos. Dicho fenómeno subraya la necesidad de implementar planes de ordenamiento territorial eficaces que equilibren el desarrollo urbano con la conservación de los recursos agrícolas, como ya se ha logrado en la GAM mediante el anillo de contención para proteger los mantos acuíferos.

El ordenamiento territorial en la zona norte de Cartago es fundamental para abordar el conflicto entre la expansión urbana y la conservación de tierras agrícolas productivas. La rápida transformación de áreas fértiles en zonas residenciales y comerciales requiere un enfoque de planificación que gestione adecuadamente la cobertura del suelo. La implementación de este tipo de ordenamiento territorial puede proteger los recursos agrícolas y apoyar la sostenibilidad del sector mediante regulaciones que preserven tierras productivas y orienten el crecimiento urbano hacia áreas menos impactantes. El análisis geoespacial, al

ofrecer datos exactos y actualizados, se convierte en una herramienta esencial para identificar patrones y zonas conflictivas que facilite una planificación territorial informada y efectiva.

Para enfrentar estos desafíos, el uso de herramientas avanzadas de análisis geoespacial, como el Índice de Vegetación de Diferencia Normalizada (NDVI), resulta esencial. Esta herramienta permite monitorear con precisión el estado de la vegetación y la salud de los cultivos a partir de imágenes satelitales. En los cantones de Cartago, Paraíso, Oreamuno y Alvarado el análisis temporal del NDVI puede proporcionar indicadores clave sobre la dinámica de los cultivos y su rendimiento, lo cual permitirá a los agricultores implementar prácticas sostenibles, reducir costos operativos y contribuir a la sostenibilidad agrícola de la región (NDVI: Fórmula y Uso del Índice de Vegetación en Agricultura, 2021). Aunque existen múltiples índices espectrales disponibles en teledetección, como el *Enhanced Vegetation Index* (EVI), *Soil-Adjusted Vegetation Index* (SAVI) o el *Normalized Difference Water Index* (NDWI), el uso del NDVI se justifica por su eficiencia, simplicidad y amplia validación científica a lo largo del tiempo. El NDVI ha demostrado ser especialmente eficaz en contextos agrícolas debido a su sensibilidad a la densidad y vigor de la vegetación, así como a su capacidad para discriminar zonas con distinto nivel de cobertura vegetal mediante una fórmula sencilla basada en las bandas del infrarrojo cercano (NIR) y rojo (RED) (Pettorelli et al., 2005).

Asimismo, la clasificación supervisada y no supervisada de imágenes satelitales facilita la identificación de los distintos usos del suelo, lo que proporciona una visión detallada y actualizada del territorio. Este enfoque permite tomar decisiones informadas para la gestión y planificación del suelo. Por ejemplo, la clasificación supervisada identifica con alta precisión áreas específicas de uso agrícola o urbano, mientras que la clasificación no supervisada detecta patrones en áreas sin datos de referencia previos (Pal & Foody, 2010; Pandeypranjali, 2020). Dicha información es crucial para el ordenamiento territorial, ya que permiten identificar zonas de conflicto y planificar el uso de la tierra de manera que respete y conserve las áreas agrícolas productivas.

El análisis geoespacial aporta valor a la planificación territorial mediante la provisión de datos, actualizados y específicos a nivel geográfico, lo cual es clave para la toma de decisiones informadas en la gestión del territorio. Evaluando indicadores clave como la salud

de los cultivos y la expansión urbana, es posible realizar un diagnóstico detallado que respalde estrategias de ordenamiento territorial orientadas a la sostenibilidad. Esta visión integral permite anticipar posibles conflictos en el uso de la tierra y así ayudar a diseñar políticas y planes que optimicen la cobertura del suelo y favorezcan un desarrollo territorial equilibrado.

En este sentido, la plataforma GEE ofrece una solución innovadora para procesar grandes volúmenes de datos satelitales en la nube (Tejjido-Murias et al., 2023 y Google Cloud Tech, 2021). GEE permite acceder a imágenes de alta resolución de satélites como Sentinel-2 y Landsat, acelerando el análisis geoespacial a una escala sin precedentes y sin los costos de infraestructura computacional. Su capacidad para ejecutar algoritmos avanzados de aprendizaje automático (*machine learning*) y de inteligencia artificial es particularmente útil para analizar grandes extensiones territoriales y evaluar el estado de los cultivos y el uso de la tierra en Cartago (Solórzano y Perilla, 2022). Combinando GEE con técnicas de clasificación supervisada y no supervisada es posible obtener un análisis preciso de las dinámicas territoriales para facilitar la identificación de patrones y tendencias en la cobertura del suelo para guiar estrategias de ordenamiento más sostenibles.

La implementación de tecnologías avanzadas como GEE en el ordenamiento territorial de la zona norte de Cartago contribuye directamente a los objetivos de sostenibilidad y planificación agrícola, al proporcionar datos actualizados y análisis detallados esenciales para la toma de decisiones. Este estudio no solo beneficiará a los agricultores, permitiéndoles mejorar sus prácticas y maximizar sus rendimientos, sino también generará insumos valiosos para los planificadores urbanos y gestores territoriales. Al ofrecer información precisa sobre la interacción entre el uso agrícola y la expansión urbana, este análisis apoyará la formulación de políticas que promuevan un desarrollo territorial equilibrado y la conservación de tierras agrícolas estratégicas que beneficia tanto a la comunidad agrícola como a las poblaciones urbanas que dependen de un suministro constante y sostenible de productos agrícolas.

1.3. Objetivos

1.3.1. Objetivo general

Analizar los cambios en el uso de la tierra y la salud de las tierras agrícolas en la zona norte de Cartago, mediante la generación de insumos a través de Google Earth Engine, con el fin de contribuir al ordenamiento territorial y la gestión sostenible de las zonas agrícolas.

1.3.2. Objetivos específicos

1. Identificar zonas de conflicto entre la expansión urbana y las áreas agrícolas productivas dando propuestas estrategias de optimización en la planificación y ordenamiento territorial.
2. Determinar los factores ambientales y socioeconómicos que inciden en la degradación de las tierras agrícolas con el fin de proporcionar recomendaciones para una gestión sostenible del territorio.
3. Formular propuestas de planificación y gestión territorial que equilibren la expansión urbana con la conservación agrícola, basadas en los resultados del análisis geoespacial.

2. **ÁREA DE ESTUDIO**

La provincia de Cartago, ubicada en el corazón geográfico de Costa Rica, se destaca como un punto neurálgico de la historia, la economía y la cultura del país. Limita con la provincia de San José, al oeste, y con la provincia de Limón, al este, lo que la convierte en un puente natural entre distintas regiones del país. Cartago abarca una extensión territorial de 3,126.67 kilómetros cuadrados, distribuidos en una gran diversidad de paisajes y ecosistemas, que van desde valles montañosos hasta áreas de llanura. Esta variedad geográfica no solo contribuye a su riqueza natural, sino que también está estrechamente vinculada a su desarrollo histórico, social y económico.

Desde el punto de vista histórico, Cartago ocupa un lugar preeminente en la historia de Costa Rica. Fue la primera capital del país, un honor que ostentó hasta 1823, cuando San José asumió la sede gubernamental (Gobierno de Costa Rica, 2017). Este período inicial marcó el comienzo de una profunda influencia política, económica y cultural que dejó una huella imborrable en la identidad nacional. La capitalidad de Cartago fue fundamental no solo para consolidar su importancia en la administración pública, sino también para impulsar el desarrollo de infraestructuras y el establecimiento de instituciones claves para el crecimiento del país. Según Solórzano y Vargas (2006), este legado de capitalidad sentó las bases para el posterior desarrollo de la provincia en varios ámbitos, lo que la posiciona como una región de alto valor estratégico.

La llegada de los colonizadores españoles a la región en 1563 fue otro acontecimiento determinante en la historia de Cartago, ya que inició un proceso de colonización y transformación de la economía local. La introducción de cultivos agrícolas, como el maíz, el cacao y más tarde el café, caña de azúcar y tabaco fue crucial para la consolidación económica de la región. Estos cultivos no solo fueron fundamentales para la subsistencia de la población, sino que también marcaron el comienzo de una fuerte actividad comercial que posicionó a Cartago como un actor clave en la economía agrícola de Costa Rica (Solórzano y Vargas, 2006). A lo largo de los siglos, la provincia ha mantenido su rol central en la producción agrícola del país y ha sido reconocida principalmente por su producción cafetera que sigue siendo uno de los principales motores de su economía.

La cabecera provincial, la ciudad de Cartago, se encuentra ubicada aproximadamente a 25 kilómetros al este de la actual capital, San José. Esta ciudad histórica respira un ambiente de tradición y arraigo cultural donde se destacan elementos arquitectónicos y monumentales que evocan su pasado colonial y su relevancia histórica. Cartago se encuentra a una altitud media de 1,450 metros sobre el nivel del mar, lo que le confiere un clima templado de aproximadamente 22 grados centígrados en promedio.

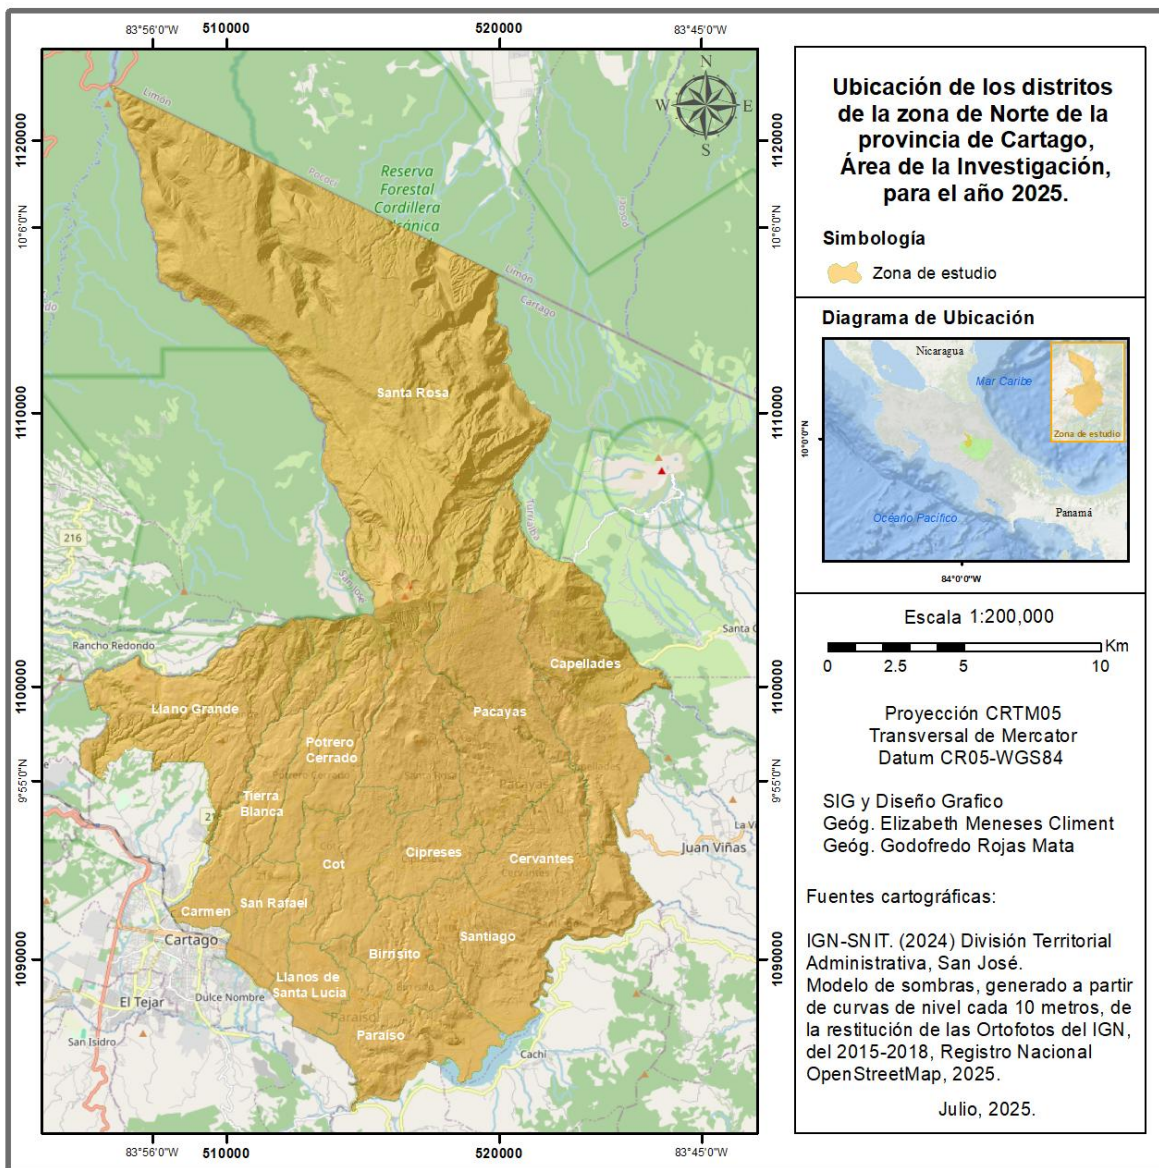
Tabla 1. Distritos del área de investigación

Código de distrito	Nombre del distrito	Área en km²
30103	Carmen	4,33
30108	Tierra Blanca	12,80
30110	Llano Grande	30,35
30201	Paraíso	18,29
30202	Santiago	25,64
30205	Llanos de Santa Lucia	6,54
30206	Birrisito	8,88
30601	Pacayas	29,62
30602	Cervantes	15,18
30603	Capellades	34,39
30701	San Rafael	10,28
30702	Cot	14,86
30703	Potrero Cerrado	18,11
30704	Cipreses	9,37
30705	Santa Rosa	150,27

Fuente: IGN-SNIT (2024)

La provincia de Cartago está conformada por ocho cantones: Cartago, Paraíso, La Unión, Jiménez, Turrialba, Alvarado, Oreamuno y El Guarco (Decreto Ejecutivo N. 41548-MGP). Cada uno de estos cantones tiene características únicas que contribuyen a la diversidad cultural, económica y social de la provincia. En particular, el área de investigación de este estudio se centra en los cantones de Cartago, Oreamuno, Alvarado y Paraíso con un enfoque

específico en los distritos definidos en la Tabla 1 y representados en la Mapa 1. Estos cantones han sido seleccionados debido a su relevancia histórica, su desarrollo agrícola y su impacto tanto en el entorno territorial como social de la provincia.



Mapa 1. Delimitación del área de investigación

Fuente: Elaboración propia, 2025.

El Mapa 1 representa la conformación del área de estudio constituida por 15 distritos que abarcan 4 cantones de la provincia de Cartago y representan el 12,57 % del territorio de la provincia con 388,90 kilómetros cuadrados.

3. MARCO TEÓRICO

3.1. Expansión Urbana y sus Efectos en el Uso de la Tierra

La expansión urbana en Costa Rica responde al crecimiento poblacional y al desarrollo económico que ha generado cambios significativos en la cobertura del suelo, especialmente, en el Valle Central donde se concentra la mayor parte de la población y actividad económica. Como lo menciona la Contraloría General de la República (CGR) (2023) se evidencia un crecimiento acelerado y desordenado, carente de elementos esenciales para un desarrollo urbano sostenible; con el paso de 50 % a 81 % de población urbana entre 1990 y 2020. Este proceso implica la conversión de áreas rurales, agrícolas y naturales en zonas residenciales, comerciales e industriales, lo cual afecta negativamente la disponibilidad y calidad de los recursos naturales y ejerce presión sobre la infraestructura y los servicios existentes. Y como lo menciona Concepción (2022) a medida que la demanda de terreno para asentamiento e infraestructuras continúa aumentando, la urbanización va más allá de áreas urbanas consolidadas y sus alrededores, pues se proliferan áreas urbanizadas dispersas o desperdigadas que generan una fragmentación del paisaje.

La transformación de tierras fértiles en zonas urbanizadas reduce la capacidad de producción agrícola y compromete la seguridad alimentaria a largo plazo, además de alterar los ecosistemas locales, lo que afecta los servicios ambientales, como la regulación del ciclo hidrológico y la conservación de la biodiversidad (Vargas y Nienhuis, 2012). En la zona norte de Cartago, la presión por nuevos desarrollos ha desplazado la actividad agrícola hacia terrenos menos productivos y ha elevado los costos de producción, agravado por la cercanía a la GAM, que acelera la conversión de tierras agrícolas en espacios urbanos (Barboza-Navarro et al., 2021).

Este proceso de urbanización también afecta los recursos hídricos y los suelos, dado que aumenta la escorrentía y provoca inundaciones y erosión. El reemplazo de áreas verdes por superficies impermeables genera islas de calor urbano que alteran el microclima y aumentan las necesidades de energía y agua en las ciudades. Por lo tanto, es crucial que el ordenamiento territorial en Costa Rica se base en una planificación integral y sostenible que favorezca el uso racional del suelo y busque un equilibrio entre el desarrollo urbano y la preservación de los recursos agrícolas y naturales.

3.2.Ordenamiento Territorial.

El ordenamiento territorial es una disciplina fundamental que se ocupa de la organización, planificación y regulación del uso de la tierra y los recursos naturales en un territorio específico con el propósito de alcanzar un desarrollo equilibrado y sostenible. Según Ayala Arcipreste y Márquez (2022), este proceso implica un análisis exhaustivo de las características físicas, ambientales, sociales, económicas y culturales del territorio. La determinación de las actividades y usos más adecuados para cada área debe considerar la capacidad de carga del medio ambiente y las necesidades de la población local.

El ordenamiento territorial no solo optimiza el uso de la tierra en función de su capacidad de carga y las necesidades sociales, económicas y ambientales, sino que también mitiga los conflictos derivados de la competencia por los recursos naturales. Herramientas como la cartografía temática, los modelos de capacidad de carga, la planificación participativa, la evaluación de impacto ambiental, los Sistemas de Información Geográfica (SIG) y el análisis multicriterio son fundamentales en este proceso. Los SIG, en particular, integran operaciones de bases de datos para generar información en capas vectoriales y ráster, lo que facilita el análisis espacial y la toma de decisiones informadas. Estas herramientas permiten recopilar y utilizar datos distribuidos espacialmente, preparar archivos de entrada para modelos y evaluar los resultados, lo cual contribuye a la sostenibilidad y resiliencia de los territorios frente a cambios y presiones urbanas (Molina et al., 2005; Miller et al., 2007).

3.3.Sostenibilidad de las Tierras Agrícolas.

La sostenibilidad de las tierras agrícolas es un componente esencial para garantizar la productividad y viabilidad del sector a largo plazo. Las prácticas sostenibles en la gestión de tierras agrícolas incluyen la rotación de cultivos, el uso eficiente del agua, la conservación del suelo y la biodiversidad, así como la adopción de tecnologías que minimicen el impacto ambiental. La sostenibilidad agrícola se basa en la premisa de que es posible satisfacer las necesidades actuales de producción de alimentos sin comprometer la capacidad de las futuras generaciones para satisfacer sus propias necesidades. Este enfoque holístico integra aspectos económicos, sociales y ambientales, lo que promueve un uso racional y eficiente de los recursos disponibles.

El análisis geoespacial y la clasificación de imágenes mediante teledetección son herramientas cruciales para seguir y gestionar la sostenibilidad de las tierras agrícolas. Y como lo menciona Arruda et al. (2021) la teledetección puede ser útil para monitorear y mapear en diferentes resoluciones espaciales, temporales y espectrales. Estas tecnologías proporcionan datos precisos y actualizados sobre la cobertura terrestre, el estado de los cultivos y los cambios en el uso de la tierra que permite una toma de decisiones más informada y efectiva.

El ordenamiento territorial juega un papel vital en la sostenibilidad de las tierras agrícolas al planificar y regular su uso para equilibrar el crecimiento urbano y la preservación de tierras agrícolas (Vásquez, 1996). Esta disciplina se encarga de distribuir adecuadamente los espacios destinados a actividades agrícolas, urbanas e industriales, asegurando que el desarrollo de las ciudades no comprometa la viabilidad de las zonas rurales y agrícolas. El ordenamiento territorial incluye la identificación de áreas prioritarias para la conservación agrícola y la implementación de políticas que protejan estos territorios de la conversión a usos no agrícolas.

3.4. Sistemas de Información Geográfica (SIG), Teledetección y Tecnologías Avanzadas.

Los SIG son herramientas fundamentales para capturar, almacenar, gestionar, analizar y visualizar datos geoespaciales. Estos sistemas integran múltiples capas de información como imágenes satelitales, datos topográficos de suelo y de cobertura del suelo lo que permite realizar análisis espaciales complejos y generar mapas temáticos que revelan patrones y relaciones entre elementos geográficos. Por ejemplo, en la planificación territorial se emplean los SIG para identificar áreas propensas a inundaciones o para monitorizar la expansión urbana a lo largo del tiempo.

Un SIG integra las operaciones fundamentales de las bases de datos (Molina et al., 2005) como generar información en capas vectoriales y ráster para un análisis espacial. El SIG proporciona el marco dentro del cual se recopilan y utilizan datos distribuidos espacialmente para preparar archivos de entrada del modelo y evaluar los resultados (Miller et al., 2007).

La teledetección complementa el uso de los SIG al adquirir datos sobre la superficie terrestre mediante sensores instalados en satélites, aviones o drones. Esta técnica se clasifica en teledetección pasiva que capta la radiación natural emitida o reflejada por los objetos y teledetección activa que emite radiación hacia la superficie y registra la radiación reflejada (Navarro-González, 2023) (Figura 1). Ejemplos prácticos de su aplicación incluyen el seguimiento de la deforestación y el monitoreo de cultivos donde la información en tiempo real permite evaluar cambios ambientales con gran precisión.



Figura 1. Clasificación de la teledetección

Fuente: Modificado de Pérez (2007)

Estas tecnologías son esenciales para el análisis geoespacial y la gestión de recursos naturales, ya que proporcionan datos precisos y en tiempo real sobre características como la cobertura del suelo, la salud de la vegetación y las variaciones topográficas. Los sensores de percepción remota, instalados en diferentes plataformas, recopilan información sin contacto físico directo, utilizando la radiación electromagnética en diversas bandas espectrales para analizar fenómenos ambientales, agrícolas, urbanos y meteorológicos (Escobedo-Tamez y Yépez-Rincón, 2019; Sacristán, 2005) (Figura 2).

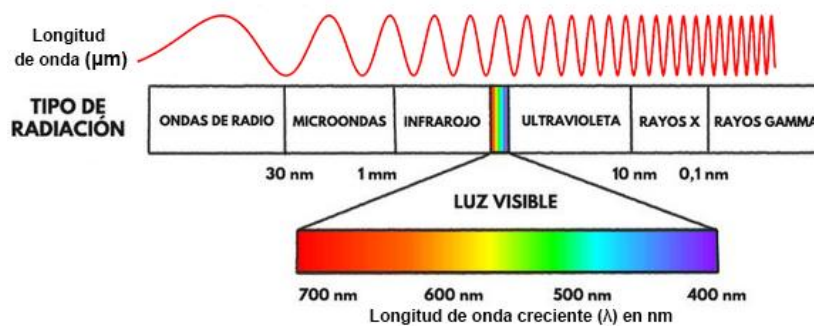


Figura 2. Espectro electromagnético visible

Fuente: Modificado de Pérez (2007)

Los SIG y la teledetección han revolucionado la forma en que se analiza y gestiona la información espacial, los cuales al utilizar dos enfoques: el multitemporal y el multiescalar permiten lograr mayores éxitos en la interpretación de datos y determinar conclusiones en investigaciones.

Enfoque Multitemporal

Es una técnica utilizada en la interpretación de imágenes de satélite para estudiar cambios en la superficie terrestre a lo largo del tiempo. Se utilizan imágenes de diferentes fechas para comparar y analizar los cambios en la vegetación, la urbanización, la degradación del suelo, entre otros aspectos. Los datos recolectados en estos análisis son utilizados para monitorear y manejar de manera efectiva los recursos naturales y para tomar decisiones en la planificación urbana y en la gestión ambiental (Ochoa, 2023).

Los estudios multitemporales son análisis de tipo espacial que se realizan a través de la comparación de interpretaciones de las coberturas en imágenes satelitales, mapas o fotografías aéreas de una misma superficie de terreno en distintos periodos de tiempo. De esta manera, permite la evaluación de los cambios suscitados en las coberturas del suelo que han sido previamente clasificadas para así determinar su evolución del medio natural o las consecuencias de la acción humana sobre aquel medio. Constituyéndose como un método eficaz en el comparación y estimación de cambios acontecidos en un periodo de tiempo determinado (Culqui y Pazmiño, 2022).

Enfoque Multiescalar

Se entiende como la conjunción de diferentes escalas espaciales al ser un enfoque epistemológico distinto al análisis de las escalas por separado y permite analizar la multidimensionalidad de los objetos en estudio.

En este contexto, el enfoque multitemporal permite la observación y comparación de cambios en un área específica a lo largo del tiempo, lo que facilita la identificación de tendencias y patrones en fenómenos naturales y humanos. Además, el enfoque multiescalar se centra en la integración de datos y análisis a diferentes escalas, desde lo local hasta lo global, lo que permite una comprensión más completa y contextualizada de los procesos estudiados. Junto a estos enfoques avanzados potencian la capacidad de los SIG y la teledetección para abordar

desafíos complejos en diversas disciplinas desde la planificación urbana hasta la gestión ambiental (Ceroni et al., 2015).

3.5. Google Earth Engine.

GEE es una plataforma en la nube que permite el análisis y la visualización de datos geoespaciales a gran escala (Orellana Díaz & Jiménez, 2018). Y como se refiere Velastegui-Montoya et al. (2023) GEE cuenta con un vasto catálogo a escala de *petabytes*. Su extenso catálogo de imágenes satelitales, como las de Landsat, MODIS, y Sentinel, junto con capacidades avanzadas de análisis facilita estudios detallados del uso de la tierra, la cobertura terrestre y otros aspectos ambientales (Habib & Connolly, 2023; Méndez Cordonero, 2024) (Figura 3). GEE es especialmente útil para la detección de cambios, el mapeo de tendencias y la cuantificación de recursos naturales para brindar una solución eficiente para el análisis geoespacial (Mutanga & Kumar, 2019). Además, GEE utiliza clúster de servidores para el manejo de datos y como lo menciona Peñaloza y Peñaloza (2018) la computación paralela es necesaria para el manejo de grandes volúmenes de información como la clasificación de Imágenes Satelitales.



Figura 3. Catálogo de datos públicos de GEE

Fuente: Modificado de GEE (2024)

GEE se basa en tres elementos clave: el catálogo de información, la capacidad computacional y la Interfaz de Programación de Aplicaciones (API). Dichos aspectos permiten a los usuarios concentrarse en la generación de resultados científicos significativos. La plataforma integra

aprendizaje automático (ML), una rama de la inteligencia artificial que permite a las máquinas aprender de los datos y hacer predicciones. Los enfoques principales de ML incluyen el aprendizaje supervisado, no supervisado, semisupervisado y de refuerzo. Cada uno emplea aplicaciones específicas en el análisis de datos geoespaciales (Solórzano y Perilla, 2022; Sarker, 2021).

En el sector agrícola, GEE permite análisis detallados sobre la salud de los cultivos y la gestión de recursos hídricos al utilizar técnicas como el NDVI y la clasificación supervisada y no supervisada, lo cual se describirá con más detalle. Esta información es esencial para la planificación y gestión sostenible de las tierras agrícolas, lo cual ayuda a tomar decisiones informadas que promuevan la sostenibilidad (Verma & Verma, 2021; Sidey-Gibbons & Sidey-Gibbons, 2019; Franceschini & Ali, 2022).

Índice de Vegetación de Diferencia Normalizada (NDVI)

El NDVI es una medida ampliamente utilizada para evaluar la salud y la densidad de la vegetación a partir de datos obtenidos por sensores remotos. Se calcula utilizando la diferencia entre las reflectancias en el infrarrojo cercano (NIR) y el espectro rojo (RED) de la luz solar reflejada por la superficie terrestre. Este índice varía de -1 a 1, donde los valores más altos indican una mayor densidad y salud vegetal, mientras que valores bajos o negativos pueden indicar la presencia de suelos desnudos o cuerpos de agua (Pettorelli et al., 2005).

Principios Fundamentales

Como lo menciona Huete et al. (2002), el cálculo del NDVI se basa en la diferencia normalizada de las reflectancias de dos bandas espectrales:

- NIR (Infrarrojo Cercano): Esta banda es sensible a la cantidad de clorofila presente en las hojas de las plantas y es altamente reflectante en vegetación densa.
- RED (Rojo): Esta banda es absorbida por la clorofila en las hojas verdes, por lo tanto, es menos reflectante en vegetación densa.

Este índice se ha incorporado de manera extensa en estudios geoespaciales y de planificación territorial. En el ámbito agrícola, por ejemplo, el NDVI facilita la detección temprana de

zonas con estrés hídrico o deficiencias nutricionales, lo cual permite intervenciones oportunas. Asimismo, en la evaluación ambiental, se utiliza para monitorizar cambios en la cobertura vegetal y para desarrollar mapas temáticos que apoyen la implementación de políticas de conservación y restauración (Toribio, 2019) (Figura 4).

Complementariamente, el NDVI se integra en métodos de clasificación supervisada y no supervisada en teledetección, por lo que contribuye a agrupar áreas con características similares y a mejorar la precisión de los análisis de imágenes satelitales (Foody, 2002; Vaddi et al., 2024). Además, cabe destacar lo que indicó el INEGI (2022), el NDVI se consolidó como una propuesta fundamental en el análisis de percepción remota multiespectral y ha sido ampliamente empleado en investigaciones desde la década de 1970.

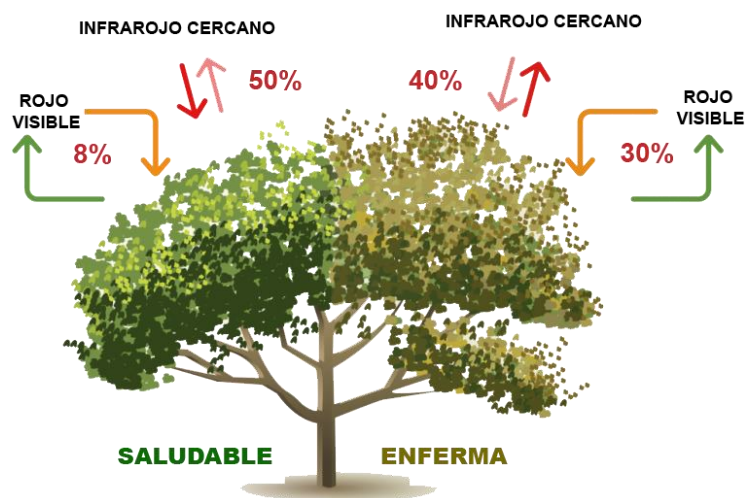


Figura 4. Porcentajes de irradiación de cada banda espectral

Fuente: Modificado de Toribio (2019)

Clasificación Supervisada y No Supervisada

La clasificación supervisada es un método donde el analista proporciona muestras de entrenamiento al algoritmo, especificando qué categoría (clase) representa cada muestra. El algoritmo utiliza estas muestras para aprender a distinguir entre las diferentes clases en el resto de la imagen (Foody, 2002).

La clasificación no supervisada es un método donde el algoritmo asigna automáticamente píxeles a diferentes clases sin la necesidad de muestras de entrenamiento previas y agrupa

los píxeles en clases basadas en sus características espectrales y de textura en busca de patrones naturales en los datos (Vaddi et al., 2024).

Imágenes Sentinel-2

Es una misión de observación de la Tierra desarrollada por la Agencia Espacial Europea (ESA) como parte del programa Copernicus (Arrieta-Chaves, 2021). Consiste en dos satélites, Sentinel-2A y Sentinel-2B, que operan en conjunto para proporcionar imágenes ópticas multispectrales de alta resolución (10 a 60 metros) que capturan datos en 13 bandas espectrales sobre vegetación, el suelo, el agua, la cobertura terrestre y las áreas costeras (Copernicus, 2018).

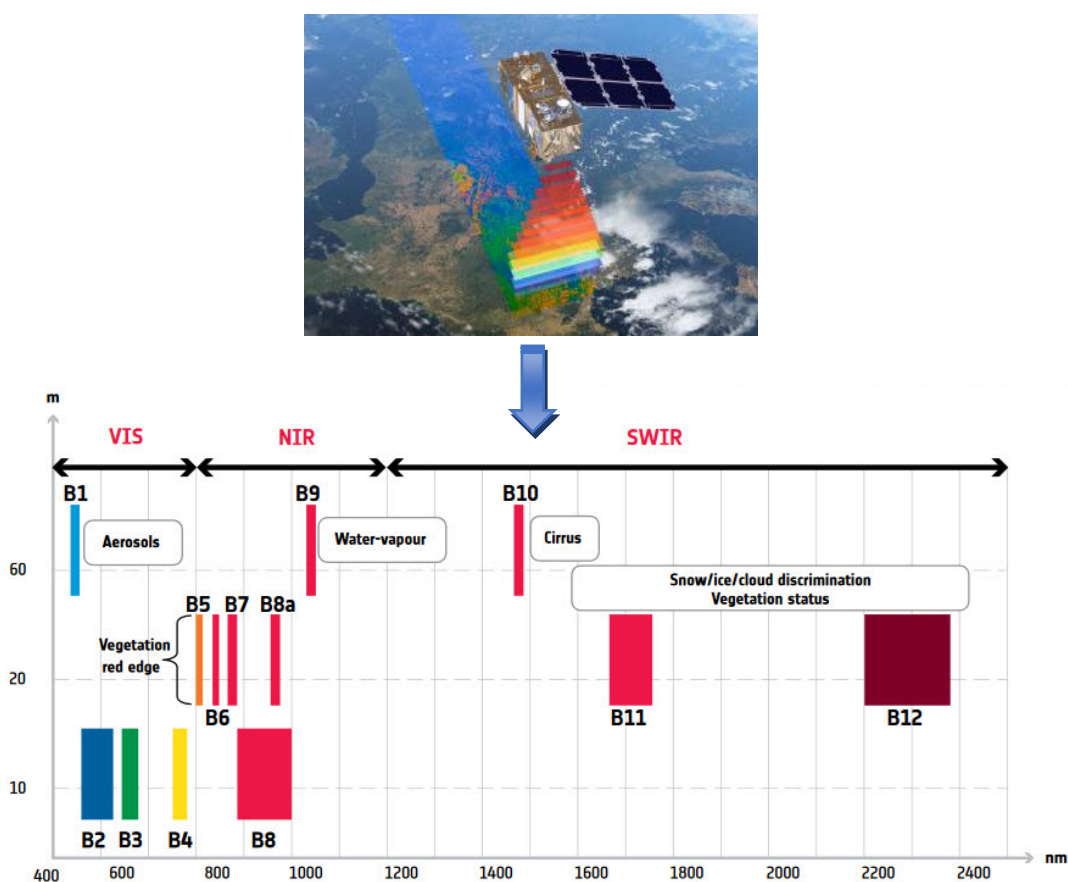


Figura 5. Satélite Sentinel-2 y la representación de sus 13 bandas

Fuente: Modificado de GeoSage (2025)

Además, la alta frecuencia de revisita de Sentinel-2 alcanza intervalos de 5 días en regiones de latitudes medias, lo cual permite la construcción de series temporales que facilitan el monitoreo de cambios estacionales a largo plazo en la cobertura del suelo (Drusch et al., 2012; Mutanga & Kumar, 2019).

Este enfoque integral permite a los investigadores obtener una comprensión profunda de la dinámica territorial que facilita la formulación de estrategias de ordenamiento territorial y de sostenibilidad agrícola basadas en evidencia empírica y análisis cuantitativos (Congalton & Green, 2008). Como se menciona el proyecto Sentinel tiene una capacidad relevante para el estudio de la dinámica agrícola, ya que posibilita la identificación de patrones sutiles en la vegetación que son indicadores de la salud y la productividad de los cultivos. Y como se refiere Jaramillo y Antunes (2018) las imágenes satelitales de resolución espacial y espectral media y alta son herramientas fundamentales para la ejecución de proyectos destinados a la clasificación de la cobertura vegetal y la detección de sus variaciones temporales.

El enfoque multiescalar y multitemporal basado en Sentinel-2 y reforzado por el trabajo de campo y el desarrollo de códigos específicos en GEE constituye un método avanzado y replicable que permite un análisis detallado y confiable de los cambios en la cobertura del suelo. Este enfoque no solo es esencial para la identificación de áreas de conflicto entre la expansión urbana y la actividad agrícola, sino que también sienta las bases para la implementación de políticas públicas orientadas a la gestión sostenible del territorio.

A esto se puede sumar lo que mencionada Trujillo-Jiménez et al. (2021) sobre el proyecto Sentinel-2 el cual fue diseñado para el monitoreo de la vegetación y el mapeo de la cobertura terrestre. De esta manera las capacidades de Sentinel-2, sumadas a las herramientas analíticas y a la validación *in situ*, proporcionan una plataforma integral para abordar los desafíos contemporáneos en el ordenamiento territorial que garantiza resultados precisos y de alta relevancia para la toma de decisiones en la planificación de la cobertura del suelo (Drusch et al., 2012; Mutanga & Kumar, 2019; Pettorelli et al., 2005).

4. METODOLOGÍA

En este trabajo de tesis se aplicaron técnicas avanzadas de teledetección y análisis geoespacial en el marco del ordenamiento territorial con enfoque en la sostenibilidad agrícola y la gestión de recursos en la zona norte de Cartago, Costa Rica. Utilizando GEE, se desarrolló un análisis detallado mediante el cálculo del NDVI y la aplicación de técnicas de clasificación supervisada y no supervisada con el objetivo de obtener información precisa sobre la cobertura y el uso del suelo. Las técnicas empleadas fueron esenciales para identificar zonas de conflicto entre el crecimiento urbano y las áreas agrícolas productivas para facilitar la toma de decisiones informadas en los procesos de planificación y gestión territorial.

La metodología del estudio siguió una serie de pasos estructurados. Para el uso de GEE, fue necesario crear una cuenta y configurar el entorno de trabajo, lo que permitió desarrollar los *scripts* requeridos para el análisis. La delimitación del área de estudio consideró los distritos ubicados al norte de la cuenca del río Reventazón, tradicionalmente vinculados a la actividad agrícola. Con el propósito de fundamentar el análisis espacial, se recurrió a información geográfica oficial proveniente del Registro Nacional de la Propiedad (RNP) y del Sistema Nacional de Información Territorial (SNIT). Los datos fueron obtenidos mediante el servicio WFS del *Open Geospatial Consortium* (OGC) que facilita la descarga de capas vectoriales de la división administrativa nacional. Los límites oficiales de los distritos fueron definidos a través del software de Sistemas de Información Geoespacial, QGIS. En esta plataforma, los datos espaciales se procesaron en formato *Shapefile* con proyección CRTM05 y, posteriormente, se transformaron a WGS84 para garantizar su compatibilidad con GEE y optimizar la preparación de información conforme a los estándares geoespaciales.

Se emplearon imágenes satelitales Sentinel-2 con resolución espacial de 10 x 10 metros, lo cual permitió realizar un análisis preciso de la vegetación y de los cambios en la cobertura del suelo durante un periodo de un año. Esta información brindó una visión actualizada sobre la dinámica territorial y agrícola de la zona que es clave para evaluar la sostenibilidad de los recursos.

En el entorno de GEE se programó un conjunto de algoritmos en lenguaje *JavaScript*, utilizados para calcular el NDVI y llevar a cabo clasificaciones supervisadas y no supervisadas de la cobertura terrestre. Estos resultados enriquecieron la comprensión de las dinámicas territoriales y agrícolas en la región de Cartago, además de generar herramientas replicables para su aplicación en otras regiones y marcos temporales. La metodología implementada permitió integrar variables clave de análisis geoespacial que constituyen a una base técnica sólida para apoyar procesos de planificación y ordenamiento territorial con enfoque en conservación agrícola y sostenibilidad, en consonancia con la normativa vigente.

4.1. Tipo de investigación

Según Grajales (2000), existieron diversos tipos de investigación, entre los cuales se incluyeron la investigación básica, aplicada, documental, de campo o mixta, exploratoria, descriptiva, explicativa, experimental y no experimental, entre otros. En el presente estudio se adoptó un enfoque de investigación aplicada, orientado a la implementación de herramientas tecnológicas avanzadas que permitieron abordar problemáticas específicas de ordenamiento territorial y sostenibilidad agrícola.

La investigación aplicada en este estudio se centró en la utilización de técnicas de clasificación supervisada y no supervisada mediante GEE en la zona norte de la provincia de Cartago. Este enfoque metodológico se fundamentó en la aplicación de técnicas de teledetección y análisis geoespacial con el uso de datos satelitales para identificar y clasificar diferentes coberturas vegetales y usos del suelo. Se establecieron procedimientos detallados que incluyeron la adquisición y procesamiento de datos geoespaciales, la implementación de algoritmos de clasificación en GEE y la validación de resultados mediante criterios cuantitativos y cualitativos. Esta metodología se vinculó directamente con los objetivos del estudio, ya que facilitó la toma de decisiones basadas en información precisa y actualizada que contribuye a mejorar la gestión territorial y la planificación agrícola en la región.

4.2. Enfoque Multiescalar y Multitemporal

El enfoque multiescalar y multitemporal constituyó el pilar fundamental de la metodología desarrollada en este estudio, ya que permitió abordar los procesos de cambio en la cobertura

del suelo y la salud de las tierras agrícolas desde una perspectiva que integró tanto la amplitud espacial como la dinámica temporal (Anderson et al., 1976). En este sentido, se optó por la utilización de imágenes satelitales de Sentinel-2 cuya alta resolución y capacidad multispectral facilitaron un análisis detallado de la cobertura terrestre en múltiples escalas y a lo largo de periodos extendidos.

El análisis multiescalar se fundamentó en la capacidad de integrar datos a diferentes resoluciones espaciales, lo cual permite la identificación de tendencias generales a nivel regional (macroescala) y la detección de variaciones locales en zonas específicas de conflicto entre la expansión urbana y el uso agrícola (microescala). En la escala macro, las imágenes de Sentinel-2 ofrecieron una visión global que permitió observar la evolución de los patrones de la cobertura del suelo en toda la zona de estudio, lo que evidencia la expansión urbana y la consecuente reducción de áreas dedicadas a la agricultura. A nivel micro, el análisis se complementó con el trabajo de campo, en el que se recolectaron datos de alta precisión que validaron y calibraron los modelos obtenidos a partir de la teledetección. Este doble abordaje garantizó una robusta validación de los resultados, ya que la comparación entre datos satelitales y mediciones *in situ* permitió corregir posibles sesgos y mejorar la exactitud de la clasificación de la cobertura del suelo.

Para llevar a cabo este análisis se desarrollaron tres códigos principales en el entorno de GEE que permitieron procesar y analizar las imágenes de Sentinel-2 de manera automatizada y reproducible. Seguidamente, se detalla cada uno de estos. El primer código fue diseñado para el cálculo del NDVI, el cual se utilizó como indicador de la salud de la vegetación y permitió distinguir áreas de cultivos sanos de aquellas sometidas a estrés o degradación. La fórmula del NDVI, basada en la diferencia normalizada entre las bandas del infrarrojo cercano y el rojo, se implementó para generar mapas que reflejaron de forma cuantitativa la variabilidad de la vegetación en el territorio (Pettorelli et al., 2005).

El segundo código se encargó de realizar la clasificación supervisada de la cobertura del suelo. Este algoritmo se nutrió de datos de entrenamiento obtenidos a partir de la recolección de información de campo y de la interpretación visual de las imágenes satelitales. Mediante

el uso de algoritmos como el *Support Vector Machine* (SVM), se clasificaron las áreas en distintas categorías, tales como áreas agrícolas, urbanas, forestales y cuerpos de agua. La clasificación supervisada permitió una asignación precisa de las clases y facilitó la identificación de áreas de conflicto en la frontera entre el crecimiento urbano y la expansión agrícola (Foody, 2002; Maxwell et al., 2018).

El tercer código implementó la clasificación no supervisada que utilizó técnicas de agrupamiento como el algoritmo *K-Means* para detectar patrones inherentes en las imágenes sin la necesidad de muestras previas. Este método de aprendizaje automático agrupó datos en conjuntos similares o clústeres. Esta metodología fue particularmente útil para identificar patrones emergentes o áreas que no habían sido previamente definidas que proporcionan una visión complementaria a la clasificación supervisada (Tobar-Díaz et al., 2023). La integración de ambas técnicas de clasificación en el análisis permitió contrastar y validar los resultados para asegurar que las zonas identificadas correspondieran a patrones reales de cambio en el territorio.

El trabajo de campo, en conjunto con estos tres códigos, habilitó una validación cruzada robusta de los resultados obtenidos a partir de la teledetección. La recolección de datos *in situ*, mediante el uso de equipos de alta precisión, complementó el análisis satelital al asegurar que los índices calculados y las clasificaciones generadas reflejaran fielmente la realidad del terreno.

4.3. Definición de Variables Clave y Parámetros Iniciales

Para el desarrollo del análisis geoespacial en la zona norte de Cartago fue indispensable establecer las variables clave y los parámetros iniciales que guiaron la ejecución metodológica del estudio. Esta definición permitió estructurar un marco técnico coherente para la evaluación del uso y cobertura del suelo, así como para la interpretación de los procesos de transformación territorial vinculados al crecimiento urbano y la sostenibilidad agrícola.

En este contexto, se definieron los insumos fundamentales para el análisis multiescalar y multitemporal, lo cual garantizó la integridad de los datos procesados y la alineación con los objetivos específicos de la investigación. Los parámetros generales utilizados fueron los siguientes:

- **Imágenes Satelitales:** se emplearon imágenes Sentinel-2 con una resolución de 10 x 10 metros, lo que incrementó la precisión tanto en el análisis espacial como temporal. El uso de estas imágenes es principalmente por su disponibilidad gratuita de los datos y su resolución.
- **Periodo de Estudio:** el análisis abarcó un periodo de un año (enero 2024 a enero 2025) que proporcionó una visión actualizada de la dinámica de uso de la tierra, esto para ver el estado de los cultivos, pero en el caso de clasificación supervisada y no supervisada se utilizó un rango de imágenes del primer trimestre del 2025.
- **Información de campo:** se realizó un trabajo de levantamiento de datos con la validación con GPS de alta precisión con punto previamente interpolados según cada distrito de la zona de estudio para recolectar muestras representativas de cada categoría de la cobertura del suelo.
- **Sistema de Coordenadas:** para garantizar la precisión y compatibilidad de los datos, estos fueron proyectados inicialmente en CRTM05 utilizando QGIS y, posteriormente, transformados al sistema de coordenadas geográfica con WGS84 para su integración en GEE.

El análisis geoespacial se sustentó en variables definidas estratégicamente para responder a los objetivos específicos de la investigación. La siguiente tabla resume dichas variables, su tipo, los instrumentos o indicadores empleados para su medición y el objetivo específico al cual se encuentran asociadas. Esta estructuración metodológica permitió vincular directamente los componentes técnicos del análisis con las metas del estudio, lo que facilita tanto la interpretación de los resultados como la reproducibilidad del proceso investigativo.

Tabla 2. Variables de análisis geoespacial y su vinculación con los objetivos específicos

<i>Variable</i>	Tipo	Instrumento/Indicador	Objetivo vinculado
<i>NDVI</i>	Cuantitativa continua	Cálculo multitemporal con Sentinel-2	Objetivo 2: Determinar factores ambientales que afectan la degradación agrícola.
<i>Cobertura del suelo</i>	Cualitativa nominal	Clasificación supervisada y no supervisada	Objetivo 1: Identificar zonas de conflicto por expansión urbana.
<i>Zonas de conflicto agro-urbanas</i>	Cualitativa dicotómica	Cruce espacial entre capas SIG	Objetivo 1: Proponer estrategias de planificación para la conservación de suelos.
<i>Fragmentación y patrones espaciales</i>	Cuantitativa continua	Índice de Moran Global y Local (LISA)	Objetivo 3: Formular propuestas de ordenamiento y gestión territorial.

Fuente: Elaboración propia, 2025.

- **Cálculo de Índices de Vegetación**

Se utilizó el NDVI para evaluar el estado de los cultivos. Según Kriegler et al. (1969), el NDVI se obtuvo al calcular la razón entre la diferencia (NIR – Roja) y la suma (NIR + Roja) de los valores de las bandas del infrarrojo cercano (NIR) y rojo (RED) de las imágenes Sentinel-2 (ver Anexo 1). Este índice permitió distinguir áreas de vegetación saludable (valores positivos) de aquellas sin cobertura vegetal significativa (valores cercanos a 0 o negativos). La reflectancia espectral de la vegetación, medida a través de diferentes bandas, se utilizó como indicador de la presencia y el estado general de la cobertura vegetal (Toribio, 2019).

- **Clasificación Supervisada y No Supervisada del Uso de la Tierra**

Para optimizar el análisis y lograr una categorización detallada de la cobertura del suelo, se emplearon técnicas de clasificación supervisada y no supervisada a través de GEE. Estas metodologías permitieron identificar y agrupar los distintos tipos de cobertura terrestre, lo cual garantizó un análisis integral de la zona norte de Cartago en consonancia con los objetivos de ordenamiento territorial y sostenibilidad agrícola.

La clasificación supervisada se fundamentó en el uso de datos de entrenamiento, mediante la selección manual de muestras representativas de cada categoría de la cobertura del suelo (denominadas "regiones de interés"). Estas fueron etiquetadas en GEE para que el algoritmo aprendiera a distinguir patrones específicos y clasificara con precisión las diferentes coberturas. Este método resultó ser especialmente útil cuando se contó con información previa sobre la cobertura del suelo, lo que asegura resultados que reflejaran de manera confiable la realidad en campo.

En contraste, la clasificación no supervisada utilizó algoritmos de agrupamiento, como *K-Means*, que no requirieron datos de referencia. Este enfoque agrupó los datos en clases basadas en similitudes espectrales, lo que facilita la detección de patrones naturales de la cobertura terrestre sin intervención manual. Los resultados obtenidos mediante ambas técnicas fueron procesados y visualizados en GEE para posteriormente exportarse en formato .TIFF e integrarse en QGIS, lo que permitió un análisis complementario. La combinación de estos métodos proporcionó una caracterización detallada del territorio, fundamental para la formulación de estrategias de ordenamiento territorial y el diseño de políticas de sostenibilidad agrícola en la región de Cartago.

4.4. Recolección de datos de campo

Para complementar el análisis geoespacial y mejorar la precisión de la clasificación de la cobertura del suelo, se llevó a cabo una recolección de datos de campo en áreas representativas de la región norte de Cartago. La selección de estas áreas se basó en un muestreo estratificado aleatorio al utilizar como base los resultados preliminares de la clasificación no supervisada y mapas temáticos existentes. Dicha metodología permitió distribuir puntos de verificación de manera proporcional entre los diferentes distritos y clases

de cobertura identificadas. La representatividad espacial fue validada mediante criterio experto al considerar factores como accesibilidad, diversidad de coberturas, heterogeneidad del paisaje y experiencia local. Se utilizaron equipos GPS de alta precisión para georreferenciar los puntos de control, lo cual permitió recolectar muestras fiables de cada categoría al incluir zonas agrícolas, áreas urbanizadas, cuerpos de agua, bosques, matorrales y pastizales. Esta verificación en campo fue clave para validar y calibrar los resultados generados en GEE y garantizar que las clases de cobertura terrestre reflejaran con precisión las condiciones reales observadas en terreno, como lo respaldan también estudios recientes (Tesfaye et al., 2024).

Para determinar la cantidad de puntos de campo, se analizaron varias fuentes referenciales, entre ellas Foody (2002), quien analizó la influencia del número de muestras en la precisión de los modelos de clasificación supervisada, y Olofsson et al. (2014), quienes en su obra abordaron la relación entre el número de muestras y la exactitud del mapeo de cambios de cobertura terrestre. Además, se determinó la cantidad de categorías a analizar y con el uso del Sistema de Clasificación de Cobertura de la Tierra del SIMOCUTE et al. (2023) se determinaron cinco categorías para la cobertura del suelo con el fin de utilizarlas no solo en el proceso de clasificación supervisada y no supervisada, sino también para definir la cantidad de puntos de campo.

Además, con la información del artículo desarrollado por Van Genderen et al. (1978), se desarrolló la siguiente fórmula según la distribución normal y el cálculo de proporciones basado en precisión objetivo, la cual permitía estimar la cantidad de muestras necesarias en una clasificación supervisada:

$$N = \frac{Z^2 P (1 - P)}{E^2}$$

Donde:

- N = Número mínimo de muestras necesarias por clase.
- Z = Valor de la distribución normal estándar asociado con el nivel de confianza (1.96 para un 95% de confianza, 2.58 para un 99% de confianza).
- P = Precisión esperada o probabilidad de clasificación correcta (por ejemplo, 0.95 si se espera 95% de precisión).
- E = Error máximo permitido o margen aceptable (por ejemplo, 0.05 para $\pm 5\%$).

Determinando de esta manera que la fórmula se fundamentó en estudios sobre la validación de clasificaciones de imágenes de teledetección (Congalton & Green, 2008; Foody, 2002), así como en la literatura sobre muestreo para la evaluación de exactitud temática (Stehman & Czaplewski, 1998). Tras realizar los ajustes correspondientes en la fórmula, y considerando que se trabajó con seis clases principales, se determinó la cantidad mínima de muestras necesarias para cada clase. Se definen los siguientes parámetros:

- Precisión esperada: **95%** ($P = 0.95$).
- Nivel de confianza: **99%** ($Z = 2.58$).
- Error máximo aceptable: **±5%** ($E = 0.05$).

Sustituyendo en la ecuación:

$$N = \frac{(2.58)^2 \times 0.95 (1 - 0.95)}{0.05^2}$$

$$N = \frac{6.6564 \times 0.95 \times 0.05}{0.0025}$$

$$N = \frac{0.316179}{0.0025} = 126.47$$

Se definieron los siguientes parámetros y con base en ellos se requirieron al menos 126 muestras por clase para garantizar la precisión en la recolección de datos de campo (ver Anexo 4). No obstante, con el objetivo de mejorar la calidad de los insumos, se decidió generar los puntos de forma aleatoria utilizando la herramienta “Puntos aleatorios dentro del polígono” en QGIS, lo cual permitió obtener la misma cantidad de puntos en cada distrito. Adicionalmente, se integró una séptima categoría correspondiente a las nubes, debido a la presencia de nubosidad en la parte norte y noreste de la zona de estudio en las imágenes Sentinel-2 seleccionadas. De esta forma, y haciendo uso de múltiples herramientas SIG y de teledetección, se estableció un total de 70 puntos por distrito, lo que representó 1,050 muestras en total distribuidas en toda el área de estudio (ver Anexo 2). Este procedimiento se basó en los lineamientos de Stehman & Czaplewski (1998), quienes señalaron que los muestreos probabilísticos se construyen a partir de protocolos de selección aleatoria simple y sistemática. Con ello, se logró mejorar la calidad de las clasificaciones sin interferir con los procesos automatizados implementados mediante código en GEE.

Una vez consolidados estos datos, se integraron al colector de GNSS Trimble® Modelo TDC600, el cual cuenta con un receptor GNSS profesional de alta precisión. Este dispositivo posee antena interna de 72 canales, alta sensibilidad multiconstelación y una precisión inferior a 2 metros bajo SBAS, compatible con sistemas como GLONASS (GPS/GLO/GAL), Galileo (GPS/GAL) y BeiDou (GPS/BeiDou/GAL).

Para esta investigación, se utilizó la aplicación *Mobile Topographer* (ver Anexo 3). Herramienta móvil que permitió realizar levantamientos de campo de forma sencilla y eficiente. Gracias a su interfaz intuitiva se facilitaron las tareas de recolección de datos geoespaciales. De esta forma, se cargaron los puntos de campo requeridos y necesarios para llevar a cabo la verificación de la precisión de la cobertura del suelo. Esta funcionalidad fue crucial, pues permitió comparar los datos recolectados en campo con la información derivada de las imágenes para asegurar así la validez de los resultados obtenidos.

Posteriormente, se elaboró un plan de trabajo para la verificación de los puntos de control. Para ello, se realizaron giras durante los sábados de diciembre de 2024 a marzo de 2025. Ahora bien, para planificar eficientemente las visitas de campo se utilizó el módulo Trimble GNSS *Planning* (<https://www.gnssplanning.com>), el cual permitió identificar las mejores ventanas temporales para la toma de datos, como se muestra en las Figuras 6, 7, 8 y 9.

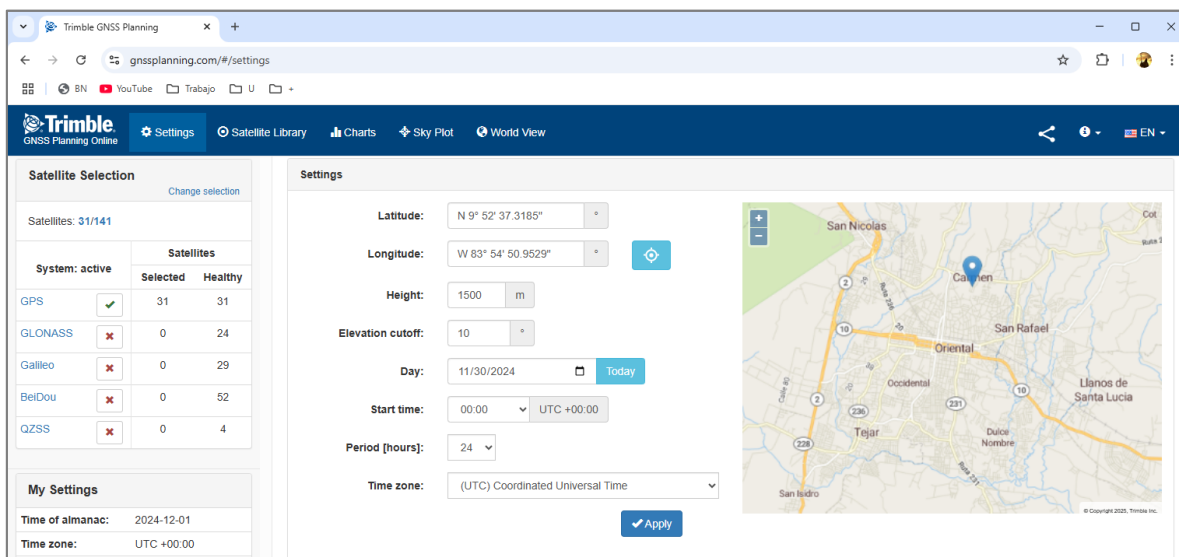


Figura 6. Selección de trabajo por medio de latitud, longitud y elevación central

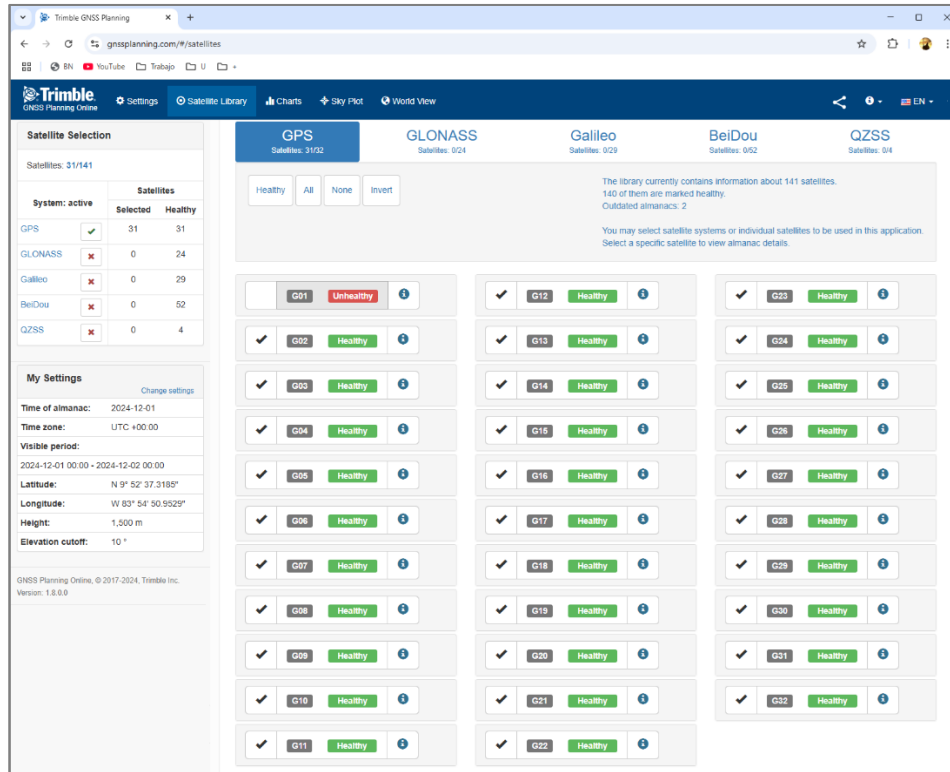


Figura 7. Constelaciones disponibles según el equipo a utilizar

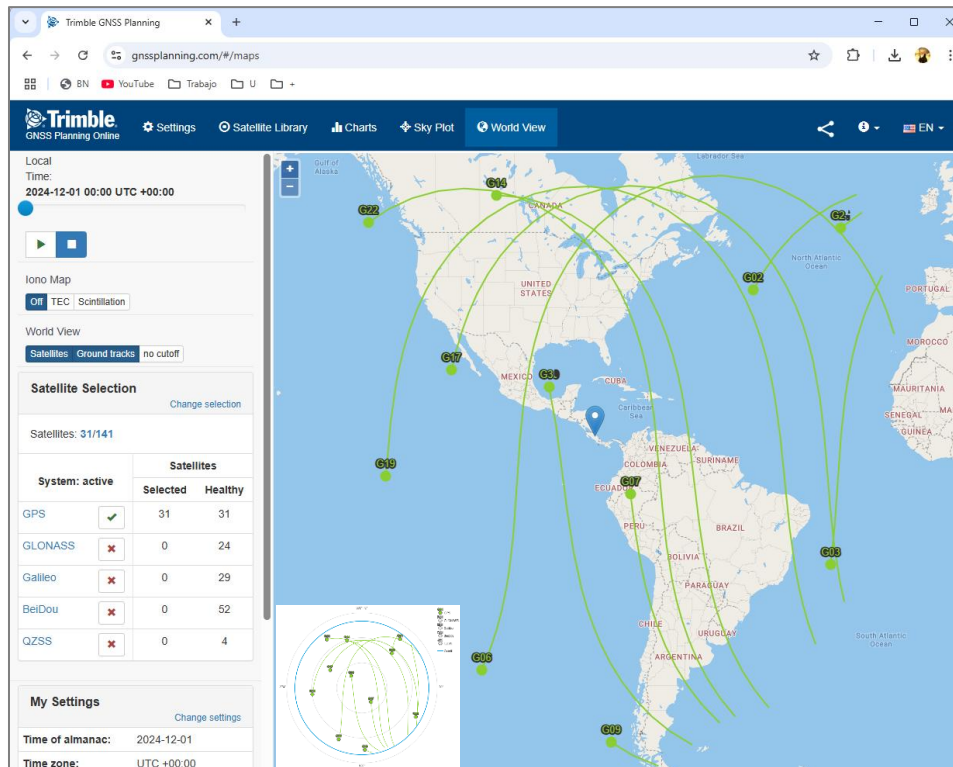


Figura 8. Orbits de los satélites de la constelación GPS

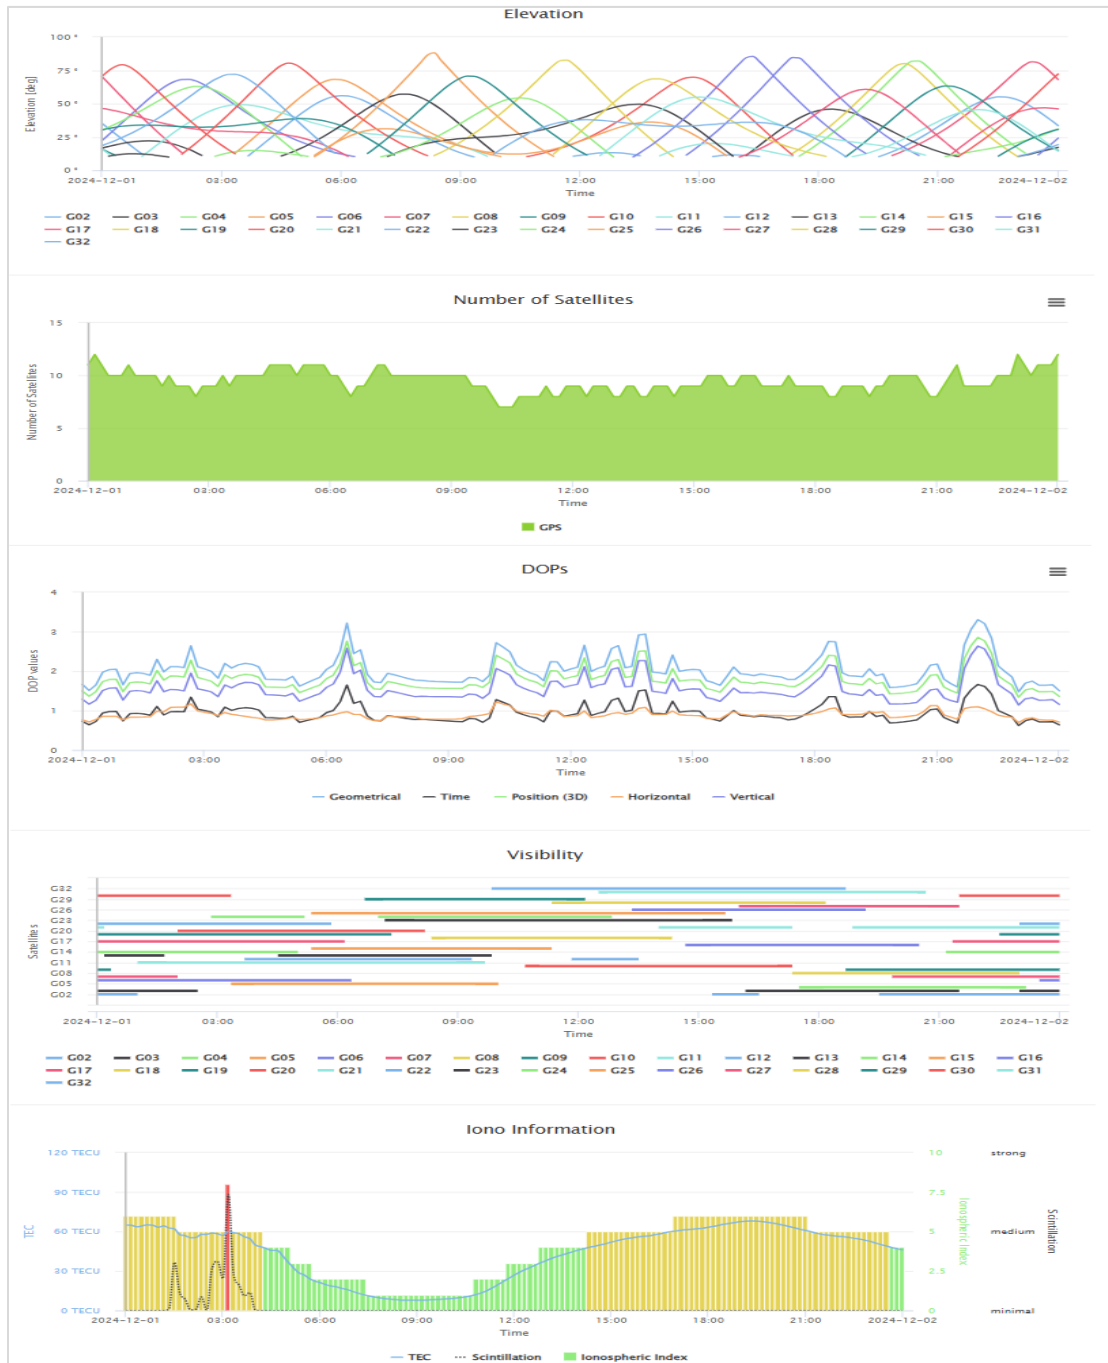


Figura 9. Condiciones atmosféricas y la mejor hora para la toma de datos

De esta forma, se determinó que el mejor horario para verificar la información de los datos de las muestras fue entre las 7:00 a.m. y las 14:00 p.m., periodo durante el cual se registró la presencia de entre 8 y 11 satélites de la constelación GPS. Esto permitió mejorar la precisión en la ubicación geográfica de los puntos al considerar además los factores atmosféricos analizados mediante la plataforma de planificación de Trimble.

4.5. Implementación de GEE

Para el procesamiento y análisis de los datos geoespaciales, se siguieron una serie de pasos para implementar GEE en esta investigación (ver Anexo 5). En primer lugar, se delimitó el área de estudio en QGIS, utilizando datos oficiales del Registro Nacional de Costa Rica en formato *Shapefile* proyectados en el sistema CRTM05. Posteriormente, estos datos se transformaron al sistema de coordenadas WGS84 para garantizar su compatibilidad con GEE. A continuación, se configuraron los datos de entrada en la plataforma, incluyendo imágenes Sentinel-2 de alta resolución espacial (10 x 10 metros) que fueron seleccionadas para capturar detalles relevantes sobre la cobertura y el uso del suelo en la zona norte de Cartago, en el periodo comprendido entre enero de 2024 y enero de 2025.

En GEE, se empleó el lenguaje *JavaScript* (JS) para crear *scripts* y algoritmos personalizados que permitieron realizar análisis de la cobertura vegetal y otros indicadores territoriales (AmbGEO, 2025; CAEG - Centro de Altos Estudios en Geomática, 2024). Este lenguaje resultó fundamental para codificar operaciones de procesamiento de imágenes satelitales y realizar análisis geoespaciales complejos según las características ofrecidas por la plataforma (Pérez Romero et al., 2024). Mediante el cálculo del NDVI, se evaluó la salud y densidad de la vegetación en el área de interés, variable esencial para identificar zonas agrícolas productivas y zonas en riesgo por presión urbana. Asimismo, la plataforma permitió aplicar filtros temporales y espaciales a las imágenes, así como máscaras para reducir el ruido provocado por la nubosidad, lo que aseguró una mayor calidad en los datos obtenidos.

Finalmente, se aplicaron técnicas de clasificación supervisada y no supervisada para categorizar la cobertura del suelo. La clasificación supervisada se realizó con base en muestras de entrenamiento recolectadas en el trabajo de campo que permitieron identificar áreas específicas como zonas agrícolas, urbanas y cuerpos de agua. Por su parte, la clasificación no supervisada utilizó algoritmos de agrupamiento para detectar patrones naturales del territorio sin requerir datos de referencia. Los resultados de ambas clasificaciones fueron exportados desde GEE en formato *.TIFF* para su posterior visualización, análisis y evaluación en QGIS. Esta metodología, basada en el uso de GEE, permitió obtener información clave para la gestión y planificación territorial con el fin de

proporcionar un enfoque robusto, automatizado y actualizado para el ordenamiento sostenible de los recursos en la región de Cartago.

4.6. Estructura del código para GEE

El código GEE siguió una estructura organizada que incluyó varias secciones clave, lo cual garantizó que fuera eficiente, claro y replicable para futuros análisis. De esta manera, para esta investigación se establecieron tres códigos (NDVI, clasificación supervisada y no supervisada) en los que se cumplieron los siguientes parámetros:

4.6.1. Selección de Datos y Área de Estudio:

- En primer lugar, se analizaron los datos y capas necesarias para desarrollar el experimento, a partir del análisis bibliográfico y de las capas oficiales proporcionadas por el país mediante el SNIT.
- Posteriormente, se llevaron a cabo los pasos detallados en el Anexo 3 que incluyeron la creación de la cuenta en GEE, la organización de los datos a utilizar y la generación del archivo necesario para delimitar la zona de estudio.
- Finalmente, se creó el repositorio de trabajo en la plataforma de GEE mediante el uso del botón “NEW”, como se muestra en la Figura 10.

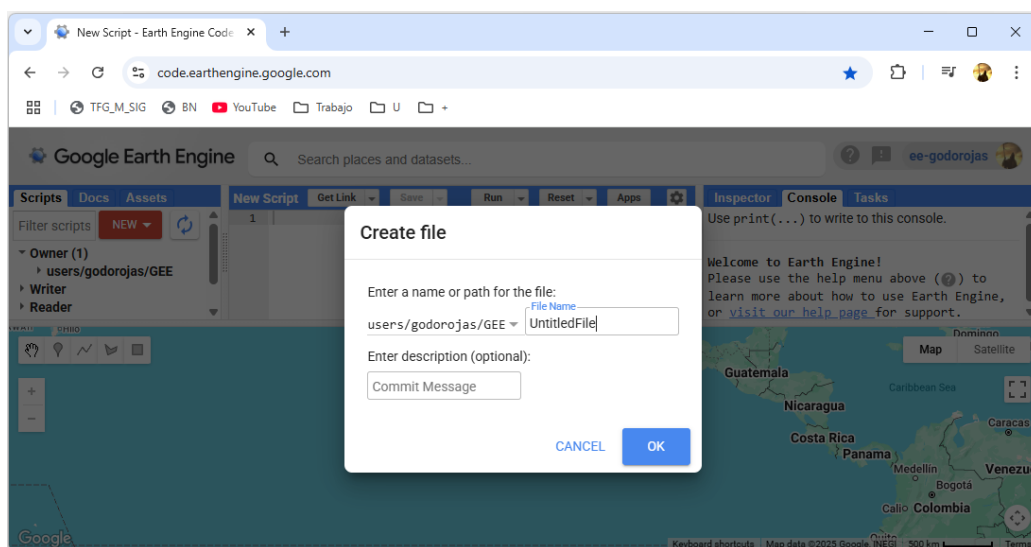
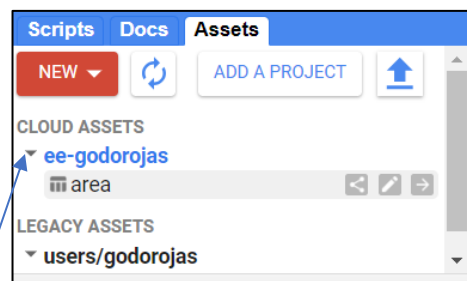
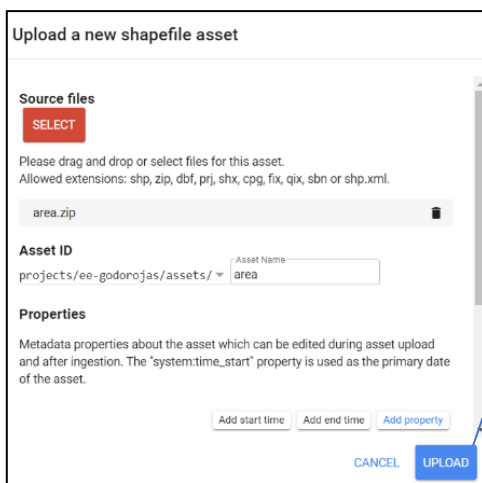
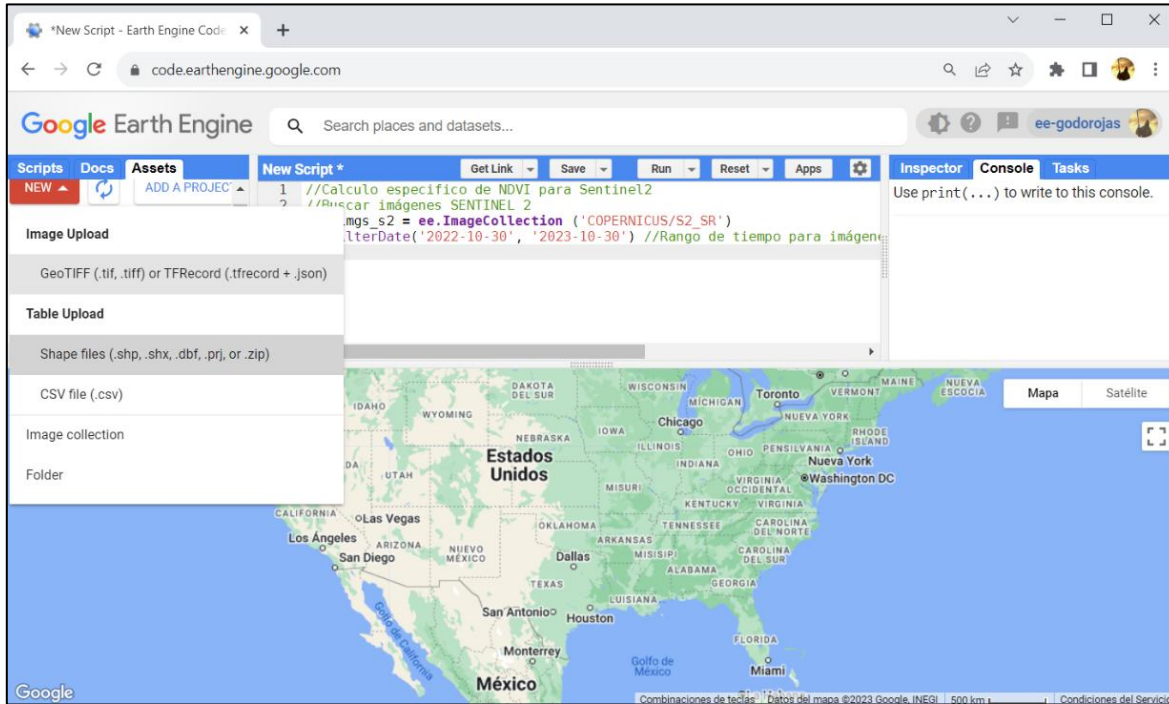


Figura 10. Creación del repositorio de trabajo

Fuente: Elaboración propia, 2024.

- Se definió la **Región de Interés (ROI)**: se delimitó el área geográfica específica sobre la cual se realizó el análisis. Esto se logró utilizando funciones como *ee.Geometry.Rectangle()* o importando una geometría desde un archivo GeoJSON o en un *Shapefile* comprimido en un archivo ZIP. Para el trabajo se utilizó esta última opción como se demuestra en la Figura 11 y como se explicó en el Anexo 1.



***Nota:** El archivo será subido en la nube de nuestro proyecto y se podrá utilizar en el momento que se requiera.

Figura 11. Carga de archivo a la plataforma GEE

Fuente: Elaboración propia, 2024.

- **Importación de Imágenes:** se seleccionó la fuente de datos satelitales adecuada según la resolución y las bandas espectrales necesarias para el análisis (Sentinel-2, Landsat, MODIS, entre otros). Se utilizó el comando ‘*var*’ para llamar los archivos y el comando ‘*ee.ImageCollection ()*’ para importar la librería de imágenes satelitales correspondientes a Sentinel-2 en un rango de 12 meses comprendiendo las fechas de enero del 2024 a enero del 2025.

4.6.2. Preprocesamiento de Imágenes:

- **Filtrado y Procesamiento:** se aplicaron filtros espaciales y temporales según los requisitos del estudio. En este caso se filtraron las imágenes basadas en fechas específicas (*filterDate()*) y límites geográficos (*filterBounds()*), esto con el fin de poder hacer un corte con el vector que se cargara del área de estudio y tener una temporalidad espacial muy reciente.
- **Visualización inicial:** se empleó el comando *Map.addLayer*, para poder visualizar las imágenes preseleccionadas y una combinación de bandas para ver en color natural mediante la línea: *bands: ['B4','B3','B2']*,

4.6.3. Análisis de Imágenes:

- **Cálculo de Índices Vegetativos:** para poder calcular el índice se utilizaron funciones como *normalizedDifference(['B8', 'B4'])* al aplicar las bandas espectrales adecuadas como también la utilización de la ecuación de NDVI. Como se visualiza en la Tabla 3 y se realiza el script para poder determinar los valores con la fórmula de NDVI.

Tabla 3. Valores utilizados para el cálculo del NDVI utilizando imágenes Sentinel-2

Banda	Descripción	Longitud de la onda central (µm)	Resolución (m)
B4	RED	0,665	10
B8	NIR	0,842	10

Fuente: Modificado de Urrego et al. (2020)

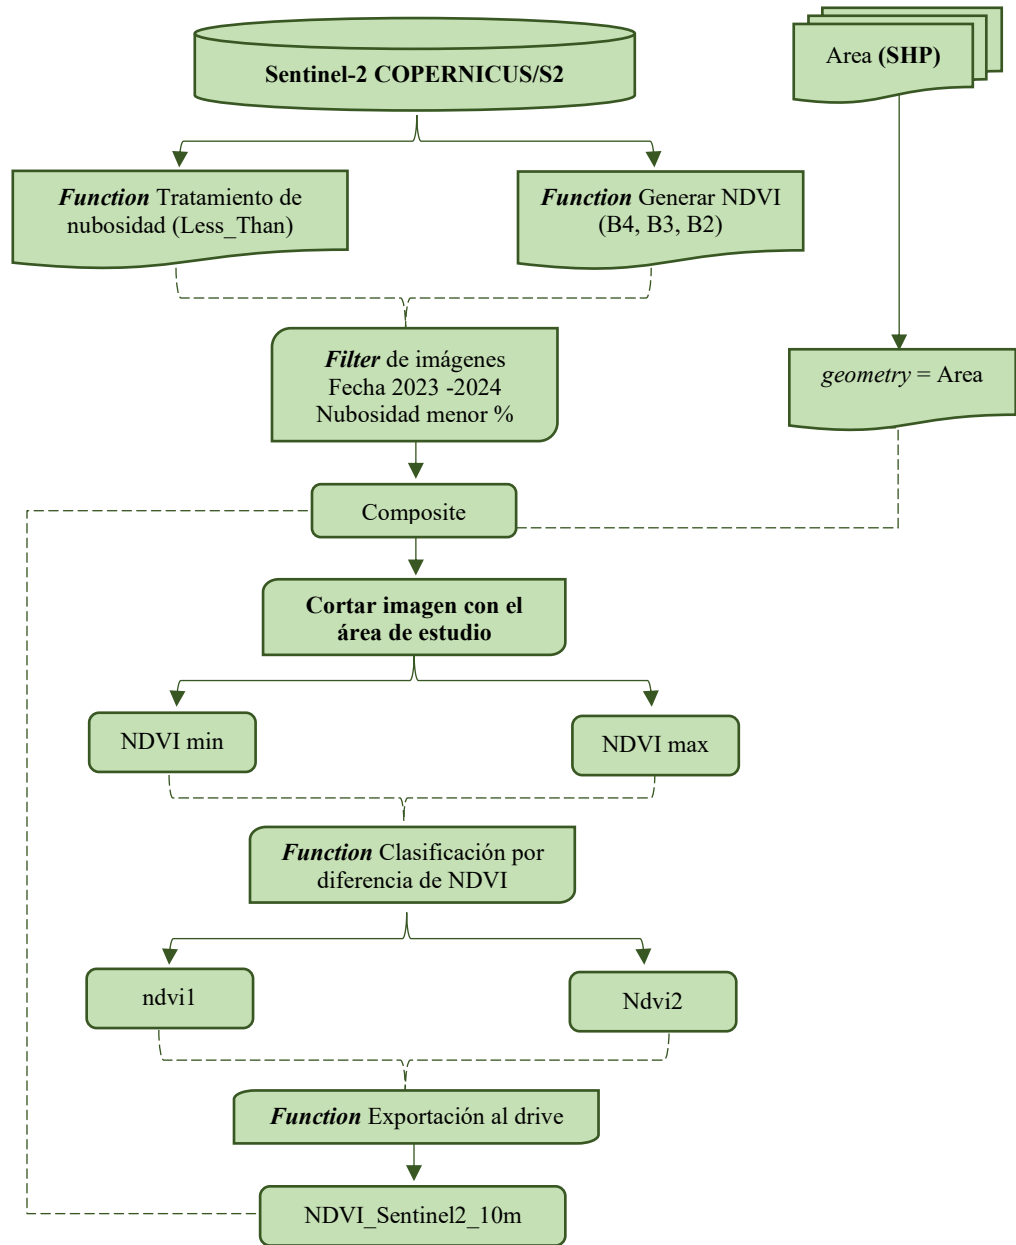


Figura 12. Diagrama de flujo para determinar el NDVI

Fuente: Elaboración propia, 2024.

Como se muestra en la Figura 12, se realizaron dos filtrados sobre la colección Sentinel-2: el primero, por un rango de fechas de un año y, el segundo, mediante un filtro por nubosidad al seleccionar las imágenes con el menor porcentaje de cobertura de nubes. A estas imágenes se les aplicaron funciones de enmascaramiento y se generó el índice NDVI, almacenado en una variable denominada “*Composite*”.

- Clasificación Supervisada:** se utilizó un conjunto de datos de entrenamiento etiquetado para entrenar un clasificador supervisado, mediante el algoritmo `ee.Classifier.libsvm().train`. (Figura 13). Este clasificador fue entrenado con muestras de distintas categorías de cobertura del suelo (por ejemplo, cultivos, bosques, cuerpos de agua) previamente etiquetadas. Se empleó el algoritmo SVM (*Support Vector Machine*), ampliamente reconocido por su eficacia en tareas de clasificación y regresión (Imran-Hossain, 2022).

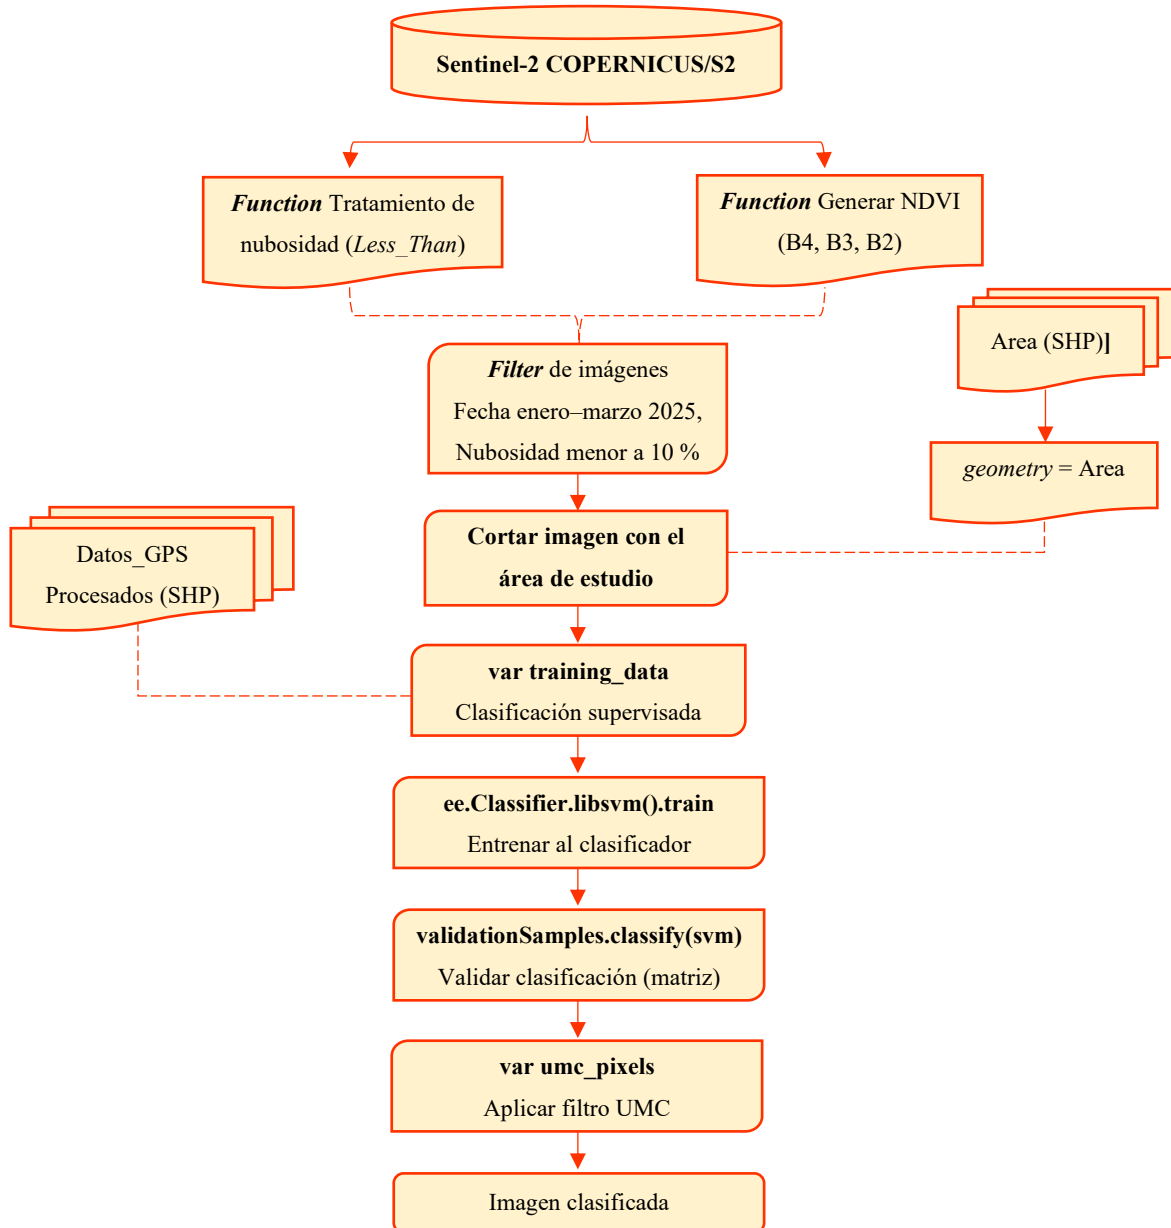


Figura 13. Diagrama de flujo para la clasificación supervisada

Fuente: Elaboración propia, 2024.

Se aplicaron filtros temporales y de nubosidad a imágenes Sentinel-2 (enero-marzo 2025, <10 % nubes) para generar una composición representativa. Las muestras de entrenamiento fueron depuradas mediante la conversión controlada de etiquetas a valores numéricos y la exclusión de registros inválidos. El conjunto se dividió en 70 % para entrenamiento y 30 % para validación. La precisión del modelo se evaluó mediante matriz de confusión, obteniendo métricas como exactitud global, precisión del usuario y del producto.

Además para garantizar la confiabilidad espacial del producto cartográfico resultante, se definió la Unidad Mínima de Cartografía (UMC) considerando la resolución espacial de las imágenes Sentinel-2 y las características de los datos de muestreo. Dado que cada punto de muestreo corresponde a un píxel individual de Sentinel-2 con una resolución de 10 metros por 10 metros (área de 100 m²) se estableció que la UMC mínima corresponde a un área formada por al menos 9 píxeles conectados equivalente a 900 m² o 0.09 hectáreas.

Esta decisión responde a la necesidad de reducir la presencia de ruido y artefactos en la clasificación final, lo cual evita que objetos demasiado pequeños (menores a la UMC) sean considerados como unidades cartográficas válidas. Para implementar esta restricción, se aplicó un filtro espacial post-clasificación que excluye aquellas regiones clasificadas cuya extensión sea menor a nueve píxeles contiguos con la misma clase temática.

- **Clasificación No Supervisada:** se aplicaron algoritmos de agrupamiento con enfoque en el análisis de datos y aprendizaje automático, utilizados para agrupar observaciones sin requerir etiquetas o categorías predefinidas. A diferencia de la clasificación supervisada en la cual el modelo se entrena con ejemplos previamente etiquetados, en la clasificación no supervisada el algoritmo identificó patrones y estructuras inherentes en los datos al agrupar los elementos en diferentes clústeres según su similitud espectral.

En este caso de estudio, se utilizó el algoritmo *K-Means* uno de los métodos de *clustering* más ampliamente implementado. Este funcionó dividiendo el conjunto de datos en $K = 6$ clústeres, valor que fue determinado previamente con base en

el conocimiento del área de estudio. El algoritmo asignó de forma iterativa cada muestra al clúster más cercano en función de la distancia al centroide y recalculó los centroides como el promedio de las muestras asignadas. Este proceso se repitió hasta alcanzar la convergencia, es decir, hasta que los centroides dejaron de cambiar significativamente.

Aunque el algoritmo *K-Means* puede ser sensible a las condiciones iniciales de los centroides, en esta implementación (mediante *ee.Clusterer.wekaKMeans()* en GEE) las iteraciones y reinicializaciones fueron gestionadas internamente por la plataforma sin posibilidad de modificación explícita. No se realizaron pruebas con distintos valores de K ni reagrupamiento posterior de clases. Además, para el resultado final se utilizó la misma UMC de la clasificación supervisada para visualizar y exportar este insumo.

En el marco del análisis de cobertura y uso del suelo, se consideró fundamental aplicar tanto la clasificación supervisada como la no supervisada para aprovechar sus características complementarias. Según Esri, Inc. (2021), la principal diferencia entre ambos enfoques radica en que la clasificación supervisada se basa en firmas espectrales previamente conocidas, extraídas de muestras etiquetadas, mientras que la clasificación no supervisada agrupa automáticamente los datos en clases espectrales sin intervención directa del analista. Por su parte, GISGeography (2024) destaca que aunque la clasificación no supervisada es útil en contextos exploratorios o sin información previa, la clasificación supervisada tiende a ser más precisa cuando se dispone de datos de campo o conocimientos previos del área, como ocurre en esta investigación. Dado lo anterior, se implementaron ambas metodologías con el fin de contrastar resultados, reforzar la validez del análisis y maximizar la utilidad de los productos cartográficos generados. Antes de detallar el procedimiento específico de cada clasificación, se presentan en la siguiente tabla comparativa que sintetiza los aspectos metodológicos clave de cada técnica y justifica su inclusión en el diseño metodológico de esta investigación.

Tabla 4. Diferencia entre Supervisada y No Supervisada

<i>Aspecto</i>	Clasificación Supervisada	Clasificación No Supervisada
Definición	Basada en muestras conocidas de referencia	Basada en agrupamiento automático de píxeles
Datos de entrenamiento	Requiere muestras etiquetadas	No requiere datos previos
Proceso	Entrenamiento del clasificador con datos conocidos	Agrupación de píxeles según similitud espectral
Intervención del usuario	Alta: selección manual de muestras	Mínima: solo se define el número de clústeres
Conocimiento previo	Necesario para definir clases	No es necesario
Precisión	Generalmente más alta	Puede ser menor
Uso ideal	Para identificar clases específicas	Para análisis exploratorio
Flexibilidad	Menos flexible: clases predefinidas	Más flexible: clases emergen del análisis
Complejidad	Más compleja por el proceso de entrenamiento	Más simple: no requiere entrenamiento

Fuente: Modificada de GISGeography (2024)

4.6.4. Visualización e Interpretación de Resultados:

- **Visualización en Mapas Interactivos:** se utilizaron funciones como *Map.addLayer()* para añadir capas de imágenes procesadas y resultados de análisis al visor de mapas de GEE, lo cual permitió visualizar el NDVI, la clasificación de cobertura del suelo, entre otros productos generados.

4.6.5. Exportación de Resultados:

- **Exportación de Imágenes:** se exportaron las imágenes procesadas en formato .TIFF y los resultados de análisis a Google Drive o Google Cloud Storage mediante la función *Export.image.toDrive()*. Esta exportación facilitó el uso posterior de los datos fuera de la plataforma GEE, en un software SIG.

4.7. Análisis Espacial de los Patrones y Tendencias de los datos obtenidos

4.7.1. Cartografía y Análisis Espacial Integrado:

Con los productos espaciales elaborados, se recopiló y presentó la información geoespacial relacionada con los enfoques de clasificación (supervisada y no supervisada), así como el índice de vegetación NDVI generado en formato .TIFF. Estos datos ráster fueron integrados en QGIS para el desarrollo de mapas temáticos que mostraron la distribución de la cobertura del suelo y el estado de los cultivos.

- **Análisis del mapa de NDVI:** se desarrolló cartografía con base en el archivo ráster del NDVI incluyendo la ubicación de la zona de estudio. A partir de ello, se analizó el estado de los cultivos al seleccionar tres sitios específicos por su comportamiento territorial, su distribución espacial y su relevancia en el análisis.
- **Mapeo según clasificación supervisada y no supervisada:** tal como menciona Ayala-Izurieta et al. (2017) la capacidad de mapear remotamente la cubierta vegetal de los geosistemas permitió realizar análisis ambientales que no pueden desarrollarse fácilmente en el campo. De esta manera, la visualización de los cambios según cada método empleado brindó una mejor perspectiva para formular una propuesta de ordenamiento territorial más alineada con la gestión sostenible.
- **Aplicación de índices de autocorrelación espacial y de patrones espaciales:** para profundizar en el análisis espacial de los datos derivados de GEE, se recurrió al uso de técnicas de autocorrelación espacial con el objetivo de evaluar la distribución y relación entre los valores del índice de vegetación (NDVI) en el espacio geográfico. La autocorrelación espacial permite identificar patrones de agrupación o dispersión no evidentes mediante una simple visualización y proporcionar así un respaldo estadístico al análisis espacial.

En este estudio, se aplicaron dos de los índices más reconocidos en el campo de la estadística espacial: el Índice Global de Moran (Moran's I) y el Índice Local de Getis-Ord G_i^* . El Índice Global de Moran, según lo describe Hidalgo Bucheli (2019), permitió cuantificar la autocorrelación espacial global, es decir, evaluar

si los valores de NDVI en áreas cercanas presentaban una distribución aleatoria, agrupada o dispersa en toda la región de estudio. Por su parte, el Índice Getis-Ord G_i^* , según la explicación de Siabato y Guzmán-Manrique (2019), facilitó la identificación de clústeres espaciales significativos mediante la detección de puntos calientes (*hotspots*), zonas con valores significativamente altos; y puntos fríos (*coldspots*), zonas con valores bajos al proporcionar una lectura más localizada del comportamiento del NDVI (AMDGS, 2020).

Es importante destacar que la aplicación de estos índices se realizó en el software QGIS para aprovechar las funcionalidades nativas del sistema, ya que ambos se encuentran disponibles en el módulo de Herramientas de Estadísticas Espaciales sin necesidad de instalar complementos externos o *plug-ins* adicionales. Este enfoque permitió garantizar la trazabilidad, transparencia y replicabilidad del análisis al facilitar su implementación por otros usuarios en entornos SIG estándar. El proceso que se realizó siguiendo estos pasos:

- Se prepararon los datos en la misma proyección (CRTM05) donde se incluye el archivo vectorial de distritos y el ráster del NDVI.
- Se generaron estadísticas zonales por distrito a partir del NDVI con el objetivo de determinar el valor promedio por unidad administrativa.
- La tabla generada se une con el archivo *Shapefile* de distritos.
- Con estos datos integrados, se calculó el Índice de Moran Global (*Global Moran's I*) como se presenta en la figura 14.

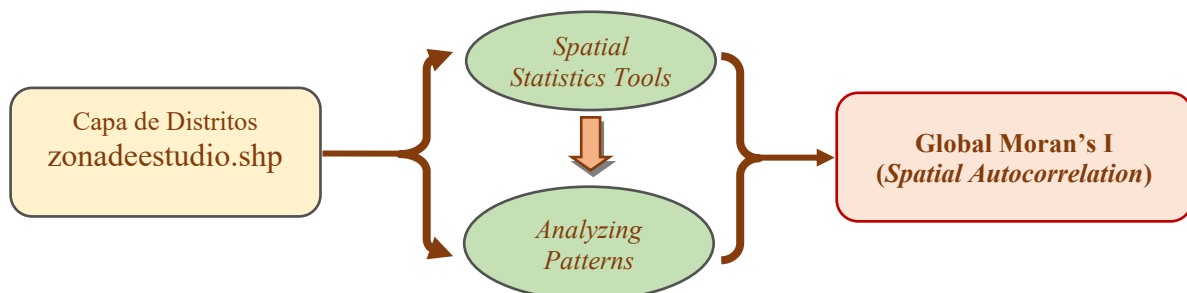


Figura 14. Diagrama de flujo Índice de Moran Global

Para obtener los resultados esperados, se configuraron los siguientes parámetros: archivo de entrada con la columna del promedio de NDVI, conceptualización de relaciones espaciales

basada en distancia inversa, método de distancia euclidiana y estandarización por fila. Además, se activó la opción de generar reporte de salida.

- Posteriormente se calculó del Índice de Moran Local (*Local Moran's I* o LISA) como se muestra en la Figura 15.

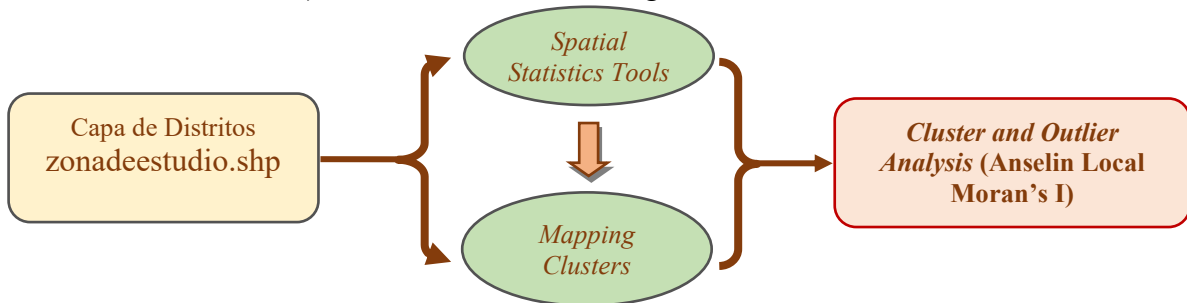


Figura 15. Diagrama de flujo Índice de Moran Local

Los parámetros utilizados para este índice incluyeron el archivo de distritos, la selección del lugar y nombre del archivo de salida y la misma configuración aplicada en el índice global. Si bien se podrían haber utilizado métodos de contigüidad (*Contiguity (Rook o Queen)*), en la conceptualización de relaciones espaciales, se optó por mantener los mismos parámetros con el fin de homogenizar los procesos y permitir comparaciones.

- Finalmente, se calculó del Índice Getis-Ord G_i^* (*Hotspot Analysis*) como se presenta en la Figura 16.

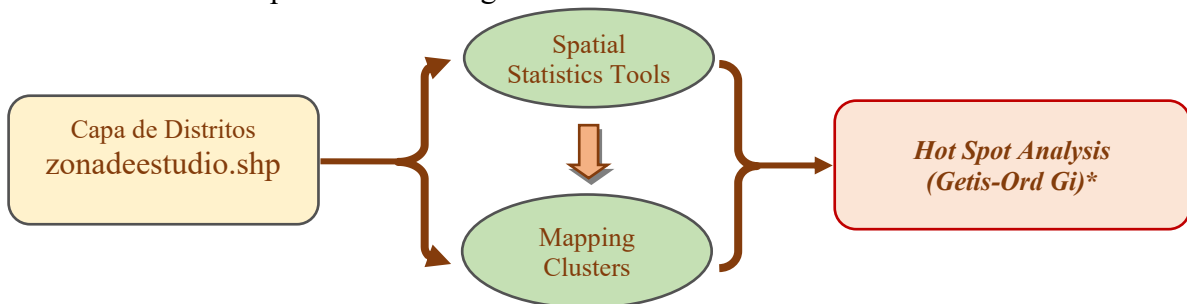


Figura 16. Diagrama de flujo Índice de Getis-Ord G_i^*

Para este índice, se configuraron los siguientes parámetros: archivo de entrada con la columna de promedio del NDVI, selección de la ubicación del archivo de salida, conceptualización espacial basada en distancia inversa, método de distancia euclidiana y estandarización por defecto.

4.7.2. Evaluación y Diagnóstico de la Fragmentación:

La fragmentación territorial obedece tanto a barreras físicas del relieve como a un crecimiento urbano desordenado y a la escasa conectividad entre unidades poblacionales (Treminio Sánchez, 2018). A ello se suma la reestructuración territorial impulsada por la globalización y el cambio en el paradigma socioprodutivo, lo cual ha alterado las dinámicas espaciales y profundizado el desequilibrio urbano-rural (Ávila-Sánchez, 2019; Lazarte Reátegui y Peña Corahua, 2023). En este contexto, la teledetección se convierte en una herramienta clave para analizar las interacciones entre sistemas sociales y ecológicos (Aly et al., 2016). Por ello, a partir de mapas generados con clasificación supervisada, se realizó una evaluación detallada para diagnosticar los factores que inciden en la degradación de tierras agrícolas y en la dinámica territorial del área de estudio.

Evaluación de la Fragmentación del Paisaje

Para este componente, se utilizó la capa ráster generada a partir de la clasificación supervisada de cobertura del suelo. El análisis se centró en cuantificar la superficie agrícola y su fragmentación a escala distrital. Se aplicaron herramientas como:

- Estadísticas zonales (*Zonal Statistics*) para calcular valores promedio del NDVI por zona administrativa, lo cual permitió evaluar la variabilidad en la salud de la vegetación.
- Tabla de áreas por categoría

Raster Layer → *Zonal Histogram* o “*Tabulate Area*”
usando *Processing Toolbox*

Para determinar la proporción de uso agrícola frente a otras coberturas en cada distrito o polígono administrativo.

Este análisis permitió identificar patrones de fragmentación del paisaje agrícola, especialmente, en distritos donde se observó una reducción significativa en el tamaño y continuidad de las parcelas agrícolas.

Diagnóstico de Áreas de Conflicto

El diagnóstico de zonas de conflicto se desarrolló mediante la integración de análisis espacial y estadística zonal con el uso principalmente de herramientas nativas de QGIS. El procedimiento incluyó:

1. Aplicación de la herramienta *Zonal Statistics* sobre el ráster NDVI para identificar distritos con bajos niveles de vigor vegetal.
2. Extracción del uso agrícola de la cobertura y generación de mapa temático de presión urbana sobre áreas productivas mediante la superposición de la capa de uso del suelo y expansión urbana reciente para lograr se utilizó la capa oficial de edificaciones del SNIT.

Este enfoque permitió identificar con precisión las zonas donde la expansión urbana presiona el suelo agrícola, lo que facilita propuestas de gestión territorial más focalizadas. El uso de QGIS y datos satelitales multitemporales ofrece una base sólida para evaluar los impactos de la urbanización no planificada en áreas agrícolas productivas.

4.7.3. Propuestas de Ordenamiento y Gestión Territorial

- **Interpretación Geográfica Contextualizada:** se analizó los resultados en función del contexto regional, identificando patrones de uso y correlacionándolos con la salud de los cultivos y las zonas de alta productividad agrícola en relación con la expansión urbana para identificar áreas prioritarias de intervención. Además, este insumo servirá de diagnóstico donde se consideren las estrategias propuestas para equilibrar la expansión urbana con la preservación de la capacidad productiva del territorio y garantizar un uso racional del suelo al realizar una correcta planificación territorial.

5. RESULTADOS Y DISCUSIÓN

En esta sección, se detallan los descubrimientos obtenidos durante el estudio geoespacial efectuado en el sector norte de Cartago, Costa Rica, una región valorada por su importancia en la agricultura, su riqueza en biodiversidad y su vulnerabilidad a cambios socioambientales. El estudio se estructuró en tres ejes fundamentales: la transformación en la cobertura del suelo, la condición de las tierras agrícolas por el estado de los cultivos a través del NDVI y la aplicación avanzada de tecnologías de teledetección mediante GEE para evaluar el territorio. A continuación, se detallan los resultados más importantes, integrando tanto metodologías como datos cuantitativos y cualitativos. Asimismo, la importancia de los códigos creados que se explican y se encuentran en los anexos para asegurar la transparencia y la replicabilidad.

5.1. Datos obtenidos utilizando GEE

Datos de referencia, puntos de muestreo en campo

A partir del análisis bibliográfico se determinaron 5 categorías que respetan las muestras necesarias para tener una confianza del 99 %. Además, se marcaron 2 categorías de consideración (nubes y cuerpos de agua) que influyen en el proceso de la clasificación supervisada. Se resumen en la siguiente tabla:

Tabla 5. Cantidades de muestra según categorías

Categorías	Muestras
Áreas urbanas	143
Bosques	253
Cuerpos de agua	35
Nubes	65
Pastizales	219
Suelo descubierto	127
Tierras agrícolas	208
TOTAL	1050

Fuente: Elaboración propia, 2025.

Para los datos de las nubes se realizó una fotointerpretación con la imagen Sentinel S2, esto con el fin de poder ingresar en la capa qué lugares presentan nubes para que a la hora de ejecutar el código no se alterara el producto final. Luego, en el caso de los cuerpos de agua se procedió a verificarlos en las giras de campo donde se pudo constatar cada característica de esta categoría donde entran desde flujos hídrico como ríos y quebradas hasta lagos naturales y artificiales. Al final del proceso, para generar los puntos de control, esto permitió cumplir con lo propuesto en la metodología y reducir significativamente el error esperado.




Figura 17. Porcentaje de las muestras según el área de estudio

Se utilizaron datos de campo adicionales en las 5 categorías principales, esto para mejorar el proceso de clasificación. Dicho procedimiento evidenció que las categorías de Bosques, Pastizales y Tierras agrícolas son fundamentales en los datos del muestreo y permiten clasificar un 65 % de la zona de la investigación, como lo muestra la Figura 17.

La incorporación de puntos de control adquiridos en campo, mediante el uso de GPS Trimble, ha favorecido la calibración y validación de las clasificaciones de cobertura realizadas en Google Earth Engine, de esta forma ayudando a incrementar la precisión temática en estas áreas heterogéneas de cobertura vegetal y/o pendientes muy pronunciadas. Estudios recientes realizados en zonas montañosas in situ proponen métodos de muestreo sistemático con utilización de rejillas hexagonales y purificación de los datos de entrenamiento para la

reducción del error en la clasificación, en especial en terrazas agrícolas y suelos diseminados (Liu et al., 2024).

Asimismo, nuevos métodos estadísticos como el de modelos bayesianos ha permitido tener una combinación de distintas interpretaciones entre observadores discretos por intentar en un segundo momento, mediante el contraste de las evaluaciones, reducir su variabilidad de las interpretaciones de los observadores entre sí, modularla para intentar así aumentar el grado de fiabilidad de los mapas temáticos, unas estrategias de contrastación como las descritas anteriormente, tal y como superaron el 85% de exactitud general dando señal de la robustez del método de campo (Tsutsumida y Kato, 2024).

Código para el Cálculo del NDVI

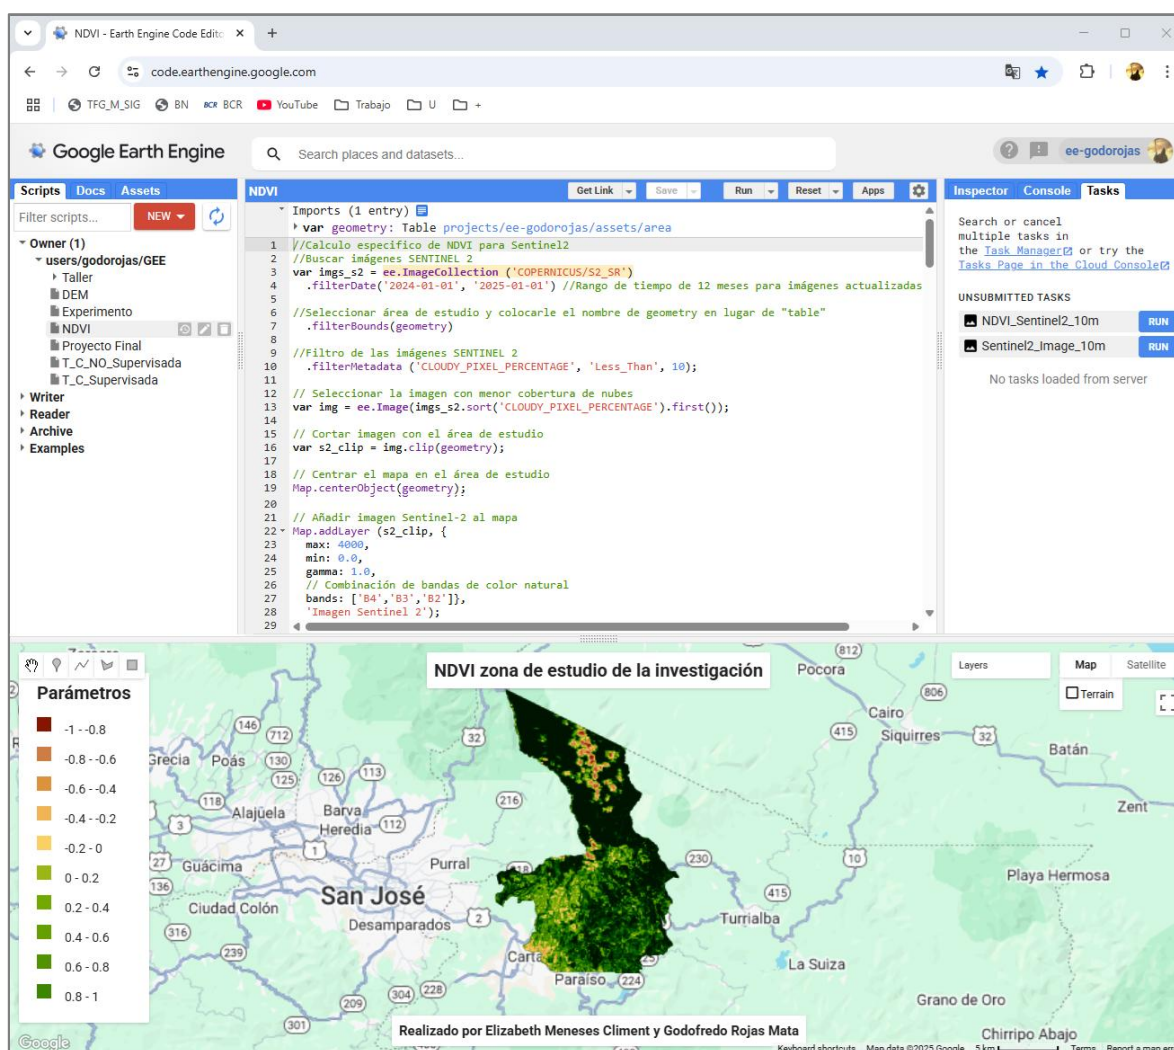


Figura 18. Aplicación del NDVI de la zona de estudio en GEE

- Se calculó el NDVI a partir de las bandas del infrarrojo cercano (NIR) y el rojo (RED) de imágenes Sentinel-2. A partir de la siguiente fórmula:

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)}$$

- El código para poder desarrollar el NDVI, aplicando la fórmula anterior, se encuentra en el Anexo 6 y se puede observar el resultado en GEE en la Figura 18.
- El resultado de la aplicación del código permitió la evaluación de la salud y la densidad de la vegetación con lo que se logra identificar áreas agrícolas productivas y zonas en proceso de degradación.
- Además, el ráster resultante se analizó en QGIS para utilizar índices y generar cartografía que se presentará en este apartado.

Código para la Clasificación Supervisada

- Se implementó un modelo de clasificación supervisada mediante SVM, entrenado con datos obtenidos en campo (5 categorías de cobertura del suelo, incluyendo tierras agrícolas, áreas urbanas, bosques, pastizales y suelo descubierto y se incluyó la categoría de cuerpos de agua y nubes) y validado con interpretación visual de imágenes Sentinel-2.
- Posteriormente, se descargó la imagen ráster de la clasificación supervisada para generar los productos cartográficos y el análisis de los datos en un SIG de escritorio.
- Un punto importante de analizar es que el mosaico se extrae según el área de estudio y el análisis automatizado de la clasificación, el cual dura un minuto. La utilización de la GEE para analizar áreas grandes o pequeñas reduce considerablemente los tiempos, como es el caso del estudio donde se tiene un área de 388.90 kilómetros cuadrados y que si este proceso se realizara en un SIG de escritorio dependería de la capacidad del equipo, licencias necesarias en caso de un software corporativo y podría durar un tiempo considerablemente mayor debido al análisis, la búsqueda y la adquisición de las imágenes para la implementación de las herramientas para procesar los datos.
- En el Anexo 6 se colocó el código completo y se puede observar el resultado en GEE en la Figura 19.

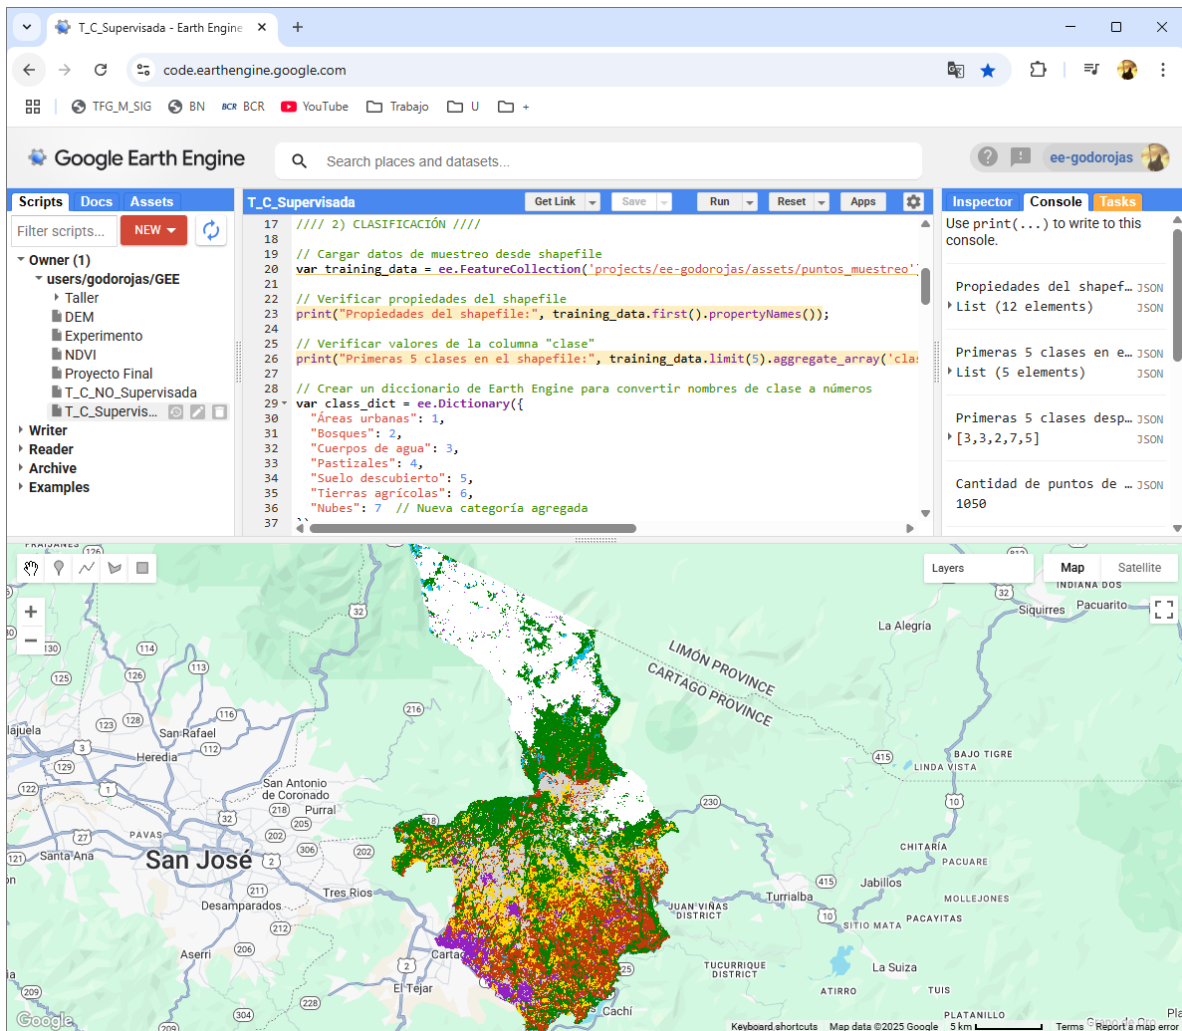


Figura 19. Clasificación supervisada para la zona de estudio

- Utilizar puntos muestreados en campo como base de entrenamiento de un modelo mejora la precisión de la clasificación y ofrece una buena base para entrenar a un modelo con un correcto nivel de generalización.
- El algoritmo SVM es robusto para realizar clasificadores con sets de datos de tamaño moderadamente grande, tal como el que hemos usado, y es menos sensible a la alta dimensionalidad que otros métodos.
- También podemos observar, en la figura 19 se muestra elevada diversidad espacial; la parte sur del área del estudio refleja que el uso de 7 categorías ha permitido una mejor clasificación dentro de la cual se puede determinar la ubicación de las tierras agrícolas y pastizales respecto al resto de categorías.

Código para la Clasificación No Supervisada

- Utilización del algoritmo *K-Means* basado en 6 clúster para detectar patrones emergentes sin intervención manual.
- En el Anexo 8 se colocó el código completo y se puede observar el resultado en GEE en la Figura 20.

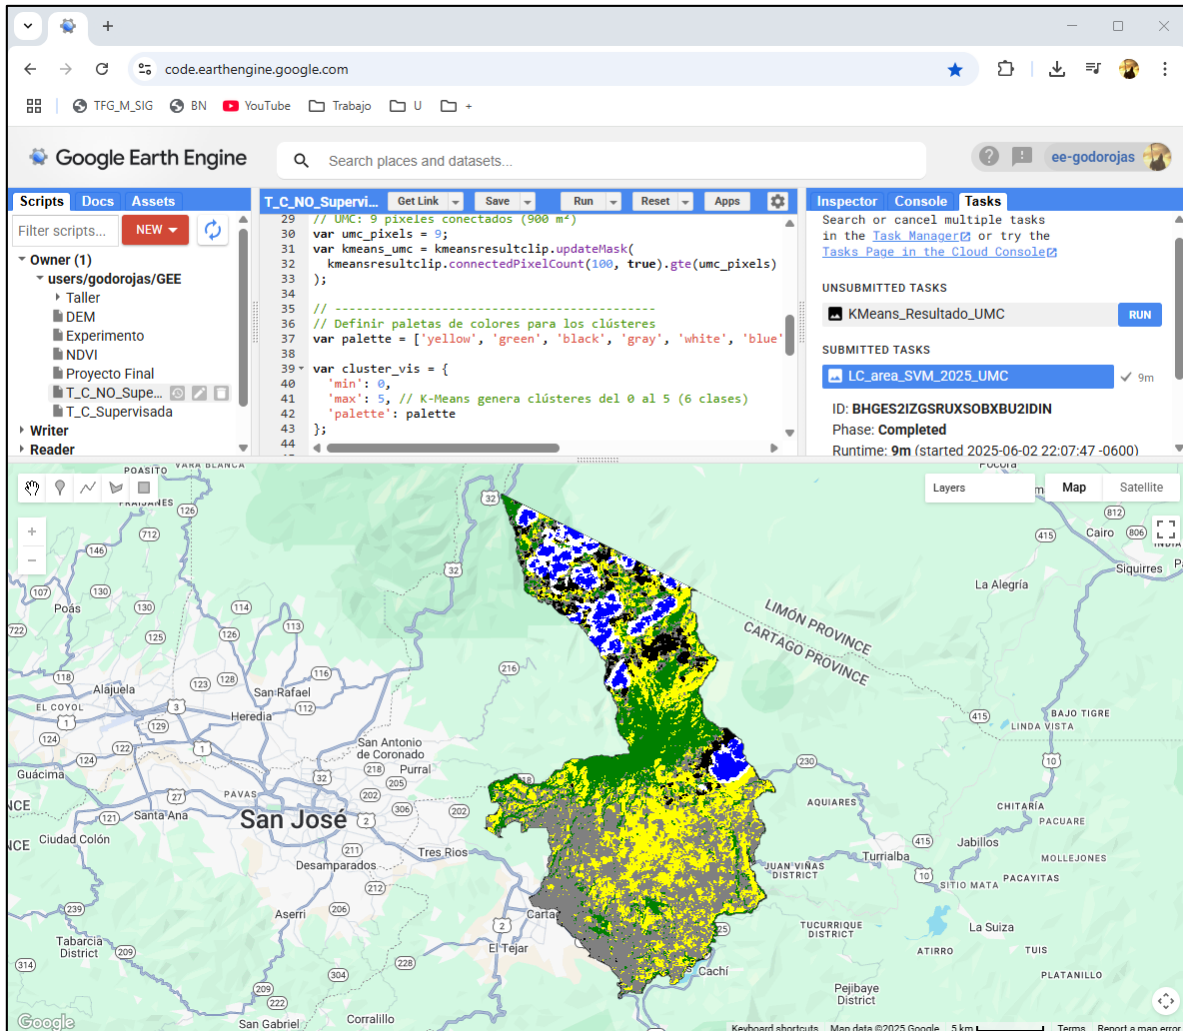


Figura 20. Clasificación No Supervisada para la zona de estudio

La Figura 20 se obtiene por medio de un proceso automatizado y sirve para un análisis preliminar del trabajo de campo y la clasificación supervisada, porque permite tener una noción visual de lo que se podría esperar en el proceso de clasificación. Además, esta representación gráfica facilita la identificación de patrones y tendencias en los datos, lo que contribuye a una mejor interpretación de los resultados.

5.2. Cartografía y Análisis Espacial Integrado a partir de los datos de GEE

Análisis del mapa de NDVI

El *script* desarrollado permitió visualizar los parámetros de los valores del NDVI calculado dentro del GEE y también descargar los datos en formato ráster. Dichos datos presentan los valores que van de -1 para zonas de vegetación poco vigorosa a 1 para aquellas áreas de mayor vigorosidad vegetal en concordancia con los parámetros NDVI establecidos en la metodología y como se visualiza en la Figura 21.


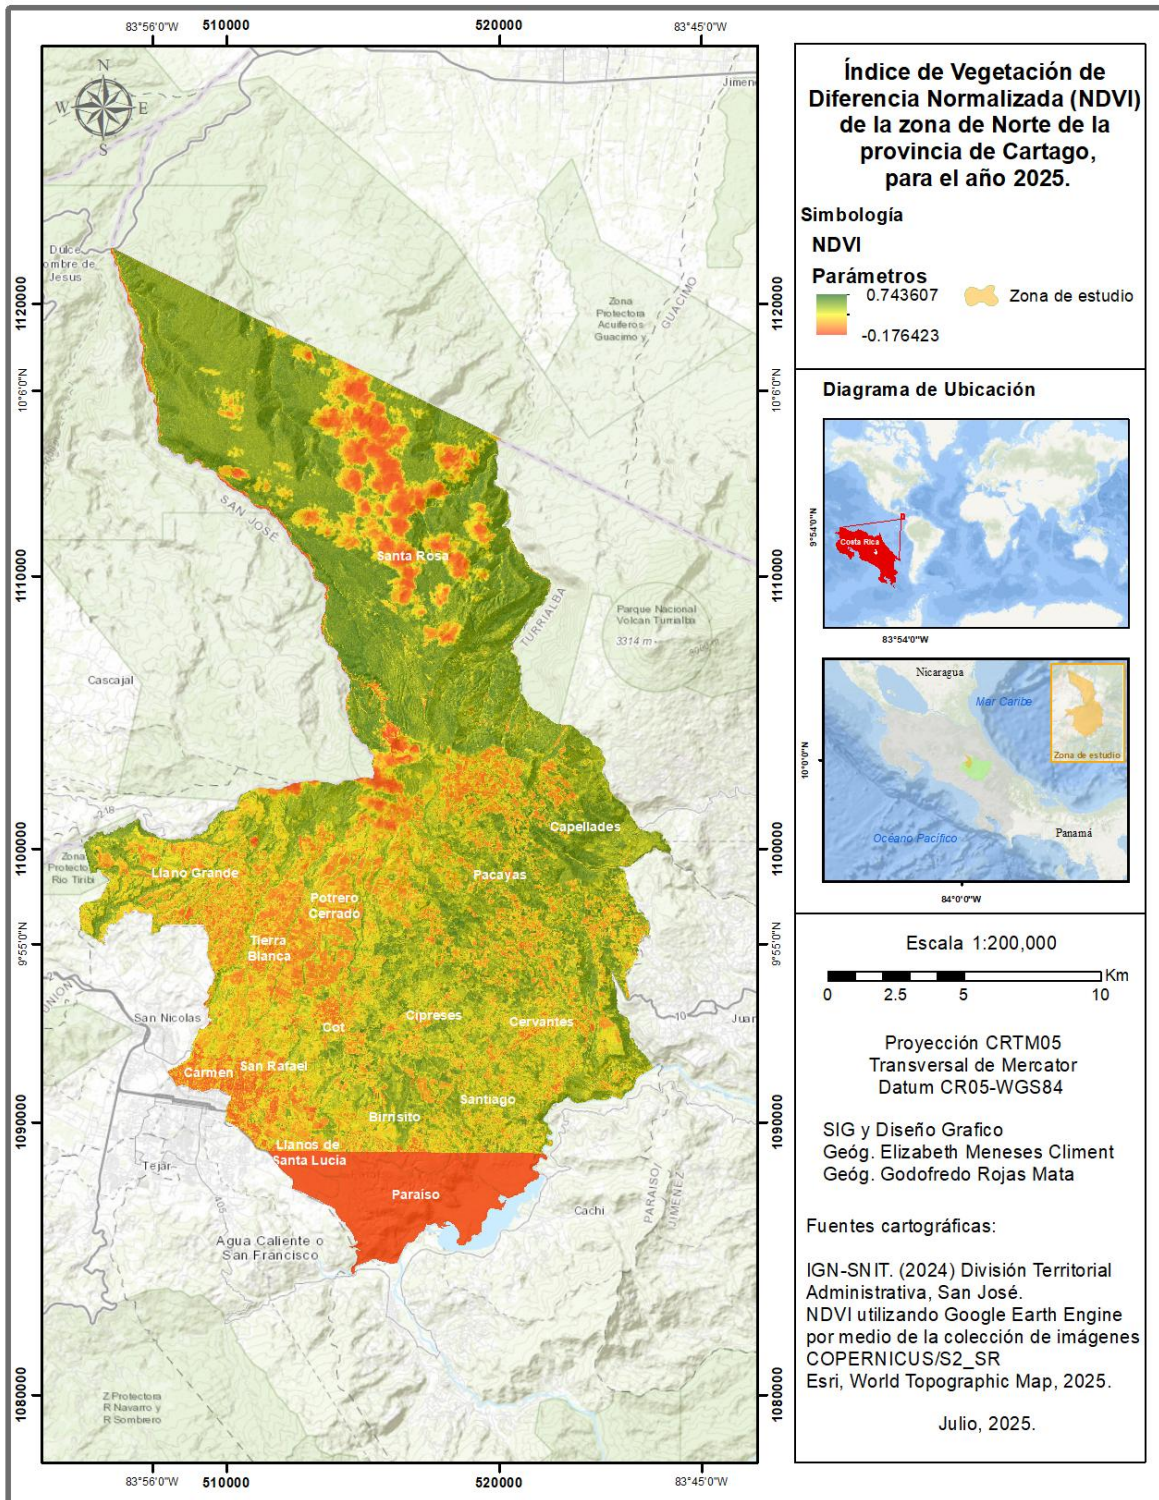


Figura 21. Parámetros NDVI con respecto al estado de los cultivos

Fuente: Modificado de Barrenechea (2020)



Mapa 2. NDVI de la zona de estudio

Fuente: Elaboración propia, 2025.

Con el ráster del NDVI se crearon productos cartográficos donde se tiene que los parámetros del estado de vegetación están dentro de los rangos mencionados, pues los valores obtenidos están de 0.743 a -0.176 (Mapa 2). Las zonas con valores que oscilan entre -0.176 a 0 son las que tienen presencia absoluta o parcial de nubes, pero también son zonas urbanas en el período seleccionado. Luego, los valores que van de 0.1 a 0.33 son áreas descubiertas o sin cultivos y de 0.331 a 0.66 son pastizales, cultivos y bosques. Los valores presentes en los últimos parámetros del en Mapa 2 son zonas con vegetación muy saludable y encontrándose muchos de estos parches en zonas protegidas donde no han tenido alteración y que las imágenes son de una época seca y de recolección de cultivos (marzo y abril del 2025). Asimismo, los parámetros reflejan un buen estado de la vegetación aunque no el valor óptimo por las circunstancias mencionadas.

Además, dentro del mapa podemos ver que la zona oeste presenta los valores más bajos debido a tres circunstancias: suelos descubiertos por la recolección de cultivos, zona más urbana que abarca centros de poblados como San Rafael, Cot, Tierra Blanca entre otros y el tercer factor es que en esta época del año se presentaron altas temperaturas como lo menciona Instituto Meteorológico Nacional de Costa Rica (IMN, 2024) que para el trimestre de febrero - abril 2025 se esperan temperaturas medias más cálida de lo normal en todas las regiones climáticas del país

Como se observa en el Mapa 2 para los distritos de Llanos de Santa Lucía, Birrisito, Paraíso y Santiago no se logró realizar el estudio del NDVI, ya que no se tiene acceso a las franjas de imágenes satelitales en esas áreas de estudio, dado que no se encuentran de forma gratuita para ese período específico del año ni para otro período cercano de toma de los datos. La colección COPERNICUS/S2_SR_HARMONIZED del *script* de GEE no tiene acceso a las bandas necesarias de esta franja de imágenes. Ahora bien, para los posteriores análisis se pudo utilizar una combinación reciente de imágenes del primer trimestre del 2025 que abarcan el 100 % de la zona de estudio que sí tenían las bandas necesarias para la clasificación supervisada y no supervisada, pero no tenía las bandas NIR disponibles.

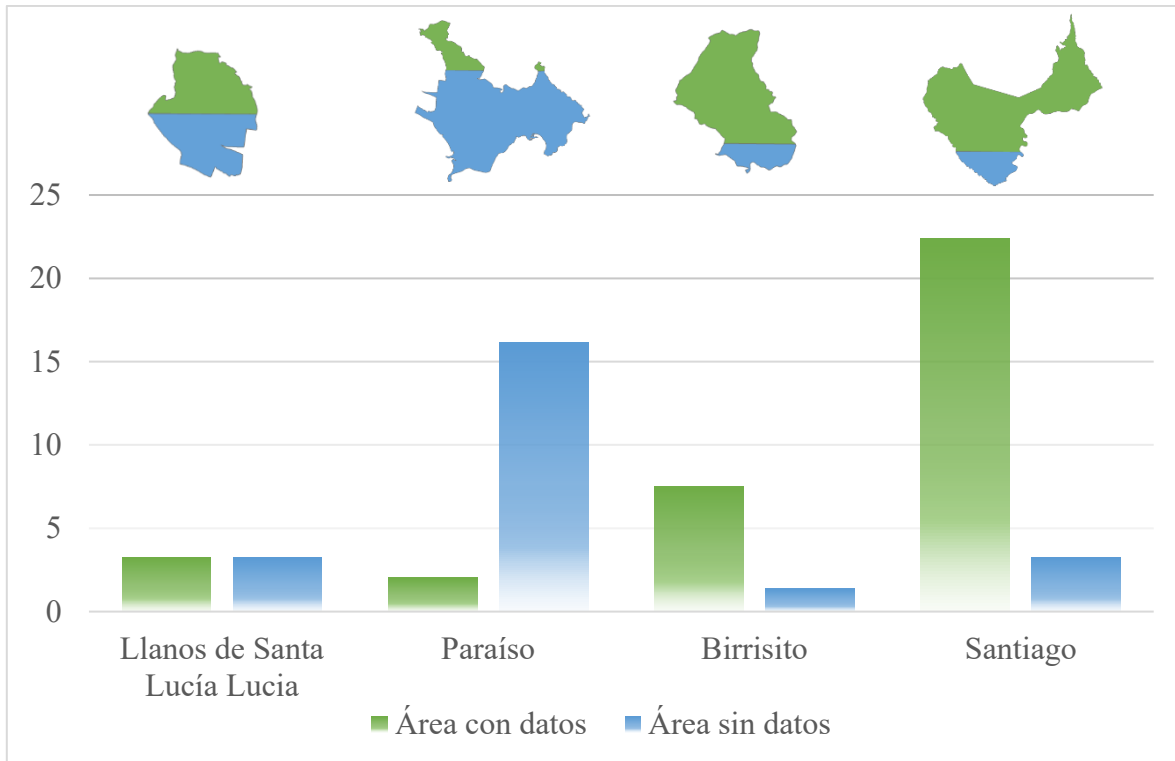
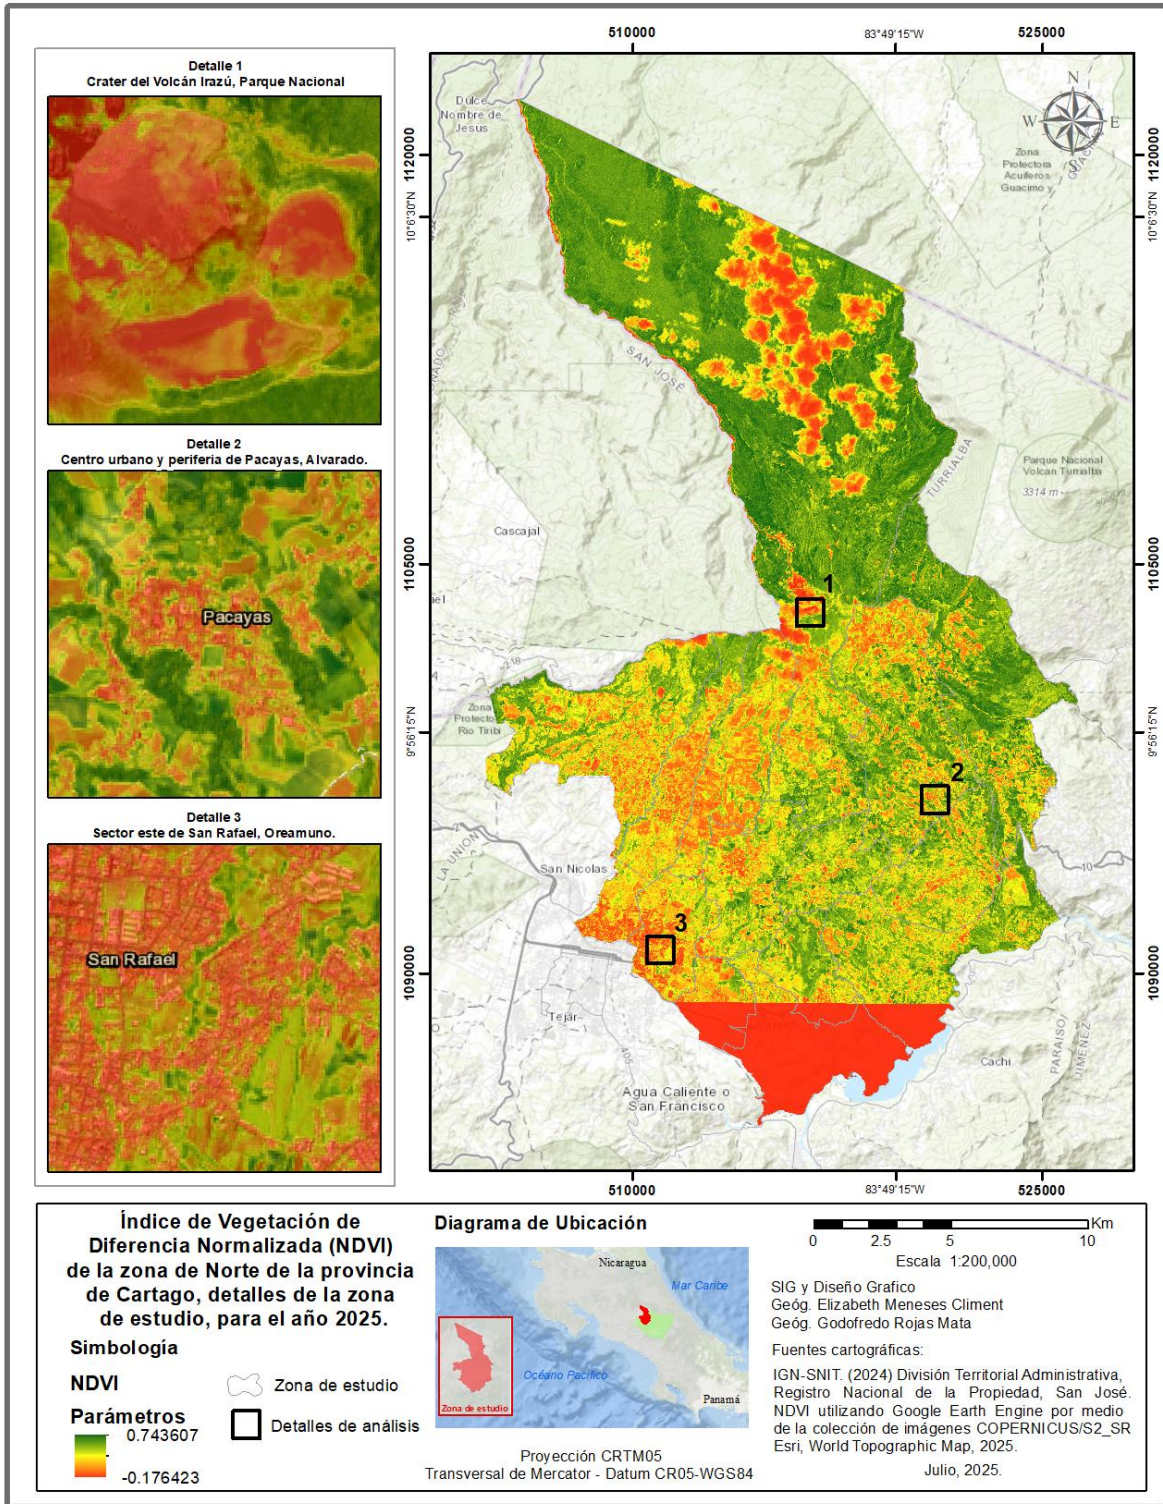


Figura 22. Área sin cobertura NDVI de los distritos al sur de la zona de estudio.

Para las áreas sin cobertura de imágenes se puede observar que el distrito con mayor área sin cobertura es Paraíso con un área de 16.16 km² que equivale a un 89 % de su territorio. El distrito de Llanos de Santa Lucía tiene un área de 3.26 km² que representa porcentualmente un 50 % sin cobertura para los distritos de Birrisito y Santiago que poseen las menores áreas sin cobertura. El primero un 3.37 km² y el segundo con 1.37 m² que equivale, respectivamente, a un 15 % y 13 %. (Figura 22).

Entre las áreas de los distritos mencionados que sí poseen acceso a las imágenes satelitales con una cobertura total de 35.16 km² se ubica el distrito con mayor cobertura de imagen, Santiago, con un área de 22.36 km² que representa 87 %. Seguidamente, Birrisito que posee un área de 7.50 km² con un 85 %. Seguido del distrito de Llanos de Santa Lucía con un área de 3.27 km² y un porcentaje de cobertura de 50 %. Finalmente, Paraíso con un área de 2.03 km² que equivale a un 11 %. De esta manera de estas zonas sí se obtuvieron datos de las imágenes satelitales para realizar los estudios respectivos de NDVI y clasificación supervisada y no supervisada.



Mapa 3. NDVI, detalles de la zona de estudio

Fuente: Elaboración propia, 2025.

Como se observa en el Mapa 3, se seleccionaron tres puntos estratégicos para el análisis NDVI con base en criterios territoriales y funcionales. El primero, corresponde a una zona cercana al Parque Nacional Volcán Irazú; el segundo, se ubica en una zona urbana consolidada dentro del área metropolitana (GAM) y; el tercero, en un entorno urbano-rural. Esta selección permite analizar distintos niveles de intervención humana: desde áreas naturales protegidas, zonas agrícolas activas, hasta sectores altamente urbanizados, considerando también los usos mixtos del suelo como la vivienda, el comercio y la agricultura. La diversidad de estos escenarios facilita una evaluación integral del comportamiento de la vegetación y la cobertura del suelo.

Adicionalmente, la distribución geográfica de los puntos responde a una lógica espacial: uno se localiza al norte del área de estudio (Volcán Irazú), otro al sur (San Rafael de Oreamuno) y el tercero al este (Pacayas). Dicha segmentación permite captar diferencias microclimáticas y altitudinales. San Rafael se ubica aproximadamente a 1453 msnm, Pacayas a 1735 msnm y el Volcán Irazú a 3432 msnm lo que implica la presencia de diferentes pisos altitudinales, zonas de vida, tipos de vegetación y condiciones del suelo. Estos factores, junto con las variaciones en la presión antrópica, hacen que los tres sectores ofrezcan contrastes significativos y complementarios para el análisis territorial.

Detalle 1. Cráter del Volcán Irazú

El área roja identificada en las imágenes NDVI corresponde al cráter del Volcán Irazú, uno de los volcanes más activos del país con actividad fumarólica constante durante todo el año debido a su altitud (3432 msnm). La zona presenta escasa cobertura vegetal que es afectada tanto por las condiciones edafológicas derivadas de la actividad volcánica como por el clima frío y húmedo. La influencia de los vientos alisios provenientes del Caribe mantiene la zona frecuentemente cubierta de nubes, lo cual induce un entorno húmedo incluso en la estación seca. La vegetación predominante es de tipo páramo subalpino caracterizada por especies de bajo porte y adaptadas a temperaturas que oscilan entre los 5 °C y 9 °C.

Además, en el flanco oeste del cráter se identifican zonas descubiertas asociadas a procesos de inestabilidad de laderas. Una de estas corresponde al Deslizamiento Activo del Río Sucio Oeste (DARSO) que es un fenómeno compuesto por desprendimientos traslacionales y flujos

de lodo y roca. Dicho desprendimiento es provocado por la ruptura de materiales volcánicos como cenizas, tobas y lavas, muchos de ellos alterados hidrotermalmente. Este deslizamiento representa una amenaza para las estructuras presentes en la zona, como las torres de telecomunicaciones. Cabe resaltar que dicho suceso fue identificado mediante la interpretación de imágenes satelitales en Google Earth.

Deslizamiento Activo Río Sucio Oeste (DARSO): Deslizamiento activo del tipo compuesto, que involucra desprendimientos traslacionales y flujos de lodo y rocas, el cual se ha desarrollado a través de rupturas retrogresivas de materiales de origen volcánico (cenizas, tobas, lavas), los cuales en ocasiones presentan una notoria alteración hidrotermal. Este deslizamiento se identificó como el único deslizamiento activo en el sector estudiado mediante la interpretación de imágenes satelitales de Google Earth, el mismo se desarrolla en la cabecera oeste del río Sucio y se le conoce como deslizamiento Las Torres. (Mora y Pirulli, 2017, p.52)

Detalle 2. Centro urbano y periferia de Pacayas

En este sector, las zonas en color rojo representan áreas urbanas y suelos descubiertos, mientras que los tonos verdes indican presencia de pastizales, parches de árboles y cultivos. Pacayas es una región predominantemente agrícola, dedicada al cultivo de papa, zanahoria, repollo, culantro y otras hortalizas, así como a la ganadería. En los márgenes de los ríos aún se conservan zonas vegetales que cumplen funciones ecológicas importantes. El casco urbano ha experimentado un crecimiento poblacional significativo, impulsado principalmente por el desarrollo agrícola y ganadero que ha dinamizado la economía local.

El patrón de urbanización se manifiesta de forma lineal y sigue las rutas principales como la 230 y otras vías cantonales hacia el norte y el oeste. En cuanto a los suelos descubiertos observados en las imágenes, estos corresponden a parcelas que han sido recientemente cosechadas y están en proceso de rotación agrícola, práctica fundamental para la conservación del suelo y la continuidad de la producción. La coexistencia de lo urbano con lo rural hace de Pacayas un entorno dinámico donde las presiones del crecimiento deben ser atendidas con estrategias de planificación sostenibles.

Detalle 3. Sector este de San Rafael, Oreamuno

Este sector presenta una alta densidad urbana que es visible por la extensión de las manchas rojas en el mapa. Su cercanía al centro de Cartago, así como la disponibilidad de servicios de salud, recreación y transporte han convertido a esta zona en un área atractiva para la expansión residencial. Sin embargo, esta urbanización ha dado lugar a un fenómeno de isla de calor urbana donde el predominio de superficies cementadas (calles, aceras, edificaciones) y la escasa cobertura vegetal contribuyen a la acumulación de calor, especialmente, perceptible durante la estación seca.

La cobertura vegetal en este sector es limitada, pues queda reducida a pequeños parches agrícolas y franjas de árboles ubicadas en los márgenes de los ríos. No se identifican parques ni zonas boscosas significativas que contribuyan a la regulación térmica o al bienestar urbano. En los distritos de Cot y Tierra Blanca, también al este, se observa una urbanización más planificada en el primer caso, aunque igualmente carente de espacios verdes. No obstante, su altitud favorece temperaturas más frescas debido a la influencia de los vientos del Caribe. Tierra Blanca, con una menor mancha urbana, conserva más zonas agrícolas y suelos descubiertos listos para el cultivo donde predomina la producción de cebolla, papa, zanahoria y otras legumbres.

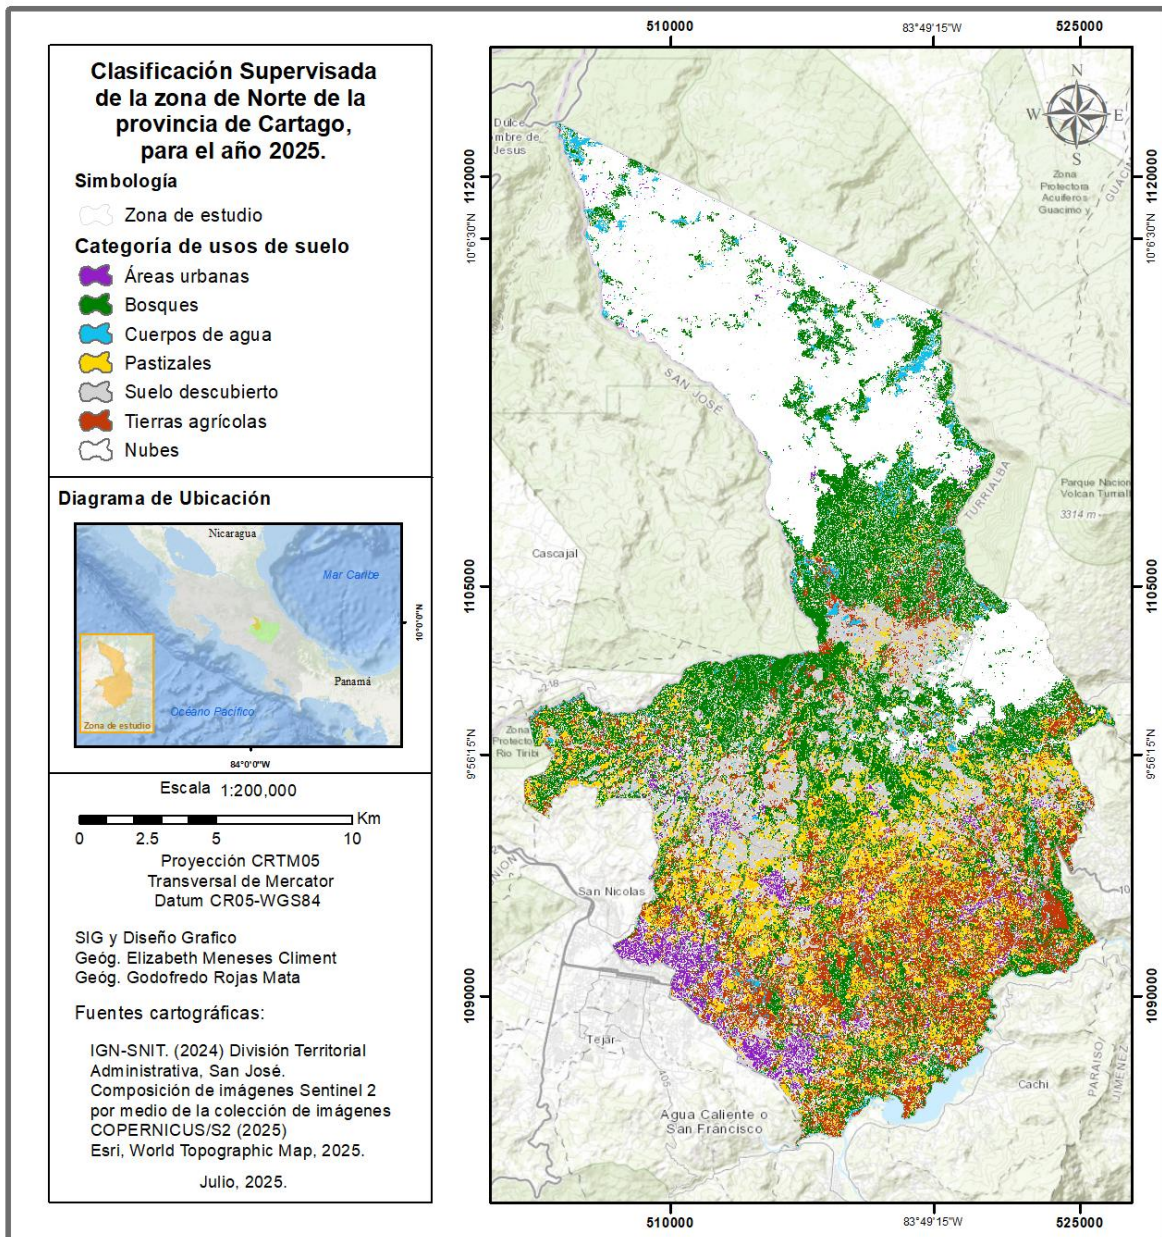
El uso del NDVI ha permitido identificar variaciones en la salud de los cultivos, especialmente en épocas secas y bajo presión urbanística. Estudios como el de Judith et al. (2025) han clasificado la salud de las plantas utilizando NDVI combinado con redes neuronales convolucionales (FCNN), logrando una tasa de error del 2.2%. Esta herramienta es valiosa para detectar estrés hídrico, plagas o pérdida de vigor en áreas tropicales, especialmente en zonas montañosas donde los cambios en la cobertura son más difíciles de monitorear (Roerink et al., 2003).

Además, también se debe tener en cuenta que el uso de NDVI no solo se puede aplicar a la detección de problemas relacionados con el estado de salud de los cultivos, sino también para la monitorización fenológica y el seguimiento de la productividad de los agroecosistemas (Yan et al., 2025), lo cual es clave para la gestión sostenible de los recursos agrícolas en la mejora de la toma de decisiones para la gestión de cultivos y la planificación agrícola.

Mapeo según clasificación supervisada y no supervisada

- *Clasificación Supervisada*

Este resultado permitió crear un diseño cartográfico que refleja con precisión las características de las clases de datos analizadas, organizando la información y facilitando su interpretación visual para mejorar la comunicación de los resultados obtenidos.



Mapa 4. Delimitación del área de investigación

Fuente: Elaboración propia, 2025.

La clasificación supervisada presentada en el Mapa 4 se basa en una metodología que combina información espectral de imágenes satelitales con un amplio conjunto de 1050 puntos de control en campo o referencias de alta precisión. Dichos puntos permiten calibrar y validar el modelo, minimizando la confusión entre las diferentes clases de la cobertura del suelo. El resultado cartográfico exhibe una zonificación detallada que distingue, al menos, las siguientes categorías principales:

1. **Áreas Urbanas:** donde se concentran en núcleos de población, infraestructura vial y construcciones que interrumpen la cobertura vegetal. Dichos sectores exhiben alta reflectancia en bandas que captan superficies impermeables (techos, pavimento) y contrastan fuertemente con la matriz rural circundante.
2. **Cultivos o Agrícolas:** que comprenden suelos intensamente explotados para cultivos (hortalizas, granos, frutales, etc.). Generalmente, aparecen en extensiones de menor pendiente o cercanas a vías de comunicación y asentamientos, y muestran patrones geométricos regulares. El uso de puntos de control en parcelas activas permitió asegurar una categorización confiable.
3. **Pastizales:** que incluyen áreas dedicadas al pastoreo y praderas con cubierta herbácea. Estos paisajes suelen presentar firmas espectrales homogéneas y transiciones difusas con otras clases, especialmente, en los límites con bosques secundarios o cultivos abandonados.
4. **Bosques:** representan las formaciones vegetales densas, tanto primarias como secundarias. Su alta heterogeneidad interna se capturó gracias a un muestreo amplio en zonas de dosel cerrado. Se revelan como extensiones compactas concentradas en terrenos con mayor pendiente o en áreas protegidas.
5. **Suelo Descubierta:** este abarca superficies con escasa o nula vegetación, como parcelas sin cultivos y áreas sin capa vegetal.

El uso de 1050 puntos de verificación permitió afinar la clasificación con alta precisión, reduciendo la confusión entre categorías con firmas espectrales similares (por ejemplo, cultivos de baja densidad y pastizales). Asimismo, la validación estadística (matrices de

confusión) confirma que la mayor parte de los píxeles se asignó correctamente, lo que proporciona confianza a la hora de utilizar este mapa como insumo en planes de ordenamiento territorial, gestión ambiental y monitoreo de cambios en la cubierta terrestre.

De esta manera con el archivo ráster resultante también se realizó la conversión a vector para determinar los kilómetros cuadrados de cada categoría. La simplificación de los vectores dio los siguientes resultados por categoría:

Tabla 6. Kilómetros cuadros por categoría de cobertura

Categorías	Área km2
<i>Áreas urbanas</i>	12.957
<i>Bosques</i>	102.558
<i>Cuerpos de agua</i>	12.630
<i>Nubes</i>	53.485
<i>Pastizales</i>	39.885
<i>Suelo descubierto</i>	59.805
<i>Tierras agrícolas</i>	108.389

Fuente: Elaboración propia, 2025.


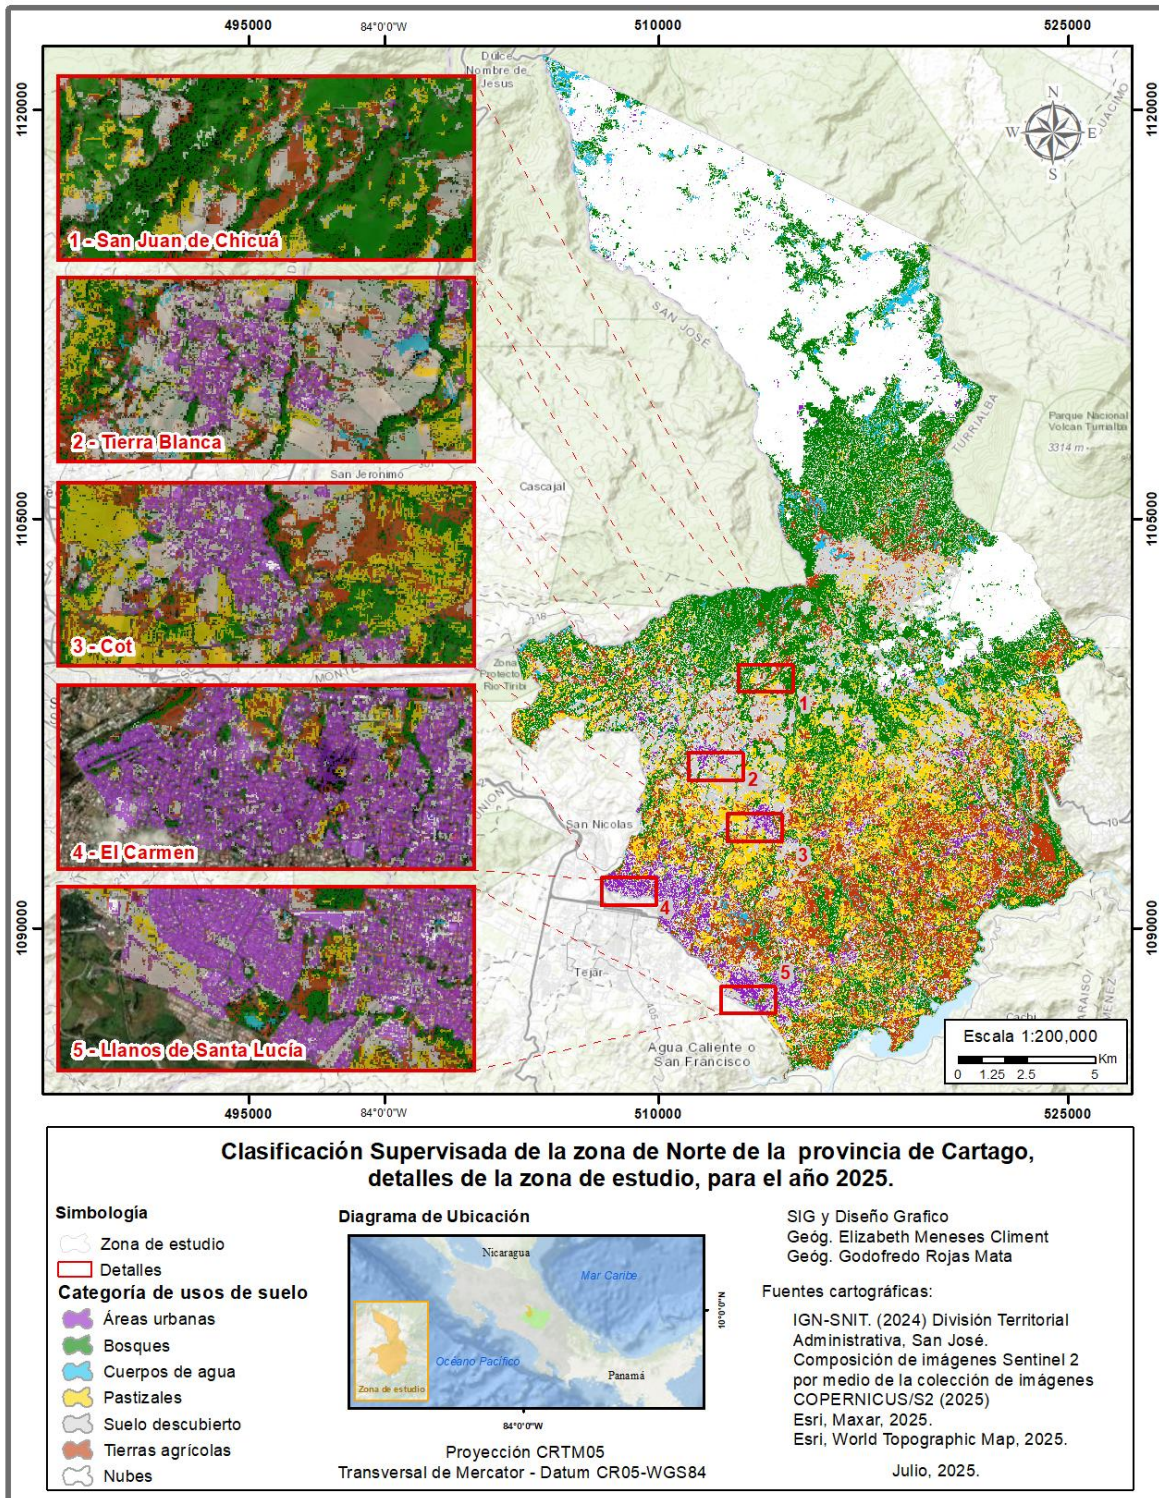


Figura 23. Porcentaje de las categorías según el área de estudio

Las zonas de pastizales y tierras agrícolas que son cruciales para la producción de alimentos, el sustento de las comunidades rurales y como se demuestra en la Figura 23, son las dos coberturas predominantes en la zona norte de Cartago que cada año aumenta el área urbana que actualmente es un 3 % de su territorio.



Mapa 5. Clasificación Supervisada detalles de la zona de estudio

Fuente: Elaboración propia, 2025.

El análisis del Mapa 5, se detalló cómo está la clasificación de la cobertura del suelo en las localidades de San Juan de Chicué, Tierra Blanca, Cot, El Carmen y Llanos de Santa Lucía con el propósito de evidenciar la desfragmentación de estas áreas en zonas agrícolas, áreas rurales y núcleos urbanos pequeños o medianos. La tierra más al norte de la zona de estudio presenta un relieve montañoso debido a la actividad volcánica antigua y además colinda con el Parque Nacional.

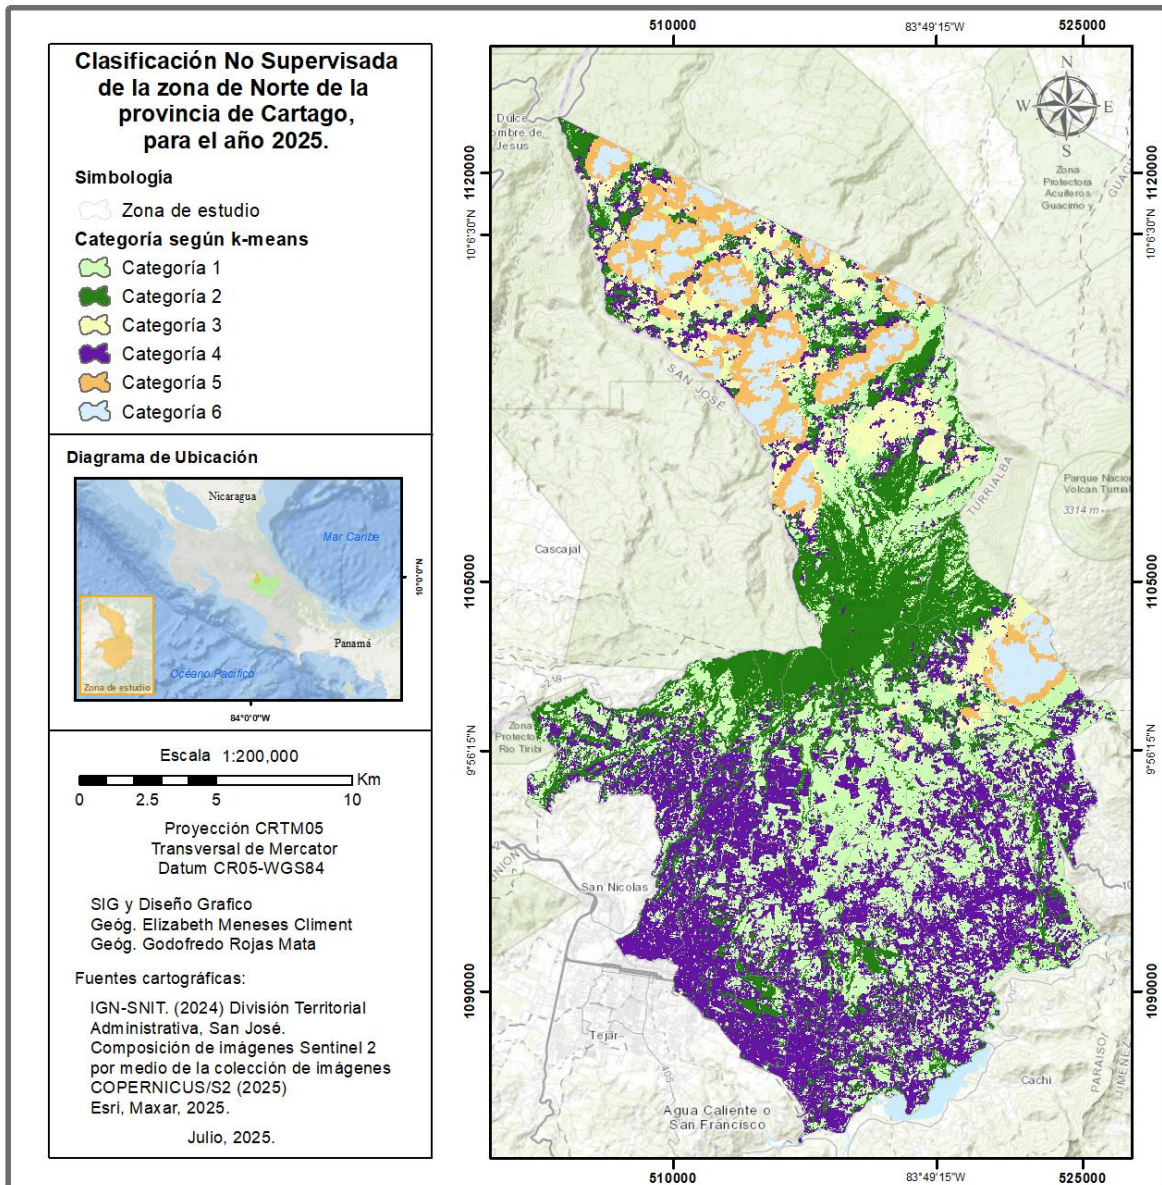
En la comunidad de San Juan de Chicué, las coberturas predominantes son las del uso agrícola con presencia de cultivos de hortalizas y granos básicos, esto se pudo comprobar en las visitas de campo. También, la transformación del territorio en esta comunidad ha provocado la aparición de un mosaico de pequeñas parcelas agrícolas y parches de vegetación secundaria. En el caso de Tierra Blanca, la producción es más intensiva, la mancha urbana no tiene homogeneidad creando una distribución sin planificación. En el caso de Cot, se identificaron sectores urbanos o semiurbanos más delimitados, alternados con áreas dedicadas a cultivos y en la clasificación supervisada pueden distinguirse contrastes claros entre la cobertura urbana y las parcelas agrícolas.

En caso de El Carmen está en la parte media-baja de la zona de estudio y empieza el cambio de usos, es decir, existe una transición entre agricultura intensiva y pastoreo a ser una zona completamente urbana. Esto ligado con el centro poblado de Llanos de Santa Lucía donde es la zona más llana y de menor elevación relativa respecto a las localidades anteriores y la conformación urbana se intensifica. Los cambios están ligados a actividades comerciales, residenciales y de educación, lo cual también se puede observar en el Carmen donde es más urbano y Cot que es cabecera de distrito.

El mapa resultante muestra claramente la distribución espacial de las diferentes coberturas del suelo. Demostrando que, en las cinco localidades estudiadas, no existe una homogeneidad ni una planificación óptima. La clasificación supervisada permitió distinguir la diversidad de paisajes agrícolas, urbanos y ecosistemas boscosos de la región. Cada localidad presenta peculiaridades en cuanto a altitud, relieve, tradición agrícola y grado de desarrollo urbano. Esta información es de alta relevancia para planificar el uso sostenible del territorio, equilibrar la producción agropecuaria con la conservación ecológica y orientar futuras iniciativas de ordenamiento y desarrollo socioeconómico.

- *Clasificación No Supervisada*

El proceso de la clasificación no supervisada consolidó un diseño cartográfico que agrupa los datos sin etiquetas predefinidas, lo cual permite que el sistema identifique patrones y clases de manera autónoma utilizando el método *K-Means*. Este enfoque es útil para explorar datos y descubrir relaciones ocultas, lo que enriquece la representación cartográfica y la comprensión del territorio.



Mapa 6. Clasificación No Supervisada detalles de la zona de estudio

Fuente: Elaboración propia, 2025.




Figura 24. Porcentaje y áreas de los patrones del método *K-means*

K-Means es uno de los algoritmos de clasificación no supervisada más usado en imágenes, datos aleatorios y no etiquetados. Este algoritmo permite la generación de clústeres, agrupando los datos bajo características similares y diferenciando elementos como vegetación, espacios urbanos vacantes e, incluso, usos rurales. Aunque el análisis jerárquico de clúster, la media móvil y maximización de la expectativa podrían considerarse alternativas apropiadas, el uso de una distancia euclidiana permite que la clasificación hecha con *K-Means* pueda superponerse a coordenadas bidimensionales y sea adecuada para entornos geográficos. (Peña-Zamalloa, 2021, p.73)

La técnica estadística *K-means* organiza automáticamente los datos en grupos sin requerir categorías previas, lo que permite identificar patrones emergentes de la imagen satelital. En este caso, se han distinguido 6 categorías o patrones que permiten una apreciación más detallada de la diversidad de coberturas en el territorio de estudio.

- Categoría 1. Pastizales o Cultivos

Esta clase agrupa zonas caracterizadas por:

- Vegetación baja y uniforme: áreas de praderas, cultivos extensivos y potreros presentan una firma espectral homogénea comparada con la vegetación densa.

- Caracterización espectral: los valores reflectivos en determinadas bandas (como el infrarrojo cercano) permiten identificar estas áreas de vegetación, aunque en algunas zonas de transición se pueden mezclar con otros usos del suelo.

La clasificación de esta categoría es útil para la planificación agrícola y para estudiar la dinámica de cultivos y pastizales, lo cual permite identificar áreas de producción agropecuaria que pueden requerir acciones de manejo, riego o protección contra la erosión.

- Categoría 2. Bosque y cuerpos de agua

Estas dos clases se distinguen por agrupar áreas con características propias de las formaciones boscosas de la siguiente manera:

- Densidad y heterogeneidad: los bosques, tanto de vegetación primaria como secundaria, presentan un dosel frondoso que se refleja en variaciones espectrales.
- Diversidad interna: las diferencias entre las categorías 5 y 6 podrían estar relacionadas con el grado de madurez del bosque o variaciones en la especie dominante, lo que da lugar a patrones internos diferenciados.

La identificación precisa de estas áreas boscosas es de gran importancia para el ordenamiento territorial, ya que permite delimitar zonas de conservación, planificar corredores ecológicos y establecer medidas para la protección de la biodiversidad. Además, este análisis ayuda a comprender la distribución de recursos naturales y la resiliencia del territorio ante cambios ambientales o actividades de deforestación.

La clasificación no supervisada con *K-means* permite un panorama inicial del paisaje, una visión global y exploratoria de la diversidad de coberturas en la zona de estudio, lo que sirve como base para profundizar en análisis específicos, descubrir relaciones y guiar intervenciones estratégicas basadas en la realidad geoespacial del territorio.

- Categoría 3, 5 y 6. Nubes

El algoritmo ha identificado de forma independiente tres categorías que corresponden a la presencia de nubes en la imagen satelital, lo cual sucede por dos razones:

- Ausencia de muestras de entrenamiento para nubes: al no haberse definido una máscara que excluya estas áreas, el algoritmo las reconoce como patrones distintos.
- Características espectrales similares: las nubes presentan un brillo y reflectancia altos que pueden confundirse con otras superficies brillantes, como canteras o superficies desnudas de ciertos suelos.

El reconocimiento de estas tres categorías (3, 5 y 6) es relevante, ya que indica la necesidad de un proceso de validación o de refinamiento, donde se debe corroborar con datos complementarios para confirmar la correcta atribución a nubes. Esta información es crucial para evitar interpretaciones erróneas en el análisis territorial y para garantizar la precisión en los estudios de cambio y cobertura del suelo

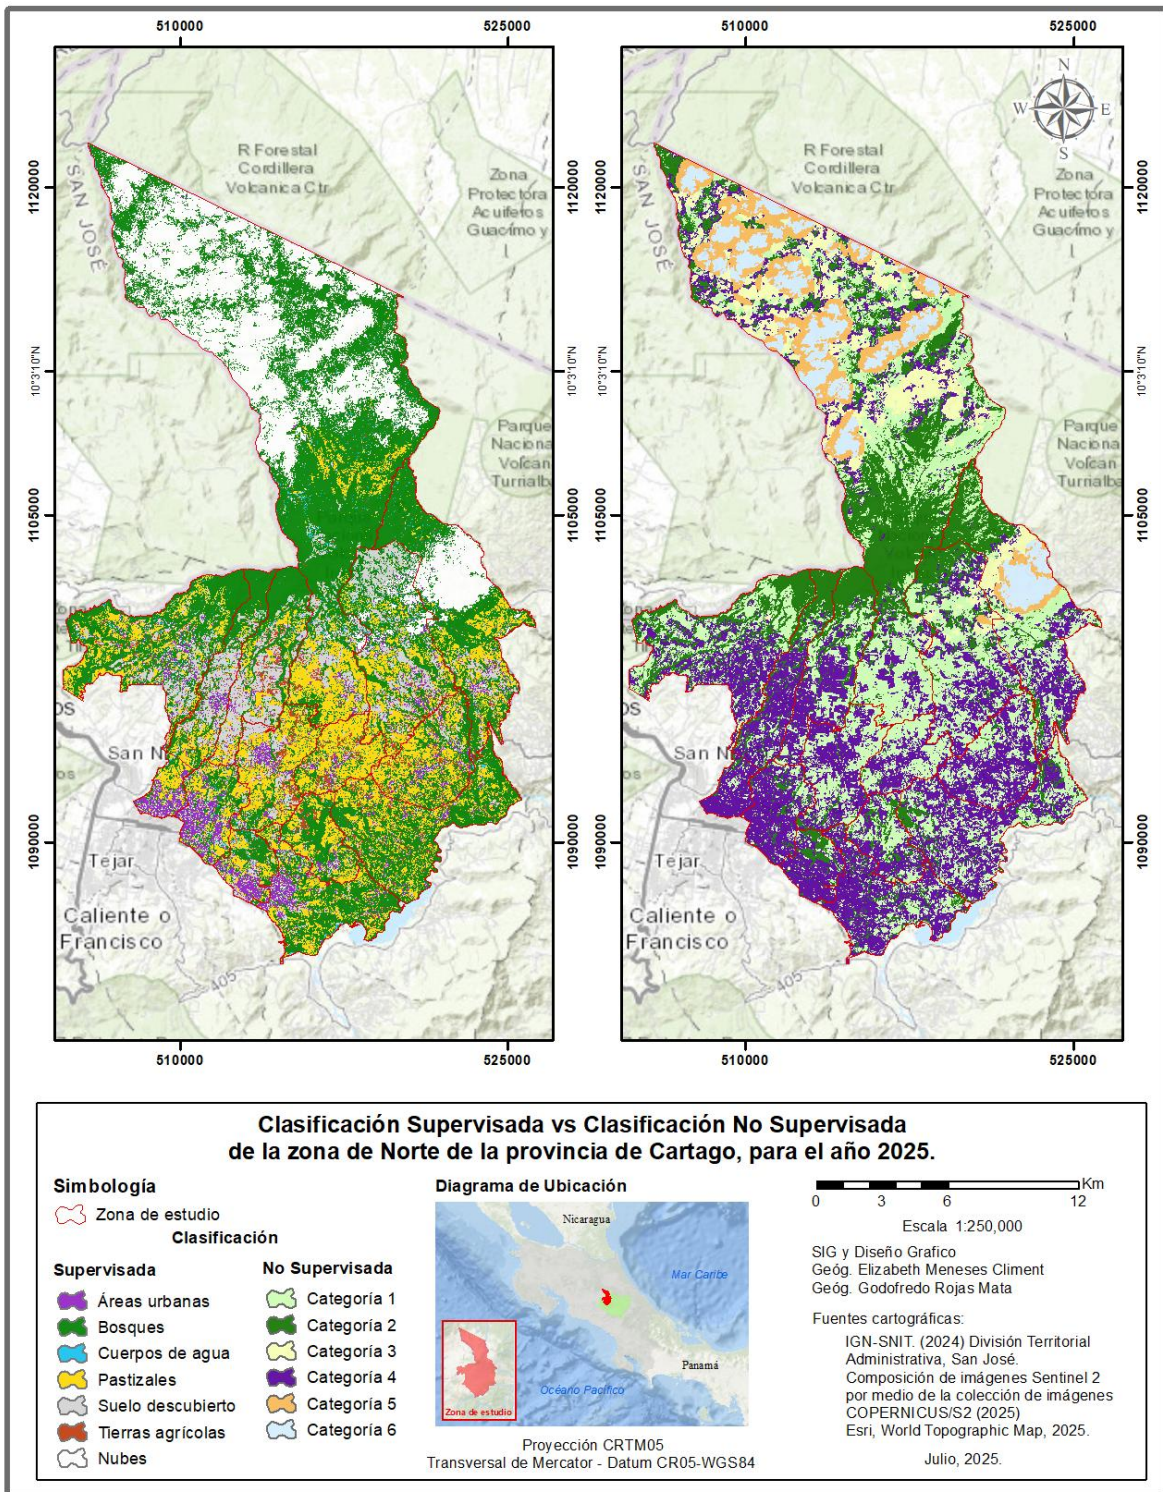
- Categorías 4. Zonas Descubiertas y Urbanas

Esta categoría parece agrupar áreas con escasa o nula cobertura vegetal, lo que incluye:

- Zonas urbanas: grandes núcleos habitacionales, espacios construidos y superficies impermeables.
- Zonas descubiertas: terrenos sin vegetación densa, lo que puede incluir sectores industriales, áreas mineras o espacios de construcción en expansión.

El método *K-means* ha determinado que estos elementos comparten características espectrales similares, diferenciándose claramente del entorno rural. Esto se aprecia en el mapa donde se evidencian contrastes marcados entre las áreas urbanas y las zonas adyacentes que generalmente son de uso agrícola o natural. La detección de esta categoría resulta esencial para el análisis del crecimiento urbano y la planificación de infraestructuras, ya que establece un límite tangible entre el desarrollo construido y el entorno natural.

- *Clasificación Supervisada vs Clasificación No Supervisada*



Mapa 7. Clasificación Supervisada vs Clasificación No Supervisada

Fuente: Elaboración propia, 2025.

El análisis de las áreas urbanas en la clasificación supervisada muestra una delimitación precisa de las zonas construidas por el ser humano, como carreteras, edificaciones e infraestructura urbana. Esto se debe a que se emplearon puntos de muestreo específicos que permitieron identificar con claridad estas coberturas. Por el contrario, en la clasificación no supervisada, las áreas urbanas se agrupan en categorías que también incluyen pastizales o suelos descubiertos, debido a que el método de agrupamiento (*K-means*) se basa únicamente en similitudes espectrales, sin una guía de referencia, lo cual lleva a una sobreestimación de las zonas urbanizables (Ver Mapa 7).

En cuanto a los bosques, se observa mayor precisión en la clasificación supervisada, pues se utilizaron muestras previamente definidas, lo que permitió una mejor calibración y delimitación de las áreas boscosas reales. La clasificación no supervisada, aunque incluye una categoría que se aproxima al patrón de cobertura forestal (Categoría 2), tiende a generalizar y puede incluir áreas que no corresponden exclusivamente a bosque.

Respecto a los cuerpos de agua, la clasificación supervisada identifica claramente estas áreas gracias a las firmas espectrales previamente definidas y validadas mediante fotointerpretación. En contraste, la clasificación no supervisada no logra diferenciar adecuadamente estas zonas, lo que sugiere que los cuerpos de agua no formaron un clúster específico durante el proceso automatizado.

Los pastizales, como se mencionó anteriormente, son confundidos a menudo con áreas urbanas en la clasificación no supervisada. Esto ocurre debido a que ambas coberturas pueden compartir características espectrales similares que lleva a que se agrupen dentro de una misma categoría (especialmente en la Categoría 1).

En relación con los suelos descubiertos, la clasificación supervisada permite diferenciarlos de manera más efectiva, mientras que en la clasificación no supervisada pueden mezclarse con otras coberturas como pastizales o incluso zonas agrícolas, dada la ausencia de criterios de referencia. Las tierras agrícolas representan una de las clases de mayor interés en este estudio. En la clasificación supervisada, se logran identificar con mayor exactitud gracias al uso de muestras previamente verificadas. En la no supervisada, esta cobertura se dispersa entre varias categorías y esto dificulta su delimitación precisa.

En el caso de las categorías de las nubes, la clasificación supervisada identifica una sola categoría bien delimitada, verificada mediante fotointerpretación. Por su parte, la clasificación no supervisada agrupa las nubes en dos categorías distintas que podría deberse a variaciones en su densidad o tipo, aunque también puede representar un efecto de mezcla espectral.

Los resultados obtenidos a partir del NDVI y de la clasificación, tanto la supervisada como la no supervisada, demuestran que los distritos de Tierra Blanca, Pacayas y Cot están sometidos a una sostenida pérdida de su suelo de cultivo como consecuencia de la expansión urbana que se encuentra sin planificación. Este proceso también es consistente con la evidencia nacional, ya que Montero et al. (2021) muestran que en el periodo de 1986 a 2014 la expansión urbana y los monocultivos estuvieron fragmentando el paisaje agrícola costarricense, produciendo una pérdida de la conectividad ecológica del paisaje de un 13 %; además de tener impactos negativos en la agroforestería del café. Por su parte, en la región de Osa, Bouffard et al. (2024), mediante el GEE, muestran un desplazamiento de las tierras de cultivo hacia los usos urbanos o hacia usos forestales secundarios desde 1987 a 2019, afectando incluso la continuidad del paisaje productivo de la zona aun en áreas que son protegidas. Finalmente, en los territorios ubicados en la cuenca del río Torres, en la zona urbana de la GAM, en pocas décadas el 50 % del territorio se ha convertido en zona urbanizada, un proceso que ilustra la misma lógica que el observado en Cartago (Quesada-Román et al., 2021).

Este fenómeno de pérdida de cobertura agrícola también fue demostrado en un estudio reciente por los autores González Gamboa et al. (2021) donde el creciente uso urbano no planificado y la no priorización de la parcela agropecuaria han llevado al país a experimentar patrones regresivos en la gestión de los recursos naturales. En la Península de Osa, el análisis cartográfico mediante el GEE y el uso de imágenes de Landsat (1987-2019) ha hecho ver que los suelos agrícolas han disminuido mientras que los suelos urbanos han crecido, es decir, que la rentabilidad de conversiones de suelos agrícolas ha sido ininterrumpida (Brumberg et al., 2024).

A raíz de un análisis conjunto, podríamos recoger que estos estudios apuntan a una tendencia poco esperanzadora de pérdida de cobertura agrícola intensificada por una urbanización sin

freno y escasas políticas de ordenación de la superficie del suelo. Inostroza et al. (2012) afirman que un proceso de urbanización sobre suelos agrícolas fértiles no acompañado por estrategias de ordenación disciplinadas favorece la disminución de la capacidad productiva del suelo, la pérdida de la diversidad agraria, el aumento de la vulnerabilidad socioambiental y la fragmentación de los espacios agrícolas. Los casos de la región de Bucarest-Ilfov evidencian cómo la urbanización fragmenta las tierras de los agricultores periurbanos, lo que resulta en una disminución de la superficie cultivable(Diaconu et al., 2025). Este fenómeno no es exclusivo de Bucarest, ya que se reproduce en procesos similares en la región de Cartago.

Generación de patrones espaciales

El análisis de patrones espaciales permite conocer qué tipo de distribución presenta los datos que vamos a representar, ya que al tener esta información de posicionamiento, nos aporta una información adicional y nos permite saber si estos valores se encuentran de forma dispersa, o si por el contrario presentan una concentración en determinadas zonas. Generalmente este tipo de análisis de patrones se llevan a cabo preferentemente sobre capas de tipo puntual, aunque es posible realizarlo con otro tipo de geometrías y/o entidades como polígonos o capas ráster (RemOT Technologies, 2020).

El análisis espacial aplicado a los productos derivados del NDVI y de las clasificaciones supervisadas y no supervisadas permitió identificar patrones territoriales relacionados con la cobertura del suelo. A partir de los mapas temáticos generados fue posible detectar concentraciones de áreas agrícolas en retroceso, zonas de expansión urbana en crecimiento y fragmentación del paisaje productivo.

Se observaron patrones de dispersión en los parches agrícolas más resilientes y agrupaciones lineales asociadas a los corredores viales, en donde predomina el desarrollo urbano y comercial. Los patrones se analizaron bajo una perspectiva multiescalar, lo cual permitió inferir la transición espacial desde un paisaje agrícola compacto hacia una configuración más fragmentada, dispersa y vulnerable a los procesos de urbanización no planificada.

También en este proceso por la situación de los datos se tuvieron que descartar 5 distritos, cuatro por condiciones dadas por la falta de la mitad del territorio sin datos que fueron Birrisito, Llanos de Santa Lucía, Paraíso y Santiago. Y, el caso de San Rafael, es que el distrito no está al 100 % con NDVI, por lo que una pequeña parte de su territorio no tiene el índice de vegetación y por *default* los SIG utilizados lo descartan.

Para poder tener estos datos se aplicaron tres índices que verifican la autocorrelación espacial y sus patrones según la capa vectorial de la zona de estudios con 15 distritos y el ráster del NDVI.

Aplicación de índices de autocorrelación espacial

- Índice de Moran (Global y Local)

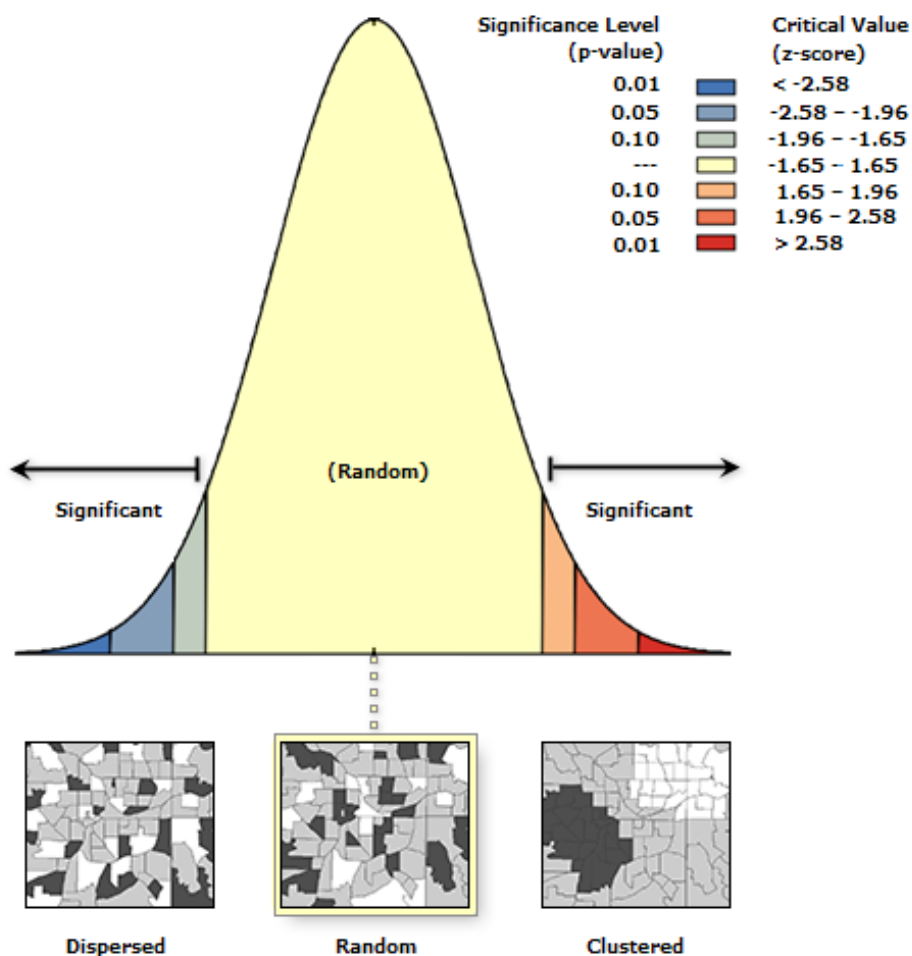


Figura 25. Índice de Moran (Global)

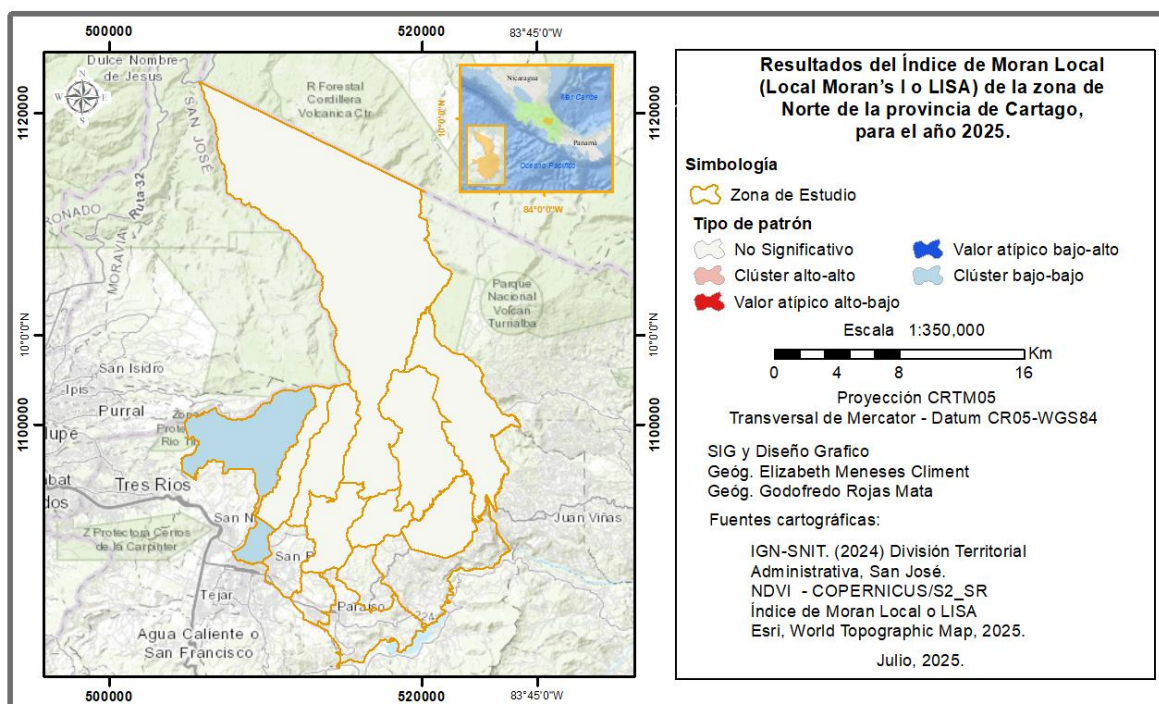
Para cuantificar la dependencia espacial entre las unidades territoriales respecto a variables como el NDVI promedio y la cobertura agrícola se aplicó el Índice de Moran global (I) utilizando los valores promedio del NDVI por distrito. Los valores obtenidos fueron:

Tabla 7. Datos obtenidos del Índice de Moran Global

<i>Índice de Moran</i>	-0.032
<i>Índice esperado</i>	-0.111
<i>Diferencia</i>	0.015
<i>Puntuación z</i>	0.653
<i>Valor p</i>	0.514

Fuente: Elaboración propia, 2025.

Este análisis reveló una autocorrelación espacial positiva significativa ($I > 0$) que indica que los valores similares de vegetación tienden a agruparse espacialmente en las áreas altas como Tierra Blanca, Cot y Pacayas.

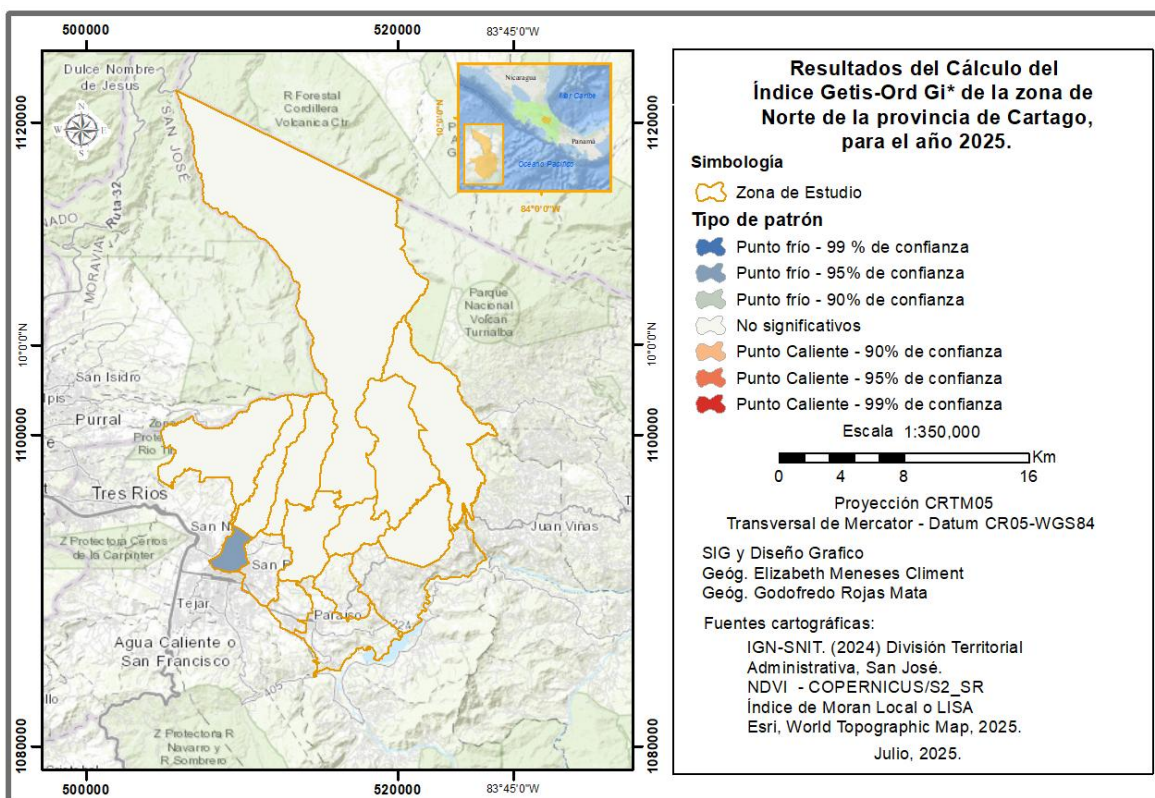


Mapa 8. Índice de Moran Local (Local Moran's I o LISA) de la zona de estudio

Fuente: Elaboración propia, 2025.

A su vez, el análisis de Moran Local (LISA) permitió identificar la presencia de un clúster bajo-bajo en los distritos de Llano Grande y El Carmen que indica que ambos presentan valores bajos del NDVI al igual que sus distritos vecinos inmediatos. Esta agrupación estadísticamente significativa sugiere una concentración espacial de baja cobertura vegetal o vegetación degradada, posiblemente vinculada a procesos de urbanización, expansión periurbana, abandono de tierras agrícolas o intensificación de cultivos con poca cobertura, como hortalizas o pastos rastreros, como se está dando en el distrito de Llano Grande. El patrón "bajo-bajo" no solo señala condiciones ambientales particulares en estos dos distritos, sino que también pone en evidencia un fenómeno regionalizado de contigüidad geográfica que refuerza la hipótesis de una presión territorial común o un proceso compartido de transformación de la cobertura del suelo.

- Índice Getis-Ord G_i^*



Mapa 9. Índice Getis-Ord G_i^* (*Hotspot Analysis*) de la zona de estudio

Fuente: Elaboración propia, 2025.

Complementariamente, se empleó el índice Getis-Ord G_i^* para detectar “*hotspots*” o concentraciones estadísticamente significativas de valores altos o bajos del NDVI, como se puede observar en el Mapa 9.

Entre los resultados obtenidos tenemos que el distrito del Carmen es el único que tiene una clasificación de Punto frío (valores bajos de la agrupación espacial) con un 95 % de confianza, esto indica una concentración estadísticamente significativa de valores bajos de NDVI, es decir, baja cobertura vegetal o degradación, no de forma aislada, sino en conjunto con distritos vecinos (aunque estos últimos no fueron analizados o resultaron no significativos). Esta zona coincide con áreas periurbanas en transición hacia usos urbanos o mixtos, lo cual puede reflejar procesos de cambio de la cobertura del suelo, presión urbana o abandono agrícola.

La mayoría de los distritos que se estudiaron no presentaron agrupaciones (ni altas ni bajas) que fueran estadísticamente relevantes. Esta observación sugiere por tanto una heterogeneidad interna o la presencia de una dispersión del NDVI que no hace clústeres claros. El análisis realizado con índices de autocorrelación espacial como Moran y Getis Ord G_i^* , descubrieron clústeres estadísticamente significativos y poderosos de transición de uso agrícola a urbano en los bordes de los distritos de Tierra Blanca, Pacayas y Cot. Estos clústeres de alto valor (*hot spots*) coinciden con las zonas donde el cultivo tradicional ha sido substituido por las construcciones informales o la expansión de la urbanización dispersa, disminuyendo así la continuidad del paisaje agroproductivo. Otros estudios recientes en Costa Rica muestran una tendencia similar a la observada en el marco del Programa Nacional de Corredores Ecológicos implementado en el periodo de 2010 a 2015, donde se muestra que aunque se ha ido recuperando la cobertura natural de algunos corredores, la fragmentación ha ido en aumento en el paisaje de los corredores, con una mayor densidad de parches más o menos aislados que han comprometido la conectividad ecológica del paisaje (Morera Beita et al, 2021). Esta fragmentación coincide con los patrones espaciales que se observaron en la investigación, donde los índices identificaron zonas específicas de alta concentración de conversión de suelo agrícola a urbano rodeadas por núcleos urbanos emergentes o ya consolidados.

5.3.Evaluación y Diagnóstico de la Fragmentación

Evaluación de la Fragmentación del Paisaje

La fragmentación del paisaje cuantifica la pérdida de continuidad espacial y funcional en los sistemas territoriales, y permite observar los cambios en el uso del suelo a partir de métricas específicas y la representación cartográfica.

Tabla 8. Área por clase de uso del suelo por distrito

Código	Distrito	Uso 1	Uso 2	Uso 3	Uso 4	Uso 5	Uso 6	Uso 7
30103	<i>Carmen</i>	13176	4012	221	6627	2883	6620	196
30108	<i>Tierra Blanca</i>	3141	37018	1826	15916	29942	15072	259
30110	<i>Llano Grande</i>	5492	128729	4332	39316	29822	27604	3620
30201	<i>Paraíso</i>	12820	41467	2318	29350	9801	46688	537
30202	<i>Santiago</i>	3463	59634	1800	42264	4397	102152	83
30205	<i>Llanos de Santa Lucia</i>	9550	6593	2620	5579	8572	19566	262
30206	<i>Birrisito</i>	2020	21697	647	18576	2726	28395	9
30601	<i>Pacayas</i>	3362	68686	4096	49464	65230	28098	31808
30602	<i>Cervantes</i>	6210	25349	247	32163	8104	54226	109
30603	<i>Capellades</i>	2295	95314	6532	30478	16458	38771	108203
30701	<i>San Rafael</i>	20718	10240	1030	16899	9840	20708	539
30702	<i>Cot</i>	6564	26037	819	40833	22344	27607	165
30703	<i>Potrero Cerrado</i>	1399	60082	2061	21536	54500	14431	967
30704	<i>Cipreses</i>	2139	13867	0	31633	3972	26729	34
30705	<i>Santa Rosa</i>	7202	342490	41503	42913	51220	29884	877604

Fuente: Elaboración propia, 2025.

La fragmentación del paisaje agrícola es un fenómeno que refleja la ruptura progresiva de la continuidad espacial y funcional de las áreas productivas, lo cual es causado principalmente por el avance de la infraestructura del uso urbano. En el contexto de la zona norte de Cartago, esta problemática fue evaluada mediante una combinación de análisis visual y métricas espaciales derivadas de los productos de la investigación.

Los resultados mostrados en la tabla anterior presentan que los distritos de Oreamuno (especialmente Cot y Potrero Cerrado) y Paraíso (Santiago y Llanos de Santa Lucía) presentan los niveles más altos de fragmentación agrícola. En estos sectores, el paisaje antes dominado por extensas zonas productivas se encuentra actualmente dividido por urbanizaciones dispersas, vías secundarias y terciarias que fragmentan los espacios productivos y lotificaciones para proyectos residenciales.

El análisis multiescalar y multitemporal realizado permitió identificar un patrón significativo de fragmentación del paisaje agrícola en la zona norte de Cartago. Este fenómeno se observa particularmente en distritos como Tierra Blanca, Cot, Pacayas y Cervantes, donde la cobertura agrícola ha sido interrumpida por núcleos urbanos dispersos y corredores viales secundarios. El Índice de Moran Global y Local (LISA) revelaron conglomerados de fragmentación con baja conectividad ecológica, lo que compromete la continuidad de los usos del suelo agrícola y reduce la capacidad funcional del territorio para sostener actividades productivas de manera sostenible.

Tabla 9. Estadísticas de NDVI por zona

Código	Distrito	Media	Desviación estándar	Mínimo	Máximo
30103	<i>Carmen</i>	0.199	0.117	-0.080	0.580
30108	<i>Tierra Blanca</i>	0.287	0.143	-0.058	0.654
30110	<i>Llano Grande</i>	0.345	0.144	-0.073	0.703
30201	<i>Paraíso</i>	0.313	0.108	-0.032	0.667
30202	<i>Santiago</i>	0.400	0.122	-0.082	0.693
30205	<i>Llanos de Santa Lucia</i>	0.267	0.138	-0.037	0.668
30206	<i>Birrisito</i>	0.398	0.129	-0.051	0.681
30601	<i>Pacayas</i>	0.379	0.150	-0.109	0.718
30602	<i>Cervantes</i>	0.381	0.129	-0.151	0.692
30603	<i>Capellades</i>	0.471	0.127	-0.081	0.735
30701	<i>San Rafael</i>	0.239	0.134	-0.085	0.655
30702	<i>Cot</i>	0.349	0.140	-0.072	0.705
30703	<i>Potrero Cerrado</i>	0.275	0.143	-0.136	0.689
30704	<i>Cipreses</i>	0.409	0.116	-0.063	0.688
30705	<i>Santa Rosa</i>	0.446	0.171	-0.176	0.744

Fuente: Elaboración propia, 2025.

Los valores obtenidos del estado de salud de las plantas, evidencian una clara variabilidad espacial y también la productividad de los cultivos, al igual que las condiciones ambientales locales. Las zonas con altos valores de NDVI (entre 0.5 y 0.8) están situadas principalmente en el noreste del área de estudio, y menores en los distritos de Potrero Cerrado y Capellades, donde se concentra una cobertura agrícola continua y bien manejada. Por otro lado, las zonas con bajos valores de NDVI (por debajo de 0.2) están relacionadas mayoritariamente con áreas urbanizables, cuerpos de agua, o con terrenos que están siendo abandonados. Esta evaluación del estado de salud de la vegetación también permitió documentar zonas donde la vegetación presenta indicios de estrés, posiblemente por zonas con prácticas agrícolas intensivas, degradación del suelo, o una falta de irrigación suficiente.

La combinación del NDVI aplicado a la clasificación supervisada y no supervisada ha permitido realizar un diagnóstico en la salud de los cultivos, así como la dinámica del uso del suelo, en este sentido es notoria por ejemplo en los distritos de Cipreses y San Rafael la evidente necesidad de la planificación diferenciada por subregiones al observar contrastes entre las buenas condiciones de salud vegetal y el deterioro ambiental. Esto sumado con la correcta clasificación a partir de una alta resolución temporal y espacial de las imágenes de Sentinel-2 y la verificación en campo, expresa la utilidad de un análisis multitemporal de las condiciones agro-productivas.

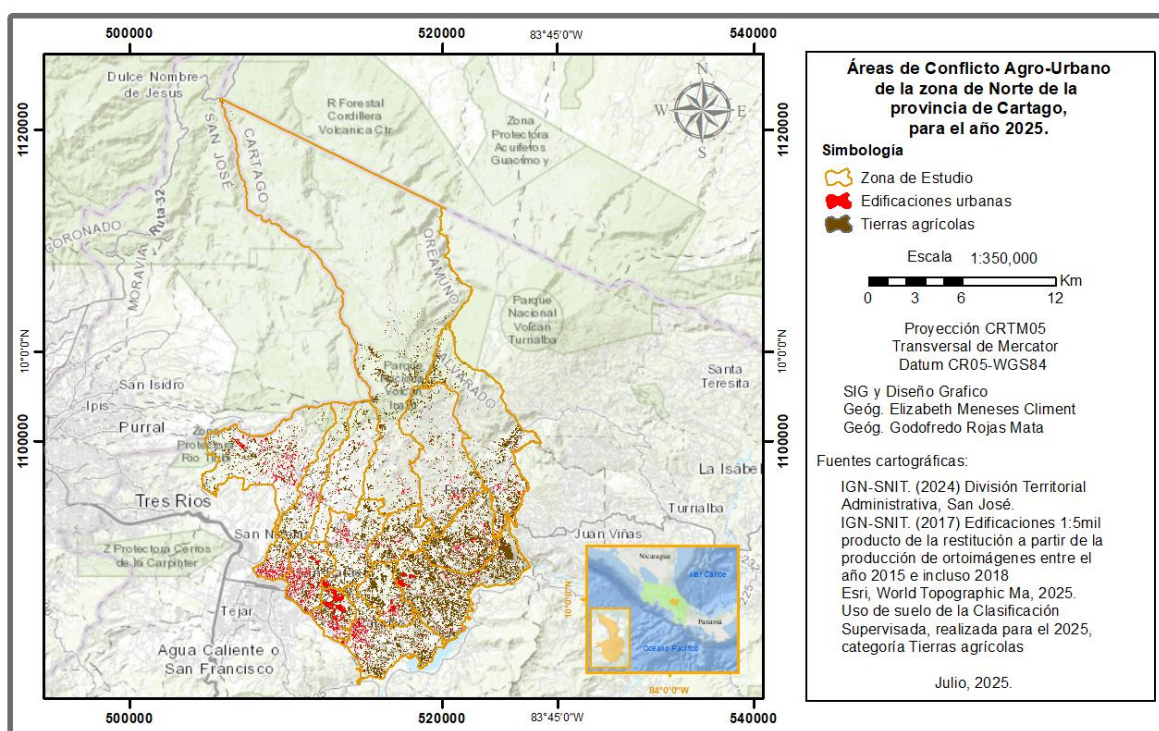
Además, se detectó una fuerte correlación negativa entre el índice NDVI y el grado de fragmentación: los sectores más fragmentados presentan valores más bajos o discontinuos que refleja pérdida de cobertura vegetal agrícola o cultivos en estado degradado, lo cual es el caso del distrito del Carmen. De esta forma la fragmentación territorial observada tiene serias implicaciones para la funcionalidad agrícola del paisaje. Esta situación dificulta la gestión eficiente del recurso hídrico, ya que interrumpe canales, quebradas y zonas de infiltración natural. Asimismo, limita el uso de maquinaria y la rotación de cultivos debido a la reducción del tamaño y la accesibilidad de las parcelas. Además, compromete la sostenibilidad ecológica al disminuir la conectividad entre sistemas agroecológicos y corredores biológicos que afecta así el equilibrio ambiental y la resiliencia del territorio.

Con el objetivo de solucionar dicha alteración en el paisaje, se sugiere aplicar estrategias de infraestructura verde periurbana que sean capaces de recuperar conectividad y resiliencia

ecológica sobre áreas fragmentadas. Con esta línea de trabajo, Morán-Ordóñez et al. (2022), por ejemplo, examinando planes de restauración forestal multisectorial dentro del Corredor Biológico Volcánica Central Talamanca, han utilizado herramientas de planificación espacial como *Marxan* para maximizar la conectividad ecológica denotando un impacto mínimo sobre actividades socioeconómicas locales. Dentro de este enfoque, están los cinturones verdes como corredores funcionales entre parches agrícolas y urbanas a la vez que se refuerza el papel de la conectividad ecológica y que, aun así, ayuda a mitigar la fragmentación identificada a través de los índices espaciales (Morán-Ordóñez et al., 2022). Incluir estas políticas es una oportunidad para poder pasar de patrones fragmentados a redes funcionales del paisaje que mejoren la sostenibilidad territorial.

Diagnóstico de los centros poblados principales.

El crecimiento urbano de los distritos de la zona de estudio, presentan similitudes en la transformación del paisaje, la fragmentación y la pérdida de conectividad ecológica, principalmente en los centros poblados principales.



Mapa 10. Áreas de Conflicto Agro-Urbano

Fuente: Elaboración propia, 2025.

La evolución de los principales centros poblados de la zona norte de Cartago muestra una clara presión sobre sus tierras agrícolas, señalizando una tendencia a la urbanización, como se ha evidenciado con las imágenes satelitales Sentinel-2 y los métodos de clasificación supervisada aplicados en GEE. Los resultados muestran que los principales centros urbanos han crecido espacialmente hacia las zonas productivas de mayor valor, en particular en los bordes norte y este de cada distrito, haciendo que el paisaje agrícola se fragmentara y circulara entre las parcelas cultivadas. Este crecimiento esporádico que se empieza a presentar en el área de Cartago está, sin embargo, mediado por la GAM y hace que se empiecen a ver presiones a los recursos naturales del área y que ponga en situación de mayor vulnerabilidad a la agricultura regional.

De forma adicional, en distritos como Cot o Tierra Blanca se determinó una fuerte pérdida de conectividad agrícola asociada a la edificación de desarrollos habitacionales que rompen las matrices agrícolas existentes. En el caso de Cervantes y Pacayas, la urbanificación va por una tendencia lineal en las vías secundarias, lo que permite el establecimiento de nuevos núcleos de población en franjas que anteriormente estaban dedicadas a la agricultura intensiva. En estos contextos, la ordenación territorial vigente y la regulación municipal han sido incapaces de frenar la dinámica de urbanización informal o especulativa, lo que ha llevado a una modificación del paisaje productivo de forma acelerada. Aunque sí que hay normativas como los perímetros urbanos del Ministerio de Vivienda y Asentamientos Humanos (MIVAH) y del INVU, la praxis actual denota una escasa aplicación o control de éstas, lo que facilita la ocupación de tierras agrícolas sin un control real.

La conjunción de recursos tales como el NDVI, el índice de Moran Local (LISA) y el análisis de "hot spots" del índice Getis-Ord G_i^* , se logró una mejor comprensión sobre los efectos que ejerce el crecimiento urbano sobre la salud de la vegetación. Las áreas perimetrales de los centros poblados tendrían una tendencia de la vitalidad vegetal decreciente, lo que podría corresponder a la aparición de estrés hídrico, a pérdida de cobertura o a presión constructiva. También el diagnóstico se enriqueció del análisis multitemporal, que permite ver los procesos antes citados intensificándose entre 2020-2024. Para poder gestionar mejor el territorio, se sugiere la incorporación de indicadores de la presión urbana sobre los suelos agrícolas, el fortalecer los instrumentos de ordenamiento del territorio basados en evidencias

geoespaciales actualizadas y la puesta en marcha de mecanismos de gobernanza que involucren a las comunidades agrícolas en la toma de decisiones. Este modus operandi es clave para apaciguar los conflictos agrouurbanos y avanzar hacia planes territoriales más sostenibles.

De esta manera a partir del análisis espacial integrado, una creciente vulnerabilidad del espacio-territorio en los distritos de transición agrícola-urbana como Cot, Pacayas, Tierra Blanca y Cervantes. El análisis muestra la combinación de la expansión urbana informal, la pérdida acelerada de los suelos fértiles y un descenso en la salud vegetal que puede ser medido por el NDVI (con valores menores a 0.3 en zonas marginales), lo que refleja un posible estrés o abandono de cultivos. A través del índice Getis Ord G_i^* se detectaron "puntos calientes" de conversión agresiva del uso del suelo, que coinciden con sectores de alta productividad histórica; por otro lado, la clasificación supervisada refleja ocupaciones fragmentadas que penetran directamente en matrices agrícolas, lo que la hace incompatible con la conectividad ecológica y funcional del paisaje.

La dinámica de crecimiento urbano en la zona norte de Cartago significa un gran reto para la integridad y la sostenibilidad del paisaje agrícola mostrando un proceso ágil de fragmentación y pérdida de conectividad efectiva. Este escenario es coincidente con estudios previos que muestran cómo la expansión urbana sin planificación impacta en la producción agrícola y la salud ecológica de los espacios (Seto et al., 2012) mostrando impactos negativos en los sistemas de la soberanía alimentaria y en la calidad de vida rural. Es por eso que se vuelve necesario poder implementar políticas de forma integral que incorporen datos geoespaciales actuales así como promover la participación comunitaria en la planificación territorial, de tal manera que se pueda fortalecer la idea de equilibrio entre desarrollo urbano y la conservación agrícola para la zona.

Principales áreas de conflicto identificadas:

1. Sector occidental de Tierra Blanca y Cot

- El análisis NDVI muestra una pérdida paulatina de vigor vegetal en áreas que anteriormente presentaban actividad agrícola intensiva.
- El crecimiento no responde a una planificación de los gobiernos locales, sino a procesos espontáneos de ocupación.

2. Llanos de Santa Lucía y Birrisito

- En estos distritos se observó un patrón de urbanización difusa, caracterizado por viviendas dispersas dentro de zonas rurales que aún se mantienen productivas.
- Los valores del NDVI son heterogéneos y esto refleja la coexistencia de zonas cultivadas, suelos en barbecho y áreas construidas en expansión.
- Además, estos cambios tienden a consolidar estructuras de borde urbano mal definidas, lo que dificulta la implementación de zonas de transición bien reguladas.

3. Bordes de Paraíso y San Rafael

- Se identificaron áreas donde coexisten lotes baldíos, suelos con potencial agrícola sin uso y zonas residenciales en consolidación.
- La falta de coherencia espacial entre las actividades productivas y las urbanas genera tensiones en el uso del agua, la contaminación de suelos por residuos sólidos y la pérdida de infraestructura agrícola.
- El mapa de clasificación supervisada evidencia una transición territorial acelerada, donde los usos del suelo cambian sin mecanismos de control o gestión integrada.

Áreas adicionales bajo presión:

- Cervantes y Capellades muestran patrones emergentes de conflicto asociados a proyectos de expansión comercial y bodegas cerca de rutas principales.
- Pacayas, si bien conserva un fuerte perfil agrícola, comienza a presentar presiones urbanas por su cercanía a Cartago centro y su accesibilidad vial mejorada.

5.4. Propuestas de Ordenamiento y Gestión Territorial

Interpretación Geográfica Contextualizada

La interpretación geográfica de los resultados obtenidos en esta investigación no puede limitarse al análisis técnico de los productos geoespaciales. Es necesario incorporar una mirada territorial integral que considere los aspectos biofísicos, socioeconómicos, normativos y culturales del espacio geográfico analizado. Para ello, se realizó una lectura cruzada entre los patrones espaciales detectados por medio de imágenes satelitales, las estadísticas derivadas del NDVI, los resultados de las clasificaciones de la cobertura del suelo, los datos de campo levantados y el marco institucional local.

Este tipo análisis geoespacial tiene un valor estratégico en la producción de políticas públicas, sobre todo en lo que dice relación con la planificación del territorio y la gestión ambiental. Las administraciones locales pueden incorporar estos insumos a planes de desarrollo urbano, sistemas de alerta temprana asociados a cambios de uso del suelo o a eventos ambientales, así como a la delimitación de zonas específicas de conservación o desarrollo. La vinculación de herramientas geoespaciales y prácticas de participación comunitaria refuerza, según McCall y Dunn (2011), los procesos de gobernanza territorial en América Latina, fomentando una gestión del territorio más transparente, pero también inclusiva y basada en la evidencia. Investigaciones como las realizadas por Clark et al. (2012) o Pinheiro et al. (2020) subrayan también que el uso de datos remotos validados en campo mejora la capacidad institucional para la toma de decisiones.

En este contexto, el análisis geoespacial, contribuye a identificar subzonas funcionales que resulten significativas y que nos permitan identificar las diferencias existentes y abordar las características de cada zona dentro del ámbito de estudio. Con el análisis de las características territoriales, los distintos grados de presión que experimenta la urbanización más intensa, el valor agrario y los conflictos de la cobertura del suelo, se puede pensar en estrategias más idóneas, adaptadas a la especificidad de cada grupo de zonas. Estas subzonas no son categorías normativas sino unidades de interpretación que permiten definir estrategias diferenciadas.

1. Zonas Altas Productivas con Potencial Agroecológico (Cot, Tierra Blanca, Pacayas)

Estas zonas se caracterizan por su altitud superior a los 1.500 metros, suelos volcánicos fértiles, clima fresco y alta disponibilidad hídrica que las convierte en áreas ideales para el desarrollo de agricultura intensiva (hortalizas, tubérculos, legumbres, cultivos orgánicos). El NDVI en estas zonas muestra valores altos y estables durante el año, confirmando la vitalidad de la vegetación cultivada.

Características:

- Suelos de alta aptitud agrícola, con estructura orgánica, buena retención de agua y bajo riesgo de erosión si se manejan adecuadamente.
- Presencia de parcelas familiares y microfincas que practican agricultura intensiva, muchas veces con saberes tradicionales.
- Alta presencia de cultivos de ciclo corto (papa, cebolla, zanahoria, lechuga) destinados tanto al consumo local como al abastecimiento de ferias y mercados de la GAM.

Problemas detectados:

- Fragmentación progresiva de las fincas por herencia o parcelamiento informal producto de los procesos de herencia.
- Presión inmobiliaria incipiente, especialmente, en bordes urbanos de Tierra Blanca y Cot donde el valor del suelo ha aumentado debido al crecimiento urbano y la expansión de la infraestructura.
- Falta de conectividad ecológica entre las parcelas, lo cual reduce el valor ambiental de estos sistemas agrícolas que ha generado paisajes fragmentados y ecosistemas aislados.
- Vulnerabilidad al cambio climático, por las variaciones en los patrones de precipitación y las temperaturas extremas que afectan la producción agrícola.

Propuesta de enfoque territorial:

Estas zonas deben consolidarse como corredores agroecológicos de montaña, priorizados en las políticas municipales y nacionales de sostenibilidad agrícola. Se propone:

- Fomentar asociaciones de productores que implementen sistemas de producción agroecológica y puedan acceder a incentivos del Ministerio de Agricultura y Ganadería (MAG), Fondo Nacional de Financiamiento Forestal (FONAFIFO) y el Instituto de Desarrollo Rural (INDER).
- Integrar estas zonas al Sistema Nacional de Áreas de Conectividad Biológica, mediante corredores funcionales que combinen producción sostenible y conservación, como el uso de cercas vivas, cultivos en fajas, reforestación de bordes y bancos forrajeros, promoviendo el tránsito seguro de fauna y la conectividad entre parches boscosos.
- Incluirlas en los Planes Reguladores como zonas agrícolas con valor ecológico y función ecosistémica, lo que permitiría restringir usos no compatibles como la expansión urbana desordenada o actividades extractivas intensivas. Además, se debe establecer una normativa que promueva prácticas de manejo sostenible, como la conservación de nacientes y zonas de recarga hídrica.
- Incorporar en el departamento área que se encuentre el Sistema de Información Geográfica municipal el uso de la plataforma GEE para un monitoreo periódico, lo que facilitaría la toma de decisiones basada en datos y evidencia científica. Esto permitiría, por ejemplo, activar alertas tempranas ante cambios críticos en el uso del suelo, pérdida de cobertura forestal o fragmentación ecológica.

2. Zonas de Transición Agrourbana (Llanos de Santa Lucía, Birrisito, Paraíso)

Estas áreas presentan un uso mixto del suelo donde conviven fragmentos de agricultura tradicional, parcelas abandonadas, zonas de urbanización dispersa y comercio en crecimiento. El análisis multitemporal evidencia un descenso del NDVI en los últimos años

junto con una pérdida de continuidad en las coberturas agrícolas, asociada a procesos de transformación del paisaje y la fragmentación presente en estas zonas.

Características:

- Terrenos de menor altitud (1.100 - 1.400 m.s.n.m.) aún productivos, pero más vulnerables a la degradación por su cercanía a los ejes viales, actividades comerciales más redituables, centros poblados y áreas urbanas consolidadas.
- Altos niveles de presión inmobiliaria ejercida por proyectos habitacionales, especialmente, de urbanizaciones cerradas o de clase media. O bien, desarrollos orientados al comercio mayorista, como bodegas, ferreterías, centros logísticos o almacenes agrícolas.
- En el caso de la urbanización residencial, el uso del suelo informal de muchos sectores presenta habitualmente problemas que están vinculados con la ausencia de servicios o de lineamientos que están desactualizados.

Problemas detectados:

- Conflicto creciente entre usos urbanos y agrícolas en zonas donde se solapan fincas productivas con lotificaciones recientes o proyectos de urbanización acelerada o en proceso de formalizarse.
- Fragmentación muy importante del paisaje agrícola que compromete la funcionalidad tanto de la funcionalidad ecológica como la funcionalidad operativa del agroecosistema porque reduce la conectividad entre parcelas, aumenta la incapacidad para practicar producción extensiva y dificulta la posibilidad de poner en marcha corredores biológicos o acciones de conservación de suelo o agua.
- Ausencia de políticas claras de contención urbana que ha permitido una expansión dispersa y no planificada de los usos residenciales y comerciales hacia zonas rurales de alto valor agroproductivo. La falta de contención se ve agravada por vacíos normativos y limitaciones en la aplicación efectiva de los reglamentos de la cobertura del suelo.

Propuesta de enfoque territorial:

Estas zonas requieren una zonificación de usos diferenciada que reconozca su papel estratégico como cinturones verdes y amortiguadores de la expansión urbana. Se propone:

- Implementar zonas de uso mixto agrourbano donde se permitan actividades agrícolas compatibles con usos residenciales de baja densidad y se prioricen modelos como huertos urbanos, agricultura comunitaria y agroecología periurbana.
- Establecer límites claros al crecimiento urbano mediante instrumentos normativos en los planes reguladores y el desarrollo de un anillo de contención como el que se ha utilizado en la GAM.
- Generar espacios de concertación multisectorial en los que participen productores, desarrolladores urbanos, instituciones municipales y actores comunitarios para definir el destino territorial de estas áreas.

3. Zonas Críticas o en Conflicto Territorial (Santa Lucía, Capellades, zonas limítrofes con Oreamuno y Cartago)

En estas zonas el análisis espacial evidenció una fuerte sustitución del uso agrícola por urbanizaciones formales e informales, la cual es acompañada de un deterioro del valor ambiental del suelo y pérdida progresiva de cobertura vegetal. Estas dinámicas expresan una transición territorial desordenada, con efectos socioambientales significativos.

Características:

- Alta accesibilidad y conectividad con nodos viales estratégicos y centros urbanos consolidados como Cartago y Paraíso, lo que genera una presión constante sobre el uso del suelo.
- Presencia creciente de usos intensivos no regulados como zonas industriales, bodegas, comercio mayorista y urbanizaciones cerradas, que alteran el tejido rural y generan desequilibrios funcionales.

- Concentración de conflictos territoriales vinculados a la cobertura del suelo, demanda de servicios básicos y expansión urbana no planificada.

Problemas detectados:

- Desplazamiento de la actividad agrícola hacia zonas marginales o menos aptas.
- Dificultad para aplicar normativas vigentes debido a la falta de actualización de los Planes Reguladores.
- Inestabilidad social en comunidades rurales afectadas por el aumento del valor del suelo y la pérdida de su identidad agrícola.

Propuesta de enfoque territorial:

Estas zonas deben ser abordadas mediante planes específicos de reconversión territorial y mitigación de conflictos que incluyan:

- Programas de reconversión productiva que promuevan actividades compatibles como agroindustria local, viveros o producción orgánica de alta rentabilidad.
- Establecimiento de parques agroecológicos o huertos urbanos como estrategia de revalorización del uso agrícola y de integración social.
- Aplicación de instrumentos de control urbano como la moratoria de construcción en suelos agrícolas, el cobro diferenciado de impuestos y la aplicación estricta de la normativa de la cobertura del suelo.
- Revisión participativa de los Planes Reguladores, incorporando datos geoespaciales (como NDVI y análisis multitemporal) para mejorar la propuesta de ordenamiento territorial y la toma de decisiones.
- Fomentar instancias de gobernanza territorial intermunicipal, en coordinación con actores como el INVU, SETENA, MAG y organizaciones de base, para gestionar los conflictos de forma integral y adaptativa.

6. CONCLUSIONES

La incorporación de GEE en esta investigación representa una evolución metodológica frente a los enfoques tradicionales en geografía aplicada. Su capacidad para procesar imágenes satelitales de alta resolución, ejecutar algoritmos de clasificación y calcular índices espectrales como el NDVI permite realizar un análisis multitemporal y multiescalar altamente preciso, actualizado y reproducible. Esta herramienta no solo optimiza el monitoreo ambiental, sino que democratiza el acceso a tecnología espacial avanzada para la planificación territorial.

La investigación brinda insumos concretos que fortalecen la toma de decisiones a nivel local y regional. La identificación precisa de zonas de conflicto agro-urbano en distritos como Tierra Blanca, Cot y Pacayas permite a los gobiernos locales anticipar tendencias de transformación del uso del suelo y aplicar medidas correctivas, como zonas de contención urbana, protección de cinturones verdes o delimitación de áreas de conservación agrícola. La precisión espacial alcanzada supera las limitaciones de las herramientas tradicionales y habilita la elaboración de planes reguladores más ajustados a la realidad territorial. El enfoque no solo mejora la eficacia de la gestión del suelo, sino que también fortalece la capacidad institucional para enfrentar los retos de la expansión urbana, el cambio climático y la seguridad alimentaria.

Los resultados obtenidos permiten evidenciar una creciente fragmentación del paisaje productivo, particularmente, en la zona norte de Cartago. Este fenómeno, resultado de un crecimiento urbano desordenado, ha provocado la pérdida de continuidad ecológica entre las parcelas agrícolas. Como consecuencia, se ha reducido la resiliencia del sistema agroecológico y se han debilitado los servicios ecosistémicos. La pérdida de tierras fértiles, el aislamiento de áreas verdes y la presión sobre recursos hídricos son impactos directos documentados mediante análisis espacial. Gracias a los datos geoespaciales procesados con GEE, es posible visualizar con claridad las zonas más vulnerables, lo cual facilita el diseño de propuestas concretas como corredores biológicos, zonas de amortiguamiento y estrategias de restauración de mosaicos paisajísticos con valor agrícola y ecológico.

El uso del NDVI, combinado con verificaciones in situ mediante receptores GPS, proporciona una evaluación robusta sobre el estado de los cultivos y la cobertura vegetal. Esta información permite no solo detectar zonas en deterioro o estrés hídrico, sino también anticipar tendencias que podrían afectar la seguridad alimentaria local. La validez científica y operativa del enfoque lo hace replicable en otros contextos geográficos con dinámicas similares.

La integración de imágenes Sentinel-2, técnicas de clasificación supervisada, no supervisada y un riguroso muestreo aleatorio de campo establece una metodología estandarizada, validada y transferible. Este modelo puede ser adaptado para diagnosticar conflictos de uso del suelo en otras regiones y esto lo convierte en un referente técnico para proyectos de ordenamiento territorial, conservación paisajística y monitoreo ambiental en escenarios de cambio rápido.

La investigación genera evidencia empírica que fundamenta la formulación de políticas públicas orientadas a la sostenibilidad. Al identificar patrones espaciales de cambio, zonas de alta presión urbana y áreas prioritarias para la conservación agrícola, se ofrece un marco de acción territorial que considera simultáneamente criterios ambientales, sociales y económicos. Dicho procedimiento permite una gestión más anticipativa, eficiente y socialmente justa del territorio.

Finalmente, el estudio reafirma el papel estratégico de la geografía aplicada en la resolución de problemáticas territoriales complejas. Al conectar escalas de análisis (local, municipal y regional), integrar información satelital con datos de campo y traducir los hallazgos en propuestas concretas fortalece las capacidades institucionales para enfrentar desafíos como el crecimiento urbano descontrolado, la pérdida de tierras agrícolas y la degradación paisajística. En síntesis, su enfoque integral contribuye al diseño de territorios más resilientes, productivos y ambientalmente equilibrados.

7. RECOMENDACIONES

Se recomienda que las instituciones académicas, especialmente, aquellas que imparten carreras en geografía, ordenamiento territorial y ciencias ambientales fortalezcan sus programas formativos mediante cursos y módulos dedicados al uso de plataformas como GEE, sensores remotos, *machine learning* y análisis geoespacial. En esta investigación se enfrentaron desafíos técnicos importantes como la curva de aprendizaje inicial en la codificación en *JavaScript* y la estructura de trabajo en la nube, ya que no todos los investigadores contaban con experiencia previa en el uso de GEE. La superación de estas dificultades se logró mediante la consulta de literatura técnica, cursos virtuales y aprendizaje colaborativo autodirigido, lo cual evidencia la necesidad de incorporar estas habilidades de forma sistemática en la formación profesional. La capacitación continua permitirá que futuros profesionales desarrollen competencias en el procesamiento masivo de datos satelitales y la evaluación dinámica del territorio, lo cual resulta esencial para responder a los retos contemporáneos en planificación y sostenibilidad.

Se sugiere integrar experiencias de investigación aplicada como la desarrollada en este estudio dentro de los planes curriculares universitarios para que los estudiantes apliquen herramientas geoespaciales a problemas reales del territorio. Durante el desarrollo de esta investigación, uno de los retos fue adaptar el enfoque multiescalar y multitemporal a un área heterogénea como la zona norte de Cartago, esto implicó una planificación metodológica rigurosa y validación en campo bajo condiciones logísticas complejas. La experiencia práctica enriqueció la comprensión del fenómeno territorial y evidenció la importancia de vincular la teoría con la realidad. Asimismo, se recomienda incentivar proyectos multidisciplinarios con carreras afines (ingeniería ambiental, sistemas, biología, arquitectura, entre otras) para promover el uso de tecnologías satelitales, clasificación de coberturas, monitoreo agrícola y gestión integrada del territorio.

Se recomienda a las instituciones responsables de la gestión territorial, municipalidades, el Ministerio de Agricultura y Ganadería (MAG) y el Instituto Nacional de Vivienda y Urbanismo (INVU), utilizar los insumos generados por esta investigación como soporte técnico para sus planes y políticas. La aplicación de NDVI y clasificaciones supervisadas y no supervisadas permiten identificar con alta precisión áreas de conflicto agro-urbano y zonas

bajo presión urbana. Esta información debe servir como base para delimitar áreas agrícolas estratégicas, establecer límites a la expansión residencial y formular regulaciones territoriales basadas en evidencia. Uno de los principales desafíos en esta fase fue la búsqueda, descarga y procesamiento de imágenes sin nubosidad y su correcta calibración en GEE, lo cual exigió adaptar *scripts* y realizar un cuidadoso preprocesamiento de datos. Superar estas dificultades permitió consolidar una base cartográfica confiable que puede ser replicada y adaptada en otras regiones del país.




Se propone un modelo de gestión territorial orientado a integrar la zonificación ecológica y económica, el control del crecimiento urbano y la protección de tierras agrícolas productivas. En el estudio, se reveló que los procesos de expansión urbana generan efectos negativos en la productividad agrícola y la conectividad ecológica. Para evitar esto, es necesario establecer límites claros a la urbanización y definir zonas de amortiguamiento entre áreas urbanas y rurales con criterios agroecológicos y paisajísticos. Se sugiere complementar esta estrategia con sistemas de supervisión remota mediante imágenes satelitales y control activo por parte de gobiernos locales, así como el impulso de alianzas público-privadas que promuevan el valor socioambiental del suelo agrícola. Uno de los retos abordados fue el tratamiento de la fragmentación del paisaje y su análisis mediante índices como el de Moran, lo cual requirió interpretar patrones espaciales complejos. Superarlo implicó aplicar herramientas estadísticas geoespaciales con apoyo conceptual en geografía cuantitativa.

La metodología empleada en este estudio, que combina el uso de GEE, el índice NDVI, la clasificación de coberturas y la validación empírica, ha demostrado ser replicable y adaptable. Se recomienda fomentar su difusión y adopción por parte de instituciones públicas, universidades, Organizaciones No Gubernamentales (ONG) y organismos de planificación regional. La replicabilidad metodológica permitiría la creación de una base de datos estandarizada a nivel nacional que facilite comparaciones entre territorios y períodos. Esta cooperación técnica y científica promoverá la generación de redes de trabajo interinstitucionales, fortalecerá la gobernanza territorial basada en datos abiertos y permitirá establecer alianzas internacionales para abordar problemáticas comunes como la pérdida de suelo agrícola, la degradación ambiental y el cambio climático.

8. REFERENCIAS

- Aly, A. A., Al-Omran, A. M., Sallam, A. S., Al-Wabel, M. I., & Al-Shayaa, M. S. (2016). Vegetation cover change detection and assessment in arid environment using multi-temporal remote sensing images and ecosystem management approach. *Solid Earth*, 7(2), 713-725. <https://doi.org/10.5194/se-7-713-2016>
- AmbGEO. (2025, 1 abril). *Como começar no Google Earth Engine?* [Vídeo]. YouTube. https://www.youtube.com/watch?v=1-_4t7ckChI
- AMDGS. (2020, 10 mayo). *Calculating Statistically Significant Hotspots Using the Hotspot Analysis Plugin in QGIS* [Vídeo]. YouTube. <https://www.youtube.com/watch?v=lnDkdbKKJXM>
- Anderson, J., Hardy, E., Roach, J., & Witmer, R. (1976). A Land Use and Land Cover Classification System for Use with Remote Sensor Data. En *USGS*. USGS. <https://pubs.usgs.gov/pp/0964/report.pdf>
- Arles Agustin Taboada Sanchez. (2021, 26 junio). 27. *Google Earth engine : K-means, algoritmo de clasificación no supervisada||Aprendizaje automático* [Vídeo]. YouTube. https://www.youtube.com/watch?v=npJBrh_fQ2g
- Arrieta-Chaves, D. G. (2021). *Análisis de la influencia de las mareas del Río Cañas y Bebedero mediante imágenes satelitales e índices de vegetación y su correlación con el nivel freático de 154 hectáreas de siembra de caña de azúcar (Saccharum Officinarum) Ubicadas en el Ingenio Taboga, Cañas, Guanacaste*. [Licenciatura en Ingeniería Agrícola, Instituto Tecnológico de Costa Rica]. <https://repositoriotec.tec.ac.cr/handle/2238/13997>
- Arruda, V. L., Piontekowski, V. J., Alencar, A., Pereira, R. S., & Matricardi, E. A. (2021). An alternative approach for mapping burn scars using Landsat imagery, Google Earth Engine, and Deep Learning in the Brazilian Savanna. *Remote Sensing Applications Society And Environment*, 22, 100472. <https://doi.org/10.1016/j.rsase.2021.100472>

- Ayala Arcipreste, M. E. y Márquez, R. I. (2022). Ordenamiento Territorial y Desarrollo Sostenible. *Proyección. Estudios Geográficos Y De Ordenamiento Territorial*, 16(31), 1–8. <https://revistas.uncu.edu.ar/ojs/index.php/proyeccion/article/view/6037>
- Ayala-Izurieta, J., Márquez, C., García, V., Recalde-Moreno, C., Rodríguez-Llerena, M., & Damián-Carrión, D. (2017). Land Cover Classification in an Ecuadorian Mountain Geosystem Using a Random Forest Classifier, Spectral Vegetation Indices, and Ancillary Geographic Data. *Geosciences*, 7(2), 34. <https://doi.org/10.3390/geosciences7020034>
- Avila-Sanchez, H. (2019). Agricultura Urbana y Periurbana. Reconfiguraciones territoriales y potencialidades en torno a los sistemas alimentarios urbanos. *Investigaciones Geográficas Boletín del Instituto de Geografía*, 98. <https://doi.org/10.14350/rig.59785>
- Baldini, C., Marasas, M. E. y Drozd, A. A. (2019). Entre la expansión urbana y la producción de alimentos. *Revista de la Facultad de Agronomía*, 118(2), 031. <https://doi.org/10.24215/16699513e031>
- Barboza-Navarro, D., Solórzano-Thompson, J. y Paniagua, J. (2021). Optimización económica para el cultivo de papa, zanahoria y cebolla en Cartago, Costa Rica. *Revista Tecnología en Marcha*. <http://dx.doi.org/10.18845/tm.v34i4.5184>
- Barrenechea, L. (2020, April 15). NDVI: todo sobre la tecnología que está revolucionando el agro. *El Agrario*. <https://acortar.link/qwMDZy>
- Brumberg, H., Furey, S., Bouffard, M. G., Quirós, M. J. M., Murayama, H., Neyestani, S., Pauline, E., Whitworth, A., & Madden, M. (2024). Increasing Forest Cover and Connectivity Both Inside and Outside of Protected Areas in Southwestern Costa Rica. *Remote Sensing*, 16(6), 1088. <https://doi.org/10.3390/rs16061088>
- Buzai, G. D. (2018). Crecimiento urbano y potenciales conflictos entre usos del suelo en el municipio de Luján (Provincia de Buenos Aires, Argentina). Modelado espacial 2016-2030. *Cuadernos Geográficos*, 57(1). <https://revistaseug.ugr.es/index.php/cuadgeo/article/view/5656>

- CAEG - Centro de Altos Estudios en Geomática. (2023a, abril 22).  *Introducción a la Teledetección con Google Earth Engine, Python y QGIS - CAEG* [Video]. YouTube. <https://www.youtube.com/watch?v=dN636Rh8te4>
- CAEG - Centro de Altos Estudios en Geomática. (2024b, 28 enero). *¿Qué es Google Earth Engine?* [Video]. YouTube. <https://www.youtube.com/watch?v=fu1hYpPC48U>
- CAEG - Centro de Altos Estudios en Geomática. (2024c, marzo 26).  *QGIS + GEE 2024: Plugin de Google Earth Engine para QGIS (Descarga e Instalación) | CAEG* [Video]. YouTube. <https://www.youtube.com/watch?v=abZPwx3BNyQ>
- CAEG - Centro de Altos Estudios en Geomática. (2024d, 18 diciembre).  *Aplicaciones de Google Earth Engine Aplicado al Monitoreo Terrestre | CAEG* [Video]. YouTube. https://www.youtube.com/watch?v=pDH_IKIZvrI
- Carlos Saúl Navarro. (2020, 27 abril). *Clasificación supervisada paso a paso en Google Earth Engine* [Video]. YouTube. <https://www.youtube.com/watch?v=B2G-oqOaLbI>
- Ceroni, M., Achkar, M., Gazzano, I. y Burgeño, J. (2015). Estudio del NDVI mediante análisis multiescalar y series temporales utilizando imágenes SPOT, durante el período 1998-2012 en el Uruguay. *Revista de Teledetección*, 43, 31. <https://doi.org/10.4995/raet.2015.3683>
- Clark, M. L., Aide, T. M., & Riner, G. (2012). Land change for all municipalities in Latin America and the Caribbean assessed from 250-m MODIS imagery (2001–2010). *Remote Sensing Of Environment*, 126, 84-103. <https://doi.org/10.1016/j.rse.2012.08.013>
- Congalton, R. G., & Green, K. (2008). Assessing the Accuracy of Remotely Sensed Data. En *CRC Press eBooks*. <https://doi.org/10.1201/9781420055139>
- Contraloría General de la República (CGR). (2023). Opiniones y sugerencias. *Entornos Urbanizados y su relación con la Hacienda Pública: Una perspectiva de servicios públicos sostenibles* (DFOE-LOC-OS-00001-2023). <https://acortar.link/7WMpeM>

- Copernicus. (2018). *El programa Copernicus aplicado a la producción y gestión de la información geoespacial: El componente espacio Copernicus*. Gobierno de España - Ministerio de Transportes, Movilidad, y Agenda Urbana. https://www.ign.es/web/resources/docs/IGNCnig/actividades/OBS/Programa_Marco_Copernicus_User_Uptake/3_componente_espacio_Copernicus.pdf
- Concepción, E. (2022). Expansión urbana o cómo el suelo urbanizado se dispersa por el paisaje: Implicaciones para la conservación de la biodiversidad. *Ecosistemas*, 31(1), 2165 (Enero-Abril 2022). <https://doi.org/10.7818/ecos.2165>
- Culqui, C. L. G. y Pazmiño, M. X. H. (2022). Análisis multitemporal de la dinámica de uso de suelo y cobertura vegetal en la microcuenca del Río Illangama. *Revista de Investigación Talentos*, 9(2), 101-116. <https://doi.org/10.33789/talentos.9.2.173>
- Diaconu, D. C., Peptenatu, D., Gruia, A. K., Grecu, A., Gruia, A. R., Gruia, M. F., Drăghici, C. C., Băloi, A. M., Alexandrescu, M. B., & Sibinescu, R. B. (2025). The Impact of Urban Expansion on Land Use in Emerging Territorial Systems: Case Study Bucharest-Ilfov, Romania. *Agriculture*, 15(4), 406. <https://doi.org/10.3390/agriculture15040406>
- Dreby, J. y Rodríguez-Pacas, F. (2020). Entre la espada y la pared: agricultores familiares en la zona occidental del Valle Central de Costa Rica. *Ciencias Sociales*, 172, 13-33. <https://revistas.ucr.ac.cr/index.php/sociales/article/download/49928/49939/203300>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing Of Environment*, 120, 25-36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Escobedo-Tamez, A. N. y Yépez-Rincón, F. D. (2019). *Diseño y evaluación de un método de inspección no destructivo para ubicar y determinar características geométricas de zonas con agrietamientos en estructuras de concreto reforzado*. [Tesis de Licenciatura en Ingeniería Civil, Universidad Autónoma de Nuevo León]. <http://eprints.uanl.mx/18318/>

- Esri, Inc. (2021). *¿Qué es la clasificación de imagen?—ArcMap | Documentación*. ArcGIS Desktop. <https://desktop.arcgis.com/es/arcmap/latest/extensions/spatial-analyst/image-classification/what-is-image-classification-.htm>
- FAO. (2021). El estado de los recursos de tierras y aguas del mundo para la alimentación y la agricultura - Sistemas al límite. Informe de síntesis 2021. [FAO eBooks]. En *FAO eBooks*. Organización de las Naciones Unidas para la Alimentación y la Agricultura Roma, 2021. <https://doi.org/10.4060/cb7654es>
- Franceschini, G., & Ali, M. (2022). Introductory course to Google Earth Engine. En *FAO eBooks*. Food and Agriculture Organization of the United Nations. <https://doi.org/10.4060/cb9049en>
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80(1), 185-201. [https://doi.org/10.1016/s0034-4257\(01\)00295-4](https://doi.org/10.1016/s0034-4257(01)00295-4)
- Gaitán-Álvarez, J. (2013). *Evaluación de erosión hídrica en suelos bajo cobertura forestal y agrícola, en la Cuenca del Río Reventazón, Costa Rica* [Licenciatura en Ingeniería Forestal, Instituto Tecnológico de Costa Rica]. <https://acortar.link/fm6rPo>
- Geoinformacion. (2020, 24 enero). *Google Earth Engine - Índice de Vegetación - NDVI - Sentinel-2 Landsat 8* [Video]. YouTube. <https://www.youtube.com/watch?v=wEf4TqYcYOQ>
- GeoSage. (2025). *Advanced software to RAPIDLY process Sentinel-2 and Landsat-8 imagery: band combinations, pan-sharpening, image fusion, feature extraction*. https://www.geosage.com/highview/features_sentinel2.html
- GISGeography. (2024, marzo 10). *Supervised and Unsupervised Classification in Remote Sensing. GIS Geography*. <https://gisgeography.com/supervised-unsupervised-classification-arcgis/>
- GIS Madras. (2025, 29 abril). *How to Import Landsat 8 image in Google Earth Engine | Beginners* [Video]. YouTube. https://www.youtube.com/watch?v=l_RflhWybnk

- González Gamboa, V., Muñoz Jiménez, R., Vargas Bolaños, C., & Durán Monge, E. (2021). Descripción de cambios de uso del suelo en Costa Rica: 1986-2019. En *Estado de la Nación*. Informe Estado de la Nación 2021. <https://acortar.link/U6nf9O>
- Google Cloud Tech. (2021, 20 octubre). *What is Google Earth Engine?* [Video]. YouTube. https://www.youtube.com/watch?v=5fQn_CMPwfU
- Grajales, T. (2000). Desarrollo de un nuevo concepto de investigación. *Revista de la Universidad Adventista del Plata*, 12(2), 41-64. <https://dialnet.unirioja.es/servlet/articulo?codigo=7358957>
- Habib, W., & Connolly, J. (2023). A national-scale assessment of land use change in peatlands between 1989 and 2020 using Landsat data and Google Earth Engine—a case study of Ireland. *Regional Environmental Change*, 23(4). <https://doi.org/10.1007/s10113-023-02116-0>
- Hidalgo Bucheli, G. (2019). Uso del Índice de Moran y LISA para explicar el ausentismo electoral rural en Ecuador. *Revista Geográfica* 160, 91-106. <https://revistasipgh.org/index.php/regeo/article/download/746/880/2228>
- Huete, A., Didan, K., Miura, T., Rodríguez, E., Gao, X., & Ferreira, L. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213. [https://doi.org/10.1016/s0034-4257\(02\)00096-2](https://doi.org/10.1016/s0034-4257(02)00096-2)
- Inostroza, L., Baur, R., & Csaplovics, E. (2012). Urban sprawl and fragmentation in Latin America: A dynamic quantification and characterization of spatial patterns. *Journal Of Environmental Management*, 115, 87-97. <https://doi.org/10.1016/j.jenvman.2012.11.007>
- Instituto Nacional de Estadística y Geografía (INEGI). (2022). *Índice de Vegetación de Diferencia Normalizada NDVI Landsat, 1984-2021* (1.a ed.). <https://www.inegi.org.mx/app/biblioteca/ficha.html?upc=889463908272>

- Instituto Meteorológico Nacional de Costa Rica (IMN). (2024). Pronóstico estacional: Febrero a abril de 2024. En *IMN*. Comité Técnico del Pronóstico Estacional del IMN (CTPE). <https://acortar.link/7vHpMS>
- Instituto Nacional de Estadísticas y Censos (INEC). (2018). Estadísticas demográficas. 2011 – 2025. Proyecciones nacionales. Población total proyectada al 30 de junio por grupos de edades, según provincia, cantón, distrito y sexo. <https://inec.cr/tematicas/listado?topics=91%252C646&documentTypes=results>
- Imran-Hossain, Md. (2022). *Support Vector Machine*. Frankfurt University of Applied Sciences. <https://www.researchgate.net/profile/Md-Hossain-794>
- Jaramillo, L., & Antunes, A. (2018). Detección de cambios en la cobertura vegetal mediante interpretación de imágenes Landsat por redes neuronales artificiales (RNA). Caso de estudio: Región Amazónica Ecuatoriana. *Revista de Teledetección*, 51, 33. <https://doi.org/10.4995/raet.2018.8995>
- Judith, J., Tamilselvi, R., Beham, M. P., Lakshmi, S. S. P., et al. (2025). *Remote Sensing Based Crop Health Classification Using NDVI and Fully Connected Neural Networks*. ArXiv. <https://doi.org/10.48550/arXiv.2504.10522>
- Kriegler FJ, Malila WA, Nalepka RF, & Richardson W. (1969). Preprocessing transformations and their effect on multispectral recognition. *Remote Sens Environ*, 6: 97–132.
- Lazarte Reátegui, H. y Peña Corahua, J. (2023). Urbanización agrícola. Desequilibrio espacial urbano/rural y afectación en la economía agrícola. *ARQUITEXTOS*, 30(38), enero-diciembre de 2023 - Universidad César Vallejo, 89-64. <https://revistas.urp.edu.pe/index.php/Arquitextos/article/view/6199/9644>
- Liu, Z., Chen, G., Tang, B., Wen, Q., Tan, R., & Huang, Y. (2024). Regional scale terrace mapping in fragmented mountainous areas using multi-source remote sensing data and sample purification strategy. *The Science Of The Total Environment*, 925, 171366. <https://doi.org/10.1016/j.scitotenv.2024.171366>

- MasterGIS. (2021, 28 enero). *Google Earth Engine en QGIS para el cálculo de NDVI* [Video]. YouTube. <https://www.youtube.com/watch?v=YUMY7avwkCs>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817. <https://doi.org/10.1080/01431161.2018.1433343>
- McCall, M. K., & Dunn, C. E. (2011). Geo-information tools for participatory spatial planning: Fulfilling the criteria for 'good' governance? *Geoforum*, 43(1), 81-94. <https://doi.org/10.1016/j.geoforum.2011.07.007>
- Méndez Cordonero, S. (2024). *Aplicación del algoritmo BFAST como método de análisis del comportamiento espacio temporal de la cobertura terrestre. caso de estudio: Refugio Nacional e Vida Silvestre Peñas Blancas, periodo 2009-2019*. [Licenciatura en Ciencias Geográficas con énfasis en Ordenamiento del Territorio]. Universidad Nacional.
- Miller, S. N., Semmens, D. J., Goodrich, D. C., Hernandez, M., Miller, R. C., Kepner, W. G., & Guertin, D. P. (2007). The Automated Geospatial Watershed Assessment tool. *Environmental Modelling and Software*, 22(3), 365–377. <https://doi.org/10.1016/j.envsoft.2005.12.004>
- Ministerio de Transportes, Movilidad y Agenda Urbana. (2018). *El programa Copernicus aplicado a la producción y gestión de la información geoespacial* (1.a ed.). Gobierno de España - Copernicus. <https://acortar.link/GWjWKO>
- Molina, A., López, L., y Villegas, G. (2005). Los Sistemas de Información Geográfica (SIG) en la planificación municipal. *Revista EIA*, 4, 21–31. <http://www.scielo.org.co/pdf/eia/n4/n4a03.pdf>
- Montero, A., Marull, J., Tello, E., Cattaneo, C., Coll, F., Pons, M., Infante-Amate, J., Urrego-Mesa, A., Fernández-Landa, A., & Vargas, M. (2021). The impacts of agricultural and urban land-use changes on plant and bird biodiversity in Costa Rica (1986–2014). *Regional Environmental Change*, 21(2). <https://doi.org/10.1007/s10113-021-01767-1>

- Mora, R. y Pirulli, M. (2017). Deslizamiento Las Torres, volcán Irazú, Costa Rica: definición de su volumen y su dirección preferencial de movimiento. *Revista Geológica de América Central*, 56. <https://doi.org/10.15517/rgac.v0i56.29236>
- Morán-Ordóñez, A., Hermoso, V., & Martínez-Salinas, A. (2022). Multi-objective forest restoration planning in Costa Rica: Balancing landscape connectivity and ecosystem service provisioning with sustainable development. *Journal Of Environmental Management*, 310, 114717. <https://doi.org/10.1016/j.jenvman.2022.114717>
- Morera-Beita, C., Sandoval-Murillo, L. F., & Alfaro-Alvarado, L. D. (2021). *Assessment of biological corridors in Costa Rica: landscape structure and connectivity-fragmentation processes*. *Revista Geográfica de América Central*, 66, 106-132. <https://www.scielo.sa.cr/pdf/rge/n66/2215-2563-rge-66-106.pdf>
- Mutanga, O., & Kumar, L. (2019). Google Earth Engine Applications. *Remote Sensing*, 11(5), 591. <https://doi.org/10.3390/rs11050591>
- Navarro-González, T. E. (2023). *Diseño de un modelo multicriterio con base SIG para mapeo de riesgo por incendios forestales en la Sierra Madre Oriental* [Tesis de Licenciatura en Ingeniería Civil, Universidad Autónoma de Nuevo León]. <http://eprints.uanl.mx/25731/7/25731.pdf>
- NDVI: *Fórmula y uso del Índice de Vegetación en Agricultura*. (2021, septiembre 27). EOS Data Analytics. <https://eos.com/es/make-an-analysis/ndvi/>
- Ochoa, F. (2023). *¿Qué es un análisis multitemporal?* <https://acortar.link/lZbm2Y>
- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing Of Environment*, 148, 42-57. <https://doi.org/10.1016/j.rse.2014.02.015>
- Orellana Díaz, O. y Jiménez, A. (2018). *Introducción Básica a Google Earth Engine (GEE). Conociendo su Interfaz*. Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH. <https://doi.org/10.13140/RG.2.2.11217.13929>

- Pal, M., & Foody, G. M. (2010). Feature selection for classification of hyperspectral data by SVM. *IEEE Transactions on Geoscience and Remote Sensing*, 48(5), 2297-2307. <https://doi.org/10.1109/tgrs.2009.2039484>
- Pandeypranjal. (2020). *Machine Learning: unsupervised learning*. The Data Science Portal. <https://thedata-scienceportal.com/posts/unsupervised-learning/>
- Peña-Zamalloa, G. R. (2021). Clasificación espacial del suelo urbano por el valor especulativo del suelo e imágenes MSI satelitales usando K-MEANS, Huancayo, Perú. *Revista Urbano*, 24(44), 70-83. <https://doi.org/10.22320/07183607.2021.24.44.06>
- Peñaloza, Y. H. y Peñaloza, A. H. (2018). Aplicación de un Clúster de Máquinas Físicas y Virtuales para la reducción de tiempo de Segmentación en la Clasificación de Imágenes Satelitales utilizando Computación Paralela y Redes Neuronales. *Proceedings Of The 16th LACCEI International Multi-Conference For Engineering, Education, And Technology: "Innovation In Education And Inclusion"*. <https://acortar.link/stF72j>
- Pérez, D. (2007) Introducción a los Sensores Remotos - Aplicaciones en Geología (Curso teórico – práctico). *IDEM* (p.1-45). Universidad de Buenos Aires
- Pérez Romero, J., Mesas Carrascosa, J. y Navarro Cerrillo, R. (2024). Capítulo 7: Google Earth Engine aplicado a ciencias forestales. En *Geociencias aplicadas a la gestión forestal* (1.ª ed., pp. 189-218). Geoforest. <https://acortar.link/ryjZgO>
- Pettorelli, N., Vik, J. O., Mysterud, A., Gaillard, J., Tucker, C. J., & Stenseth, N. C. (2005). Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends In Ecology & Evolution*, 20(9), 503-510. <https://doi.org/10.1016/j.tree.2005.05.011>
- Pinheiro, M. V., Sánchez, L. R., Long, S. C., & Ponce, A. (2020). *Environmental Governance Indicators for Latin America & the Caribbean: A Cross-Country Assessment of Environmental Governance in Practice in Argentina, Bolivia, Brazil, Colombia, Costa Rica, the Dominican Republic, El Salvador, Jamaica, Peru & Uruguay*. <https://doi.org/10.18235/0002398>

- Quesada-Román, A., Castro-Chacón, J. P., & Boraschi, S. F. (2021). Geomorphology, land use, and environmental impacts in a densely populated urban catchment of Costa Rica. *Journal Of South American Earth Sciences*, *112*, 103560. <https://doi.org/10.1016/j.jsames.2021.103560>
- RemOT Technologies. (2020). *Análisis de patrones espaciales con QGIS*. Geoinnova. <https://geoinnova.org/blog-territorio/analisis-de-patrones-espaciales-con-qgis/>
- Roerink, G., Menenti, M., Soepboer, W., & Su, Z. (2003). Assessment of climate impact on vegetation dynamics by using remote sensing. *Physics And Chemistry Of The Earth Parts A/B/C*, *28*(1-3), 103-109. [https://doi.org/10.1016/s1474-7065\(03\)00011-1](https://doi.org/10.1016/s1474-7065(03)00011-1)
- Sacristán, F. (2005). La Teledetección satelital y los sistemas de protección ambiental. *Civilizar*. <https://doi.org/10.22518/16578953.701>
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science/SN Computer Science*, *2*(3). <https://doi.org/10.1007/s42979-021-00592-x>
- Seto, K. C., Güneralp, B., & Hutyrá, L. R. (2012). Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools. *Proceedings Of The National Academy Of Sciences*, *109*(40), 16083-16088. <https://doi.org/10.1073/pnas.1211658109>
- Siabato, W. y Guzmán-Manrique, J. (2019). La autocorrelación espacial y el desarrollo de la geografía cuantitativa. *Cuadernos de Geografía Revista Colombiana de Geografía*, *28*(1), 1-22. <https://doi.org/10.15446/rcdg.v28n1.76919>
- Sidey-Gibbons, J. A. M., & Sidey-Gibbons, C. J. (2019). *Machine learning in medicine: a practical introduction*. *19*(1), 1-18. <https://doi.org/10.1186/s12874-019-0681-4>
- Sistema Costarricense de Información Jurídica (SCIJ). (2009, 2 de septiembre). *Declaración oficial para efectos administrativos, la aprobación de la División Territorial Administrativa de la República (Decreto Ejecutivo N.º 41548-MGP)*. <https://acortar.link/LDJ2I7>

Sistema Nacional de Monitoreo de la Cobertura y Uso de la Tierra y Ecosistemas (SIMOCUTE), Ministerio de Ambiente y Energía (MINAE); Ministerio de Agricultura y Ganadería (MAG); y Ministerio de Justicia y Paz/Registro Nacional/Instituto Geográfico Nacional (IGN). (2023). *Sistema de Clasificación de la Cobertura y Uso de la Tierra para Costa Rica: versión 2.0*. San José, Costa Rica. Ed. H. Acevedo y. Villalobos. 48 páginas.

https://www.minae.go.cr/organizacion/vicegestionestrategica/CENIGA/Documentos/2_SIMOCUTE_DOCS/7_Sistema_de_Clasificacion_Cobertura_y_Uso_v2.pdf

Solórzano, J. V., y Perilla, G. (2022). Cómo usar Google Earth Engine y no fallar en el intento. En *Universidad Nacional Autónoma de México, Centro de Investigaciones en Geografía Ambiental eBooks*. <https://doi.org/10.22201/ciga.9786073066969e.2022>

Solórzano, J. C., y Vargas, C. Q. (2006). *Costa Rica en el siglo XVI: descubrimiento, exploración y conquista*. Editorial Universidad de Costa Rica.

Stehman, S. V., & Czaplewski, R. L. (1998). Design and Analysis for Thematic Map Accuracy Assessment. *Remote Sensing Of Environment*, 64(3), 331-344. [https://doi.org/10.1016/s0034-4257\(98\)00010-8](https://doi.org/10.1016/s0034-4257(98)00010-8)

Tejido-Murias, I., Anta, M. B. y Sánchez, C. A. L. (2023). Clasificación automática de coberturas forestales a partir de imágenes Sentinel-2 y datos auxiliares mediante Google Earth Engine. *Cuadernos de la Sociedad Española de Ciencias Forestales*, 49(2), 161-184. <https://doi.org/10.31167/csecfv5i49.19935>

Tesfaye, W., Elias, E., Warkineh, B., Tekalign, M., & Abebe, G. (2024). Modeling of land use and land cover changes using google earth engine and machine learning approach: implications for landscape management. *Environmental Systems Research*, 13(1). <https://doi.org/10.1186/s40068-024-00366-3>

Tobar-Díaz, R., Gao, Y., Mas, J. F. y Cambrón-Sandoval, V. H. (2023). Clasificación de uso y cobertura del suelo a través de algoritmos de aprendizaje automático: revisión bibliográfica. *Revista de Teledetección*, 62, 1-19. <https://polipapers.upv.es/index.php/raet/article/view/19014>

- Toribio, G. (2019). NDVI, ¿qué es y para qué sirve? *Cursos teledetección*.
<https://www.cursosteledeteccion.com/ndvi-que-es-y-para-que-sirve/>
- Treminio Sánchez, I. (2018). Fragmentación y segregación social del espacio urbano de la Gran Área Metropolitana de San José. En *Laboratoire Mixte International (LMI - Meso)*. FLACSO COSTA RICA. <https://meso.hypotheses.org/files/2023/10/Policy-brief-san-josé-costa-rica.pdf>
- Trujillo-Jiménez, M., Liberoff, A., Pessacg, N., Pacheco, C. y Flaherty, S. (2021). Metodología de clasificación automática de uso y cobertura de suelo: Uso de Métodos de Aprendizaje Automático y teledetección para clasificación de uso y cobertura del suelo en un valle semiárido de la Patagonia. *Repositorio Institucional CONICET Digital*, 175-188. <https://sedici.unlp.edu.ar/handle/10915/140748>
- Tsutsumida, N., & Kato, A. (2024). Reducing Investigator Bias in Sampling-Based Land Cover Classification by Integrating Multiple Investigators' Maps Using a Multiple Classifier System. *arXiv (Cornell University)*.
<https://doi.org/10.48550/arxiv.2403.15720>
- Understanding RS-GIS & Geography. (2024, 28 agosto). *Full Tutorial || Basic Google Earth Engine Part 1* || [Video]. YouTube.
<https://www.youtube.com/watch?v=vgMHb74qwgU>
- Urrego, P., Pasqualotto, N. y Delegido, J. (2020). *Introducción a la teledetección y aplicaciones medioambientales del programa europeo Copernicus. Calidad de aguas continentales* (1.^a ed.). Universitat de València. https://www.copernicus-user-uptake.eu/fileadmin/FPCUP/dateien/resources/2018-2-23/Tutorial_Copernicus_2020_Oporto_03.pdf
- Vaddi, R., Kumar, B. P., Manoharan, P., Agilandeewari, L., & Sangeetha, V. (2024). Strategies for dimensionality reduction in hyperspectral remote sensing: A comprehensive overview. *The Egyptian Journal of Remote Sensing and Space Sciences*, 27(1), 82-92. <https://doi.org/10.1016/j.ejrs.2024.01.005>

- Van Genderen, J., Lock, B., & Vass, P. (1978). Remote Sensing: Statistical Testing of Thematic Map Accuracy. *Remote Sensing Of Environment*, 7(1), 3-14. [https://doi.org/10.1016/0034-4257\(78\)90003-2](https://doi.org/10.1016/0034-4257(78)90003-2)
- Vargas, C. R. y Nienhuis, J. (2012). Cultivo protegido de hortalizas en Costa Rica. *Tecnología En Marcha*, 25(2), 10. <https://doi.org/10.18845/tm.v25i2.303>
- Vásquez, A. (1996). El ordenamiento territorial y los cambios en el uso de la tierra en Costa Rica. *Agronomía Costarricense*, 20(1), 87-94. https://www.mag.go.cr/rev_agr/v20n01_087.pdf
- Velastegui-Montoya, A., Montalván-Burbano, N., Carrión-Mero, P., Rivera-Torres, H., Sadeck, L., & Adami, M. (2023). Google Earth Engine: A Global Analysis and Future Trends. *Remote Sensing*, 15(14), 3675. <https://doi.org/10.3390/rs15143675>
- Verma, V. K., & Verma, S. J. M. T. P. (2021). Machine learning applications in healthcare sector: An overview. *Materials Today: Proceedings*, 57, 2144-2147. <https://doi.org/10.1016/j.matpr.2021.12.101>
- Yan, K., Gao, S., Yan, G., Ma, X., Chen, X., Zhu, P., Li, J., Gao, S., Gastellu-Etchegorry, J., Myneni, R. B., & Wang, Q. (2025). A global systematic review of the remote sensing vegetation indices. *International Journal Of Applied Earth Observation And Geoinformation*, 139, 104560. <https://doi.org/10.1016/j.jag.2025.104560>

9. ANEXOS

Anexo 1. Bandas de los satélites Sentinel-2

Banda Sentinel-2	Longitud de onda central (μm)	Resolución espacial (m)
Banda 1 – coastal aerosol	0.443	60
Banda 2 - azul	0.490	10
Banda 3 – verde	0.560	10
Banda 4 – rojo	0.665	10
Banda 5 – Vegetation Red	0.705	20
Banda 6 – Vegetation Red	0.740	20
Banda 7 – Vegetation Red	0.783	20
Banda 8 – NIR	0.842	10
Banda 8A – Vegetation Red	0.842	20
Banda 9 – Vapor de agua	0.945	60
Banda 10 – SWIR – cirros	1.375	60
Banda 11 - SWIR	1.610	20
Banda 12 - SWIR	2.190	20

Fuente: Ministerio de Transportes, Movilidad y Agenda Urbana (2018)

Anexo 2. Muestra de los puntos para la verificación de campo

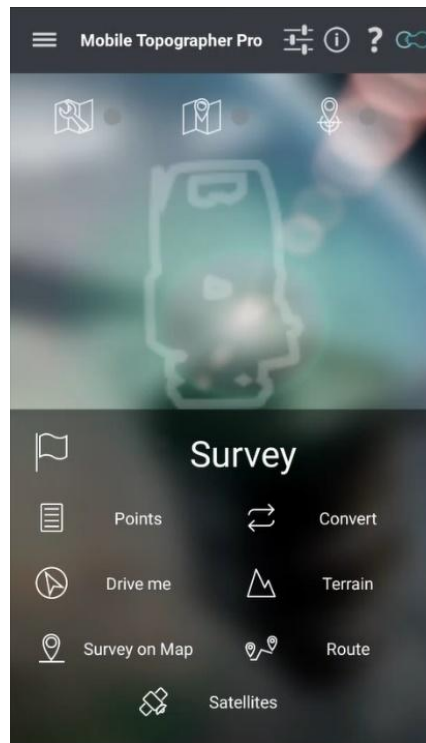
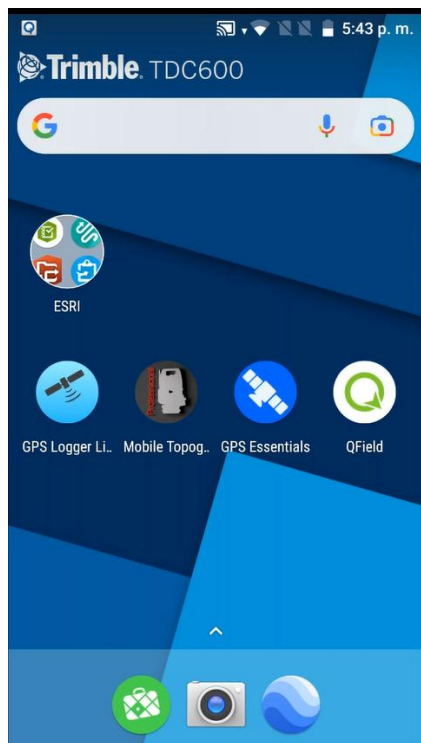
puntos_muestreo— Objetos Totales: 1050, Filtrados: 1050, Seleccionados: 0

	creator	time	lat	long	elev	time2	id	clase	POINT_X	POINT_Y	obser
1	Trimble TDC600	29/11/2024	9.8492...	-83.87509...	1369.82...	28/12/2024	1	Pastizales	513699.09876899997	1089069.142569999...	NULL
2	Trimble TDC600	29/11/2024	9.8420...	-83.87157...	1340.66...	28/12/2024	2	Bosques	514085.55516200000	1088280.104689999...	NULL
3	Trimble TDC600	29/11/2024	9.8528...	-83.88635...	1382.45...	28/12/2024	3	Áreas urbanas	512464.74849700002	1089472.129500000...	NULL
4	Trimble TDC600	29/11/2024	9.8357...	-83.87348...	1330.00...	28/12/2024	4	Bosques	513877.10940600000	1087581.865260000...	NULL
5	Trimble TDC600	29/11/2024	9.8346...	-83.87341...	1332.71...	28/12/2024	5	Bosques	513884.55476500001	1087463.405560000...	NULL
6	Trimble TDC600	29/11/2024	9.8477...	-83.87089...	1340.00...	28/12/2024	6	Cuerpos de agua	514160.70851099998	1088906.414140000...	NULL
7	Trimble TDC600	29/11/2024	9.8516...	-83.88757...	1380.00...	28/12/2024	7	Áreas urbanas	512330.60442900000	1089340.744720000...	NULL
8	Trimble TDC600	29/11/2024	9.8484...	-83.87842...	1368.37...	28/12/2024	8	Cuerpos de agua	513334.731115100001	1088985.768480000...	Lago artificial
9	Trimble TDC600	29/11/2024	9.8567...	-83.88169...	1429.73...	28/12/2024	9	Pastizales	512975.63456899999	1089899.860030000...	NULL
10	Trimble TDC600	29/11/2024	9.8456...	-83.89281...	1357.71...	28/12/2024	10	Pastizales	511755.75262900000	1088677.373660000...	NULL
11	Trimble TDC600	29/11/2024	9.8531...	-83.87646...	1386.55...	28/12/2024	11	Tierras agrícolas	513548.94608899998	1089508.648180000...	NULL
12	Trimble TDC600	29/11/2024	9.8539...	-83.87652...	1402.99...	28/12/2024	12	Bosques	513542.12166900001	1089593.628310000...	NULL
13	Trimble TDC600	29/11/2024	9.8371...	-83.87196...	1327.53...	28/12/2024	13	Pastizales	514043.10925799998	1087737.798819999...	NULL
14	Trimble TDC600	29/11/2024	9.8550...	-83.88445...	1405.17...	28/12/2024	14	Tierras agrícolas	512672.75145799998	1089718.897780000...	NULL
15	Trimble TDC600	29/11/2024	9.8508...	-83.87258...	1350.05...	28/12/2024	15	Suelo descubier...	513974.46447599999	1089246.067550000...	NULL
16	Trimble TDC600	29/11/2024	9.8410...	-83.87190...	1338.54...	28/12/2024	16	Bosques	514049.81808300002	1088165.286439999...	NULL
17	Trimble TDC600	29/11/2024	9.8462...	-83.88574...	1370.45...	28/12/2024	17	Bosques	512531.18558799999	1088747.389050000...	NULL
18	Trimble TDC600	29/11/2024	9.8431...	-83.87649...	1360.00...	28/12/2024	18	Áreas urbanas	513546.48812599998	1088404.423789999...	NULL
19	Trimble TDC600	29/11/2024	9.8553...	-83.87494...	1403.42...	28/12/2024	19	Bosques	513715.52288399998	1089750.399380000...	NULL
20	Trimble TDC600	29/11/2024	9.8463...	-83.88922...	1365.30...	28/12/2024	20	Áreas urbanas	512149.90868599998	1088751.599769999...	NULL
21	Trimble TDC600	29/11/2024	9.8504...	-83.88197...	1377.89...	28/12/2024	21	Pastizales	512944.51156800002	1089201.840709999...	NULL
22	Trimble TDC600	29/11/2024	9.8346...	-83.87881...	1340.77...	28/12/2024	22	Áreas urbanas	513292.48423700000	1087464.246899999...	NULL
23	Trimble TDC600	29/11/2024	9.8626...	-83.88428...	1449.82...	28/12/2024	23	Pastizales	512691.43464300002	1090558.693740000...	NULL
24	Trimble TDC600	29/11/2024	9.8455...	-83.87177...	1340.99...	28/12/2024	24	Suelo descubier...	514064.04649799998	1088663.857090000...	NULL
25	Trimble TDC600	29/11/2024	9.8511...	-83.88145...	1380.22...	28/12/2024	25	Cuerpos de agua	513001.56279699999	1089280.133529999...	NULL
26	Trimble TDC600	29/11/2024	9.8590...	-83.88355...	1440.59...	28/12/2024	26	Suelo descubier...	512771.11718800000	1090162.283559999...	NULL
27	Trimble TDC600	29/11/2024	9.8456...	-83.88951...	1364.02...	28/12/2024	27	Cuerpos de agua	512118.33499200002	1088670.916050000...	NULL
28	Trimble TDC600	29/11/2024	9.8440...	-83.88269...	1362.25...	28/12/2024	28	Áreas urbanas	512866.12139699998	1088500.944330000...	NULL
29	Trimble TDC600	29/11/2024	9.8388...	-83.88251...	1355.57...	28/12/2024	29	Áreas urbanas	512886.15142299997	1087927.295600000...	NULL
30	Trimble TDC600	29/11/2024	9.8589...	-83.88411...	1431.25...	28/12/2024	30	Cuerpos de agua	512709.82990399998	1090142.176010000...	NULL
31	Trimble TDC600	29/11/2024	9.8519...	-83.87246...	1360.91...	28/12/2024	31	Pastizales	513987.51729200000	1089375.632049999...	NULL

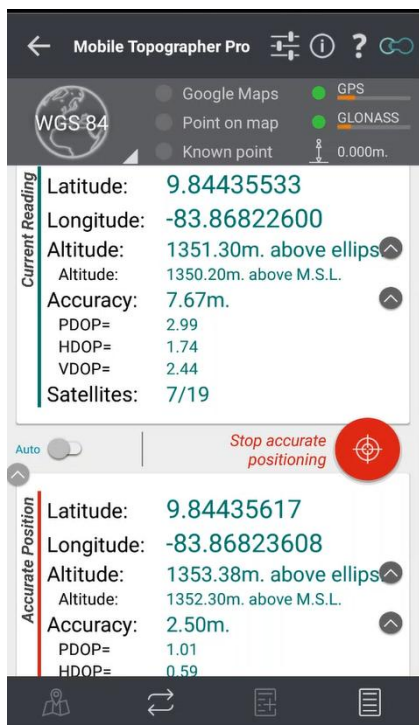
Mostrar todos los objetos espaciales

Anexo 3. Datos en campo con Trimble TDC 600

- Utilización de la aplicación *Mobile Topographer*



- Verificación de los puntos con *Survey On Map*



Anexo 4. Registro fotográfico de las categorías de entrenamiento

Categoría Áreas urbanas



Categoría Bosques



Categoría Cuerpos de agua



Categoría Pastizales



Categoría Suelo descubierto



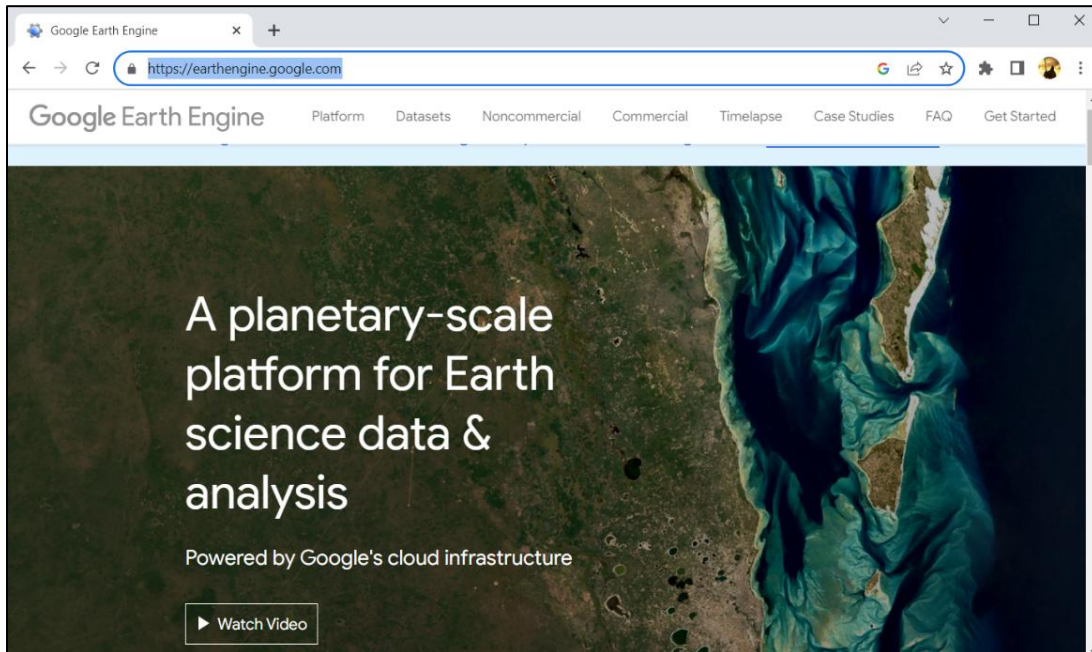
Categoría Tierras agrícolas



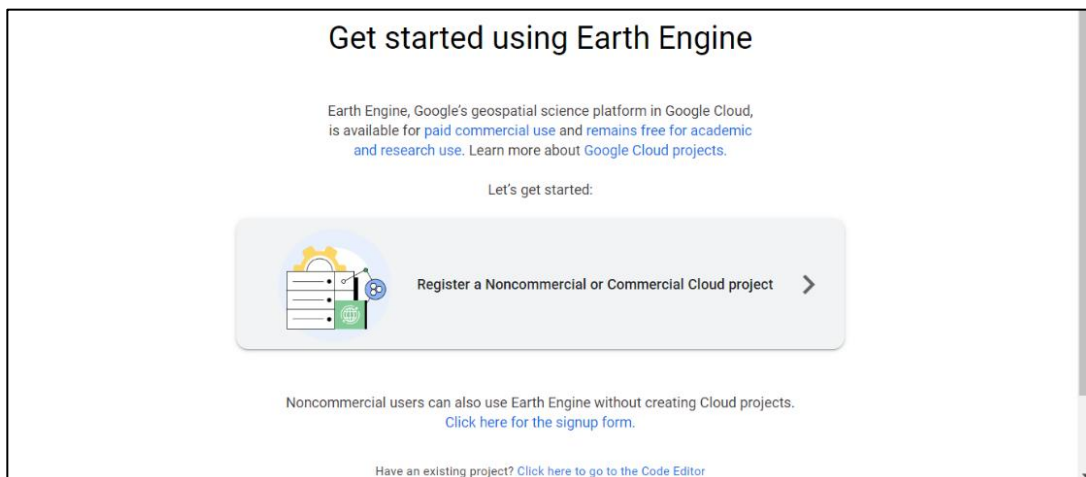
Anexo 5. Pasos preliminares para utilizar GEE

Paso 1: Creación de la cuenta Google Earth Engine (GEE).

- Nos dirigimos al sitio oficial de GEE¹

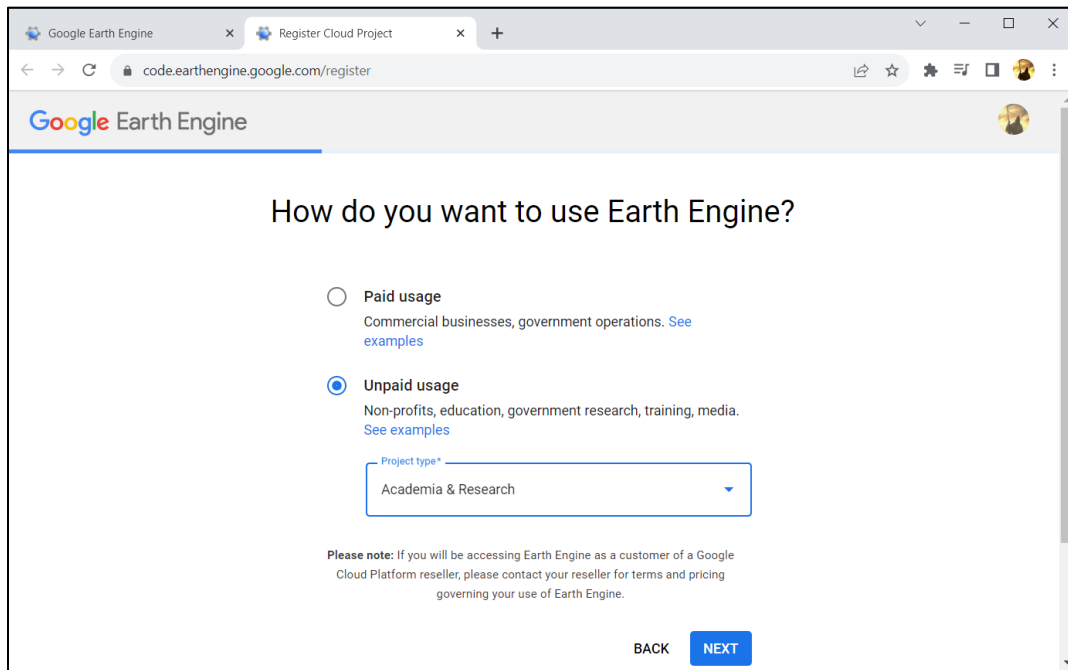


Para la generación de la cuenta (al ingresar a la opción *Get Started*), se utiliza una cuenta de Gmail para obtener acceso. Posteriormente, se solicita lo siguiente:



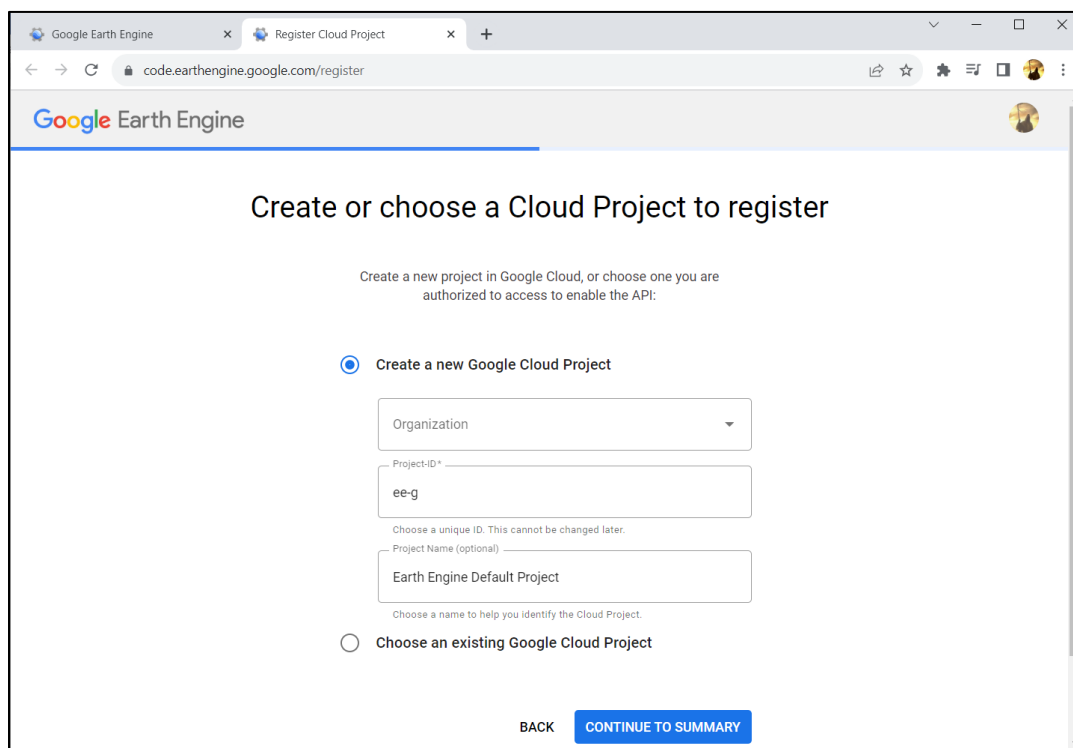
¹ Los enlaces de las diferentes páginas utilizadas se muestran como hipervínculos en los nombres cada herramienta, de manera que el lector pueda consultar las páginas correspondientes.

Se selecciona el tipo de cuenta según los objetivos de uso. La principal diferencia es que en la opción paga es posible mantener almacenados nuestros proyectos.



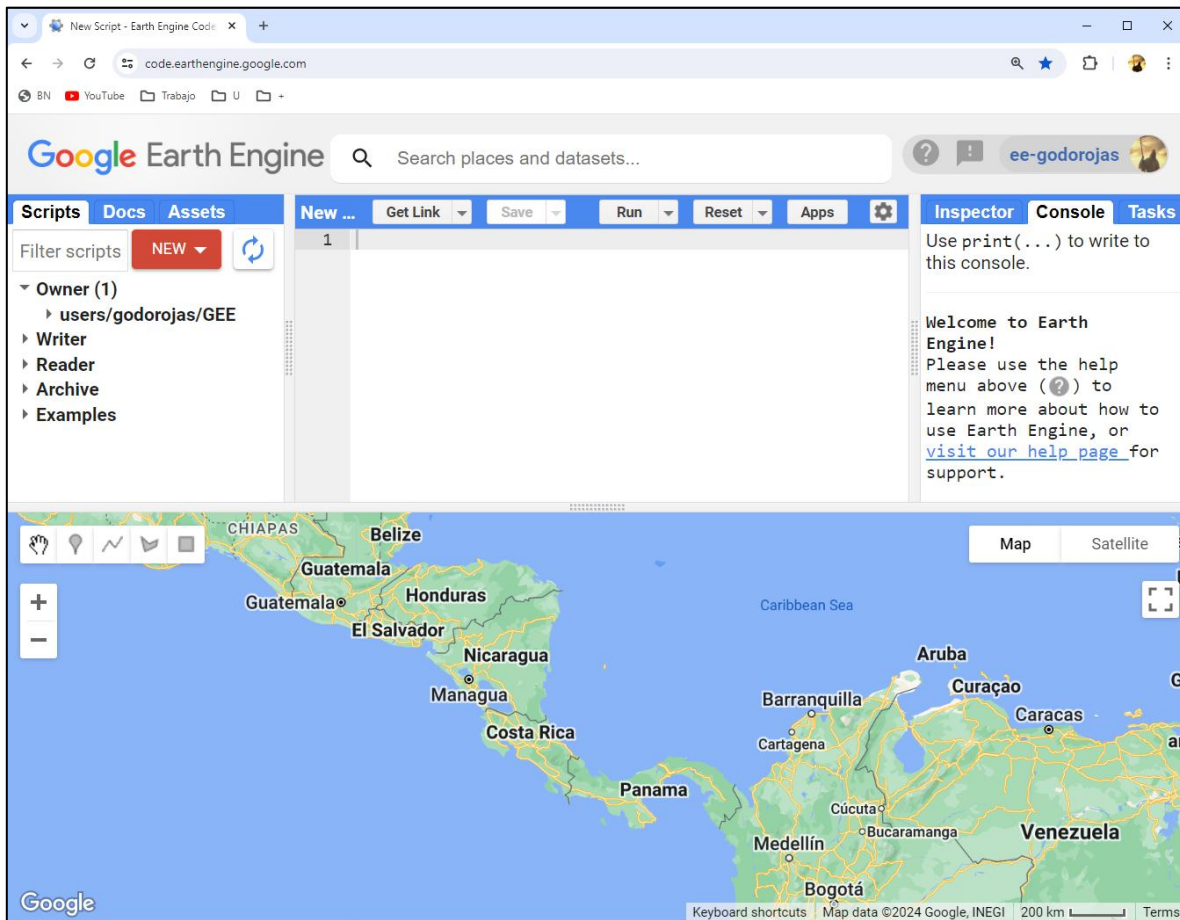
The screenshot shows the registration page for Google Earth Engine. The title is "How do you want to use Earth Engine?". There are two radio button options: "Paid usage" (unselected) and "Unpaid usage" (selected). The "Unpaid usage" option includes the text "Non-profits, education, government research, training, media. See examples". Below the options is a dropdown menu labeled "Project type*" with "Academia & Research" selected. A "Please note" section is present, followed by "BACK" and "NEXT" buttons.

Se crea el primer proyecto:



The screenshot shows the registration page for Google Earth Engine. The title is "Create or choose a Cloud Project to register". The text says "Create a new project in Google Cloud, or choose one you are authorized to access to enable the API:". There are two radio button options: "Create a new Google Cloud Project" (selected) and "Choose an existing Google Cloud Project" (unselected). Under "Create a new Google Cloud Project", there are three input fields: "Organization" (dropdown), "Project-ID*" (text input with "ee-g" entered), and "Project Name (optional)" (text input with "Earth Engine Default Project" entered). A "Please note" section is present, followed by "BACK" and "CONTINUE TO SUMMARY" buttons.

Posteriormente, después de conocer el entorno podemos ingresar a la página principal de GEE para poder crear el proyecto.



Paso 2: Exploración y opciones de la plataforma Google Earth Engine

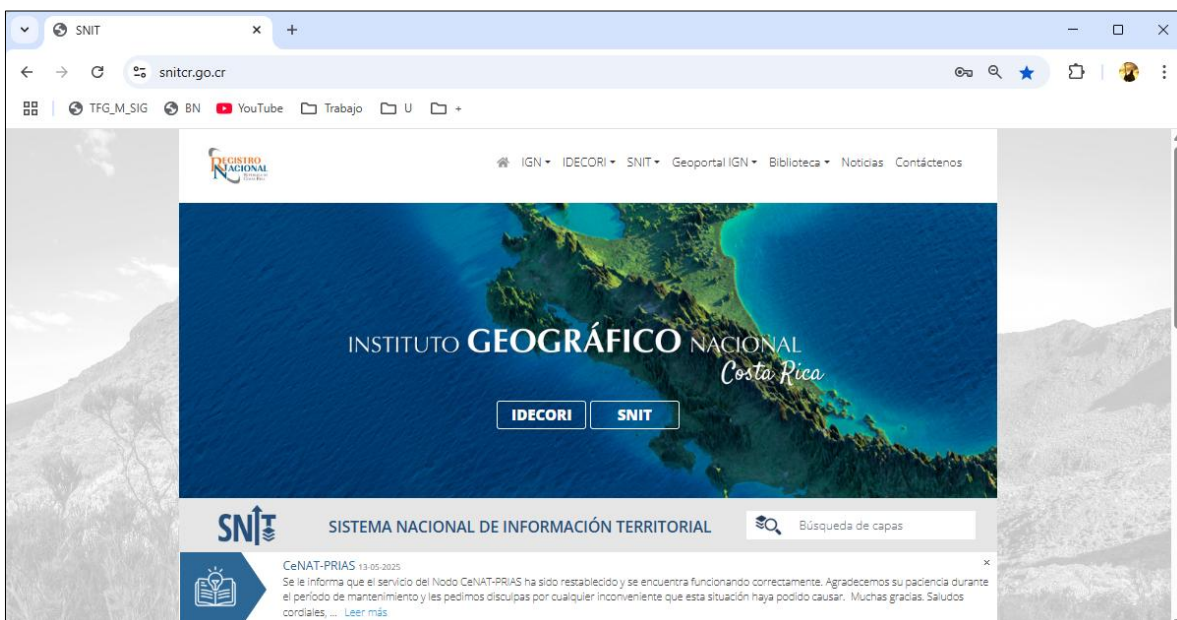
Siempre se deben considerar estos puntos:

- **Acceso a Datos Globales:** GEE ofrece acceso a una vasta colección de datos geospaciales globales que incluye imágenes satelitales de diferentes sensores como Sentinel-2, Landsat y MODIS. Estos datos están disponibles de manera gratuita para análisis y procesamiento.
- **Herramientas de Análisis Avanzadas:** La plataforma proporciona herramientas avanzadas para análisis geospacial como el cálculo de índices vegetativos (por ejemplo, NDVI), clasificaciones de imágenes supervisadas y no supervisadas, segmentación de imágenes y análisis de series temporales.

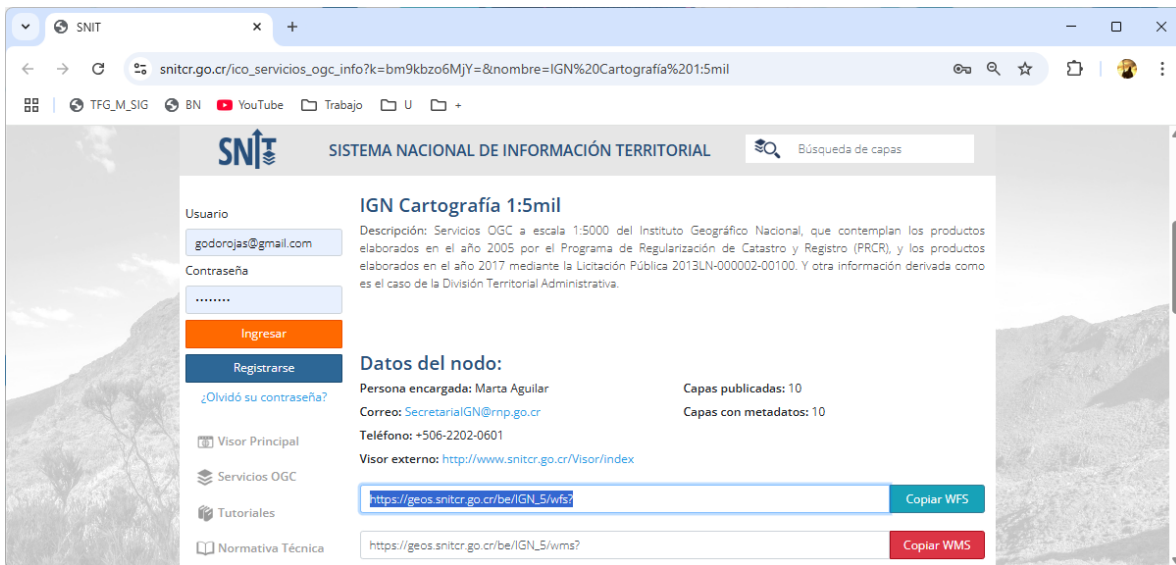
- **Capacidades de Procesamiento en la Nube:** GEE utiliza la infraestructura de Google Cloud para ofrecer capacidades de procesamiento en la nube de alto rendimiento. Esto permite realizar análisis complejos a gran escala sin necesidad de recursos computacionales locales avanzados.
- **Visualización Interactiva:** Permite la visualización interactiva de resultados mediante mapas y gráficos directamente en el navegador. Los usuarios pueden explorar y compartir visualizaciones de datos geoespaciales de manera efectiva.
- **Integración con Google Earth y otros Servicios:** GEE se integra con Google Earth y otros servicios de Google que facilita la combinación de datos satelitales con otras capas de información geográfica, así como la exportación de resultados para análisis adicionales en entornos de escritorio.

Paso 3: Definición del área de estudio por medio de QGIS

- Se definirá el área de estudio utilizando archivos vectoriales oficiales y posteriormente se cargarán en GEE. De forma alternativa, GEE permite el dibujo de puntos líneas y polígonos con sus atributos.
- Se utiliza la información del Sistema Nacional de Información Territorial (SNIT) que representa la información oficial y más actualizada disponible de la geografía territorial de Costa Rica.

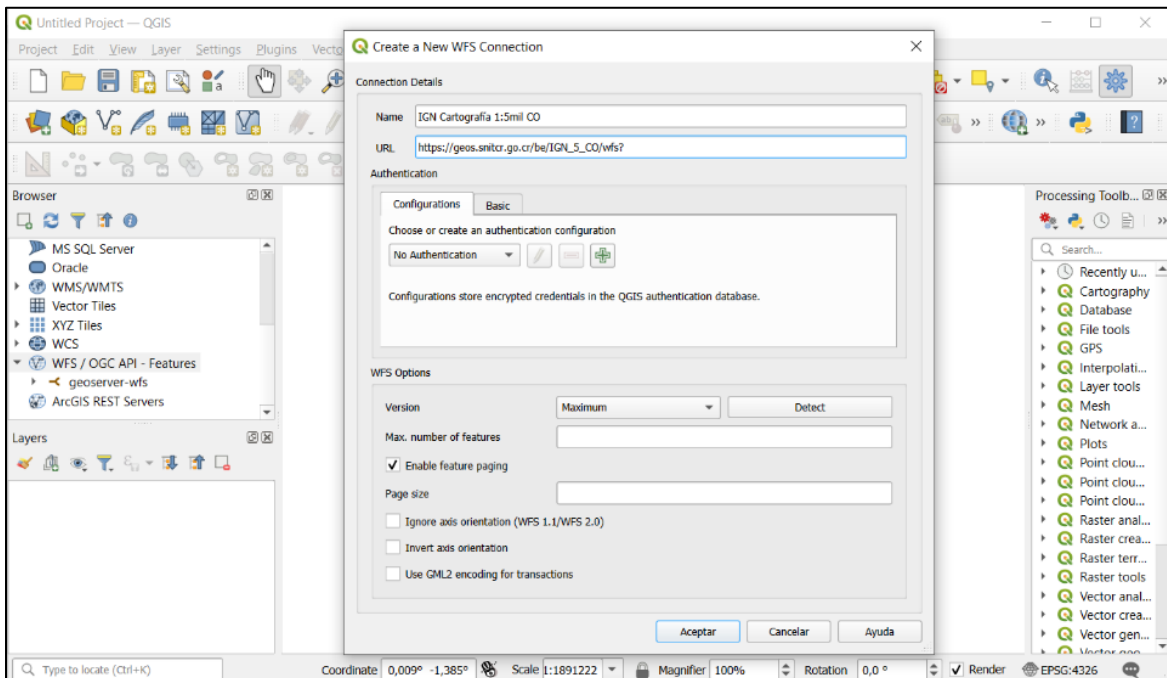


- Cargamos la página del SNIT, buscamos los servicios OGC de IGN Cartografía 1:5mil CO y copiamos el WFS.



- Abrimos QGIS, creamos la conexión WFS² con el del siguiente enlace:

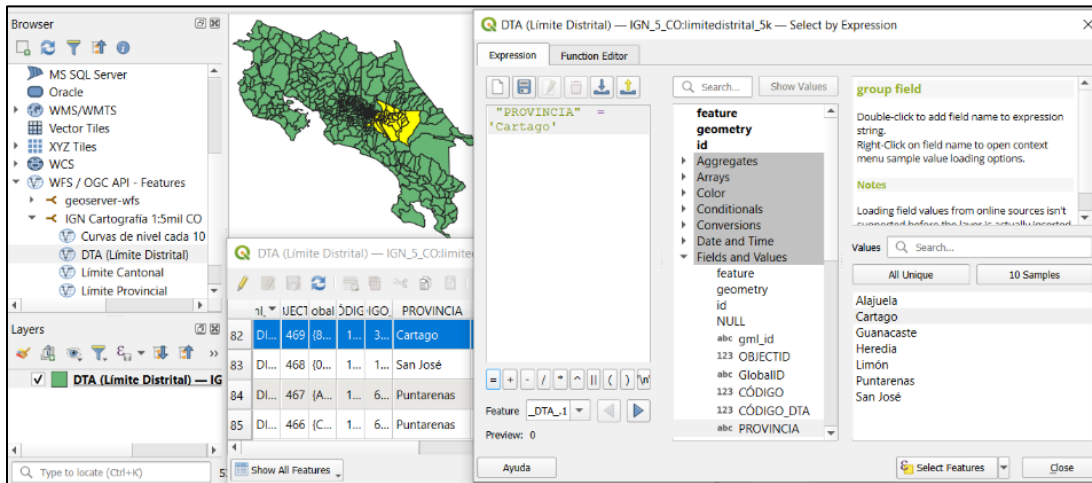
https://geos.snitcr.go.cr/be/IGN_5/wfs?




² Los enlaces de las diferentes páginas utilizadas se muestran como hipervínculos en los nombres de cada herramienta de manera que el lector pueda consultar las páginas correspondientes.

- Se carga la capa de distritos de todo el país y, posteriormente, se realiza la consulta en la tabla de atributos para seleccionar los distritos de la provincia de Cartago. La selección se lleva a cabo mediante la expresión:



“PROVINCIA” = “Cartago”



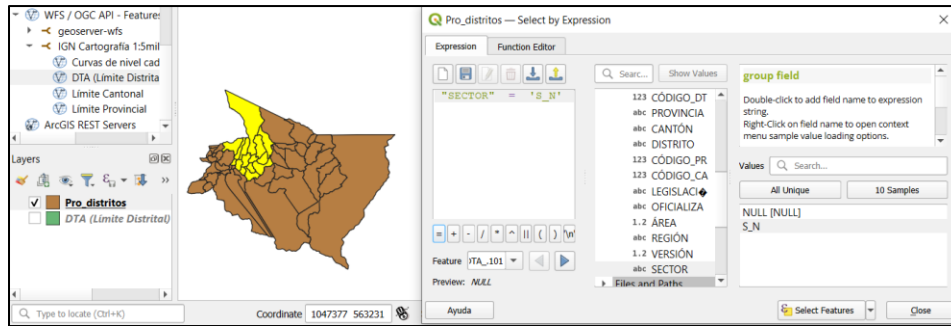
- Exportamos la información seleccionada en una nueva capa vectorial (Pro_distritos.shp)



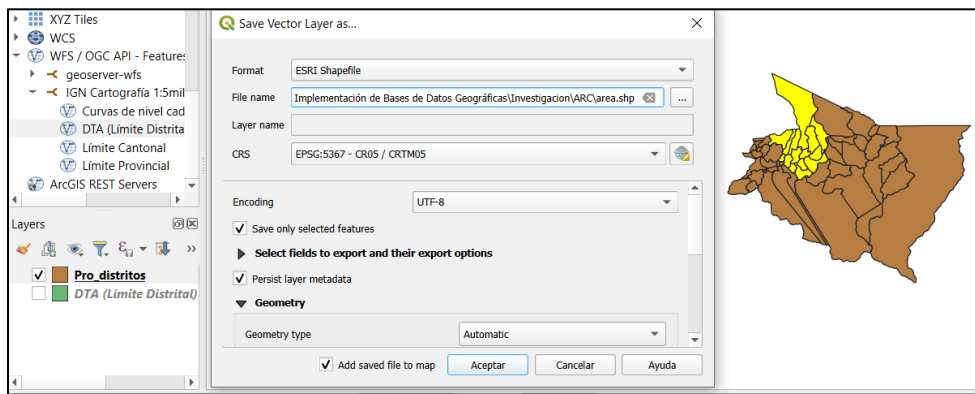
- Creamos una nueva columna en el archivo vectorial Pro_distritos.shp, con el nombre de SECTOR, tipo texto con 10 caracteres y rellenamos la información con el nombre “S_N”, a partir de las relaciones con las columnas CÓDIGO_DT con respecto a la columna del Código de distrito. Se guardan los cambios.



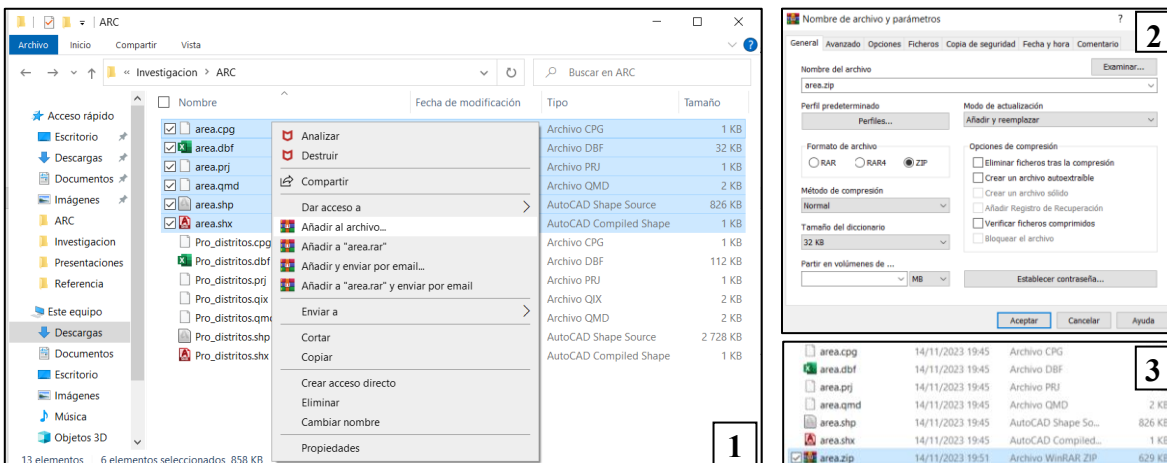
- Realizamos la consulta en la tabla de atributos de la capa Pro_distritos.shp para seleccionar los distritos que tengan el atributo de “S_N”. También, es posible seleccionar directamente los polígonos en caso de estar familiarizados con la geografía, o seleccionándolos por su llave primaria, en este caso, código de distrito.



- Exportamos la selección y guardamos la capa con el nombre de area.shp.



- Se comprimen los archivos de “área” en un archivo zip que luego se utilizará en GEE para su implementación.



Anexo 6. NDVI para la zona de estudio

```
//Calculo especifico de NDVI para Sentinel2
//Buscar imágenes SENTINEL 2
var imgs_s2 = ee.ImageCollection ('COPERNICUS/S2_SR')
  .filterDate('2024-01-01', '2025-01-01') //Rango de tiempo de 12 meses para imágenes actualizadas

//Seleccionar área de estudio y colocarle el nombre de geometry en lugar de "table"
  .filterBounds(geometry)

//Filtro de las imágenes SENTINEL 2
  .filterMetadata ('CLOUDY_PIXEL_PERCENTAGE', 'Less_Than', 10);

// Seleccionar la imagen con menor cobertura de nubes
var img = ee.Image(imgs_s2.sort('CLOUDY_PIXEL_PERCENTAGE').first());

// Cortar imagen con el área de estudio
var s2_clip = img.clip(geometry);

// Centrar el mapa en el área de estudio
Map.centerObject(geometry);

// Añadir imagen Sentinel-2 al mapa
Map.addLayer (s2_clip, {
  max: 4000,
  min: 0.0,
  gamma: 1.0,
  // Combinación de bandas de color natural
  bands: ['B4','B3','B2']},
  'Imagen Sentinel 2');

// NDVI = (NIR-RED) / (NIR+RED)
////////// Forma 1 NDVI//////////
var ndvi1 = s2_clip.normalizedDifference(['B8','B4']);

//Añadir NDVI al mapa
Map.addLayer(ndvi1, {max:1, min: -1,
palette:['871601','CE7E45','DF923D','F1B555','FCD163','99B718','74A901',
'66A000','529400','3E8601','207401','056201','004C00','023B01',
'012E01','011D01','011301']},'NDVI_1');

////////// Forma 2 NDVI//////////

var ndvi2 = s2_clip.expression('(nir-red)/(nir+red)', {
```

```

'nir':s2_clip.select('B8'),
'red':s2_clip.select('B4'}});

//Añadir NDVI al mapa
Map.addLayer(ndvi2, {max:0.5, min:0,
palette:['871601','CE7E45','DF923D','F1B555','FCD163','99B718','74A901',
'66A000','529400','3E8601','207401','056201','004C00','023B01',
'012E01','011D01','011301']}, 'NDVI_2');

// Exportar imagen a Drive
Export.image.toDrive({
image: ndvi2,
description: 'NDVI_Sentinel2_10m',
scale: 10,
region: geometry});

// Exportar imagen original de Sentinel-2 a Drive
var s2_clip_uint16 = s2_clip.toUint16(); // Convertir imagen original a UInt16
Export.image.toDrive({
image: s2_clip_uint16,
description: 'Sentinel2_Image_10m',
scale: 10,
region: geometry,
maxPixels: 1e13
});

//Definir el título en el visor de GEE
var TituloMapa = ui.Label({
value: 'NDVI zona de estudio de la investigación', // Titulo del mapa
style: {position: 'top-center', // Posición
fontWeight: 'bold', // Negrita
fontSize: '20px'}}); // Tamaño de fuente

var Titulo = ui.Label({
value: 'Realizado por Elizabeth Meneses Climent y Godofredo Rojas Mata', // Creadores
style: {position: 'bottom-center', // Position
fontWeight: 'bold', // Negrita
fontSize: '15px'}}); // Tamaño de fuente

//Incorporar el título en el visor
Map.add(TituloMapa);
Map.add(Titulo);
Map.setCenter (-83.846967, 9.977372, 10.5);

```

```

// INCORPORACION DE LEYENDA
// Descripción del etiquetado de elementos de la leyenda
var Etiquetas = [
    '-1 - -0.8',
    '-0.8 - -0.6',
    '-0.6 - -0.4',
    '-0.4 - -0.2',
    '-0.2 - 0',
    '0 - 0.2',
    '0.2 - 0.4',
    '0.4 - 0.6',
    '0.6 - 0.8',
    '0.8 - 1',];

// Configuración del título y posición de la leyenda
var Titulo = ui.Label({
    value: 'Parámetros', // Título de la leyenda
    style: {fontWeight: 'bold', fontSize: '20px', margin: '0px 15px 0px',}}); // Estilo y dimensiones
var Leyenda = ui.Panel({
    style: {position: 'bottom-left', padding: '10px 20px'}}); // Posicion, altura y anchura
Leyenda.add(Titulo);

// Configuración de la simbología
var Simbologia = ['871601','CE7E45','DF923D','F1B555','FCD163','99B718','74A901',
    '66A000','529400','3E8601','207401','056201','004C00','023B01',
    '012E01','011D01','011301'];
var Simbolos = function(simbolo, texto) {
var TextoLeyenda = ui.Label({
    value: texto,
    style: {margin: '6px 0px 10px 15px'}}); // Posición en la separación de los textos
var CajaLeyenda = ui.Label({
    style: {backgroundColor: '#' + simbolo,
    padding: '8px', // Tamaño del símbolo
    margin: '0px 6px 0px'}}); // Posición en la separación de los símbolos

//Representación de leyenda en el visor
return ui.Panel({
    widgets: [CajaLeyenda, TextoLeyenda],
    layout: ui.Panel.Layout.Flow('horizontal')}});
for (var i = 0; i < 10; i++) {Leyenda.add(Simbolos(Simbologia[i], Etiquetas[i]));}
Map.add(Leyenda);

```

Anexo 7. Clasificación supervisada para la zona de estudio

```
//Creado por Elizabeth Meneses y Godofredo Rojas Mata

//// --- 1) Crear composición de imagen Sentinel-2 ---
var img = ee.ImageCollection('COPERNICUS/S2')
  .filterDate('2025-01-01', '2025-03-31')
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
  .filterBounds(geometry)
  .map(function(image){ return image.clip(geometry) })
  .median();

Map.centerObject(geometry);
Map.addLayer(img, {max: 4000, min: 0.0, gamma: 1.0, bands: ['B4','B3','B2']}, 'Imagen Sentinel 2');

//-----
//// 2) CLASIFICACIÓN ////

// Cargar datos de muestreo desde shapefile
var training_data = ee.FeatureCollection('projects/ee-godorojas/assets/puntos_muestreo');

// Verificar propiedades del shapefile
print("Propiedades del shapefile:", training_data.first().propertyNames());

// Verificar valores de la columna "clase"
print("Primeras 5 clases en el shapefile:", training_data.limit(5).aggregate_array('clase'));

// Crear un diccionario de Earth Engine para convertir nombres de clase a números
var class_dict = ee.Dictionary({
  "Áreas urbanas": 1,
  "Bosques": 2,
  "Cuerpos de agua": 3,
  "Pastizales": 4,
  "Suelo descubierto": 5,
  "Tierras agrícolas": 6,
  "Nubes": 7 // Nueva categoría agregada
});

// Convertir clases de String a Integer, asegurando que las claves existen
training_data = training_data.map(function(feature) {
  var clase_str = ee.String(feature.get('clase')).trim(); // Eliminar espacios extra
  var clase_num = class_dict.get(clase_str, -1); // Buscar en el diccionario o asignar -1 si no existe
  return feature.set('clase_num', ee.Number(clase_num));
});

// Verificar si la conversión fue correcta
print("Primeras 5 clases después de conversión:",
training_data.limit(5).aggregate_array('clase_num'));

// Filtrar datos inválidos (-1) para evitar errores en el clasificador
```

```

training_data = training_data.filter(ee.Filter.gt('clase_num', 0));

// 🚨 Comprobar si hay datos válidos después del filtrado
print("Cantidad de puntos de entrenamiento válidos:", training_data.size());

if (training_data.size().getInfo() === 0) {
  print(" 🚨 ERROR: No hay datos de entrenamiento válidos. Revisa la columna 'clase.'");
}

//-----
//// --- 3) Dividir en entrenamiento (70%) y validación (30%) ---

// Agregar columna aleatoria para separación
var withRandom = training_data.randomColumn('random');

// Crear conjuntos
var trainingSet = withRandom.filter(ee.Filter.lt('random', 0.7));
var validationSet = withRandom.filter(ee.Filter.gte('random', 0.3));

print('Tamaño entrenamiento:', trainingSet.size());
print('Tamaño validación:', validationSet.size());

//-----
//// --- 4) Preparar datos de entrenamiento y validación ---
var bands = img.bandNames();

var trainingSamples = img.select(bands).sampleRegions({
  collection: trainingSet,
  properties: ['clase_num'],
  scale: 20
});

var validationSamples = img.select(bands).sampleRegions({
  collection: validationSet,
  properties: ['clase_num'],
  scale: 20
});

//-----
//// --- 5) Entrenar clasificador SVM ---
var svm = ee.Classifier.libsvm().train({
  features: trainingSamples,
  classProperty: 'clase_num',
  inputProperties: bands
});

//-----
//// --- 6) Clasificar imagen ---
var classified = img.select(bands).classify(svm);

//-----

```

```

//// --- 7) Validar clasificación ---

// Clasificar muestras de validación
var validated = validationSamples.classify(svm);

// Matriz de confusión
var confusionMatrix = validated.errorMatrix('clase_num', 'classification');
print('Matriz de confusión:', confusionMatrix);
print('Precisión global:', confusionMatrix.accuracy());
print('Precisión por clase (Usuarios):', confusionMatrix.consumersAccuracy());
print('Precisión por clase (Productores):', confusionMatrix.producersAccuracy());

//-----
//// --- 8) Aplicar filtro UMC (Unidad Mínima de Cartografía) ---
// Filtrar objetos con menos de 9 píxeles conectados (900 m²)
var umc_pixels = 9;
var classified_umc = classified.updateMask(
  classified.connectedPixelCount(100, true).gte(umc_pixels)
);

//-----
//// --- 9) Mostrar en mapa según paleta de colores definida para cada categoría ---
var paleta = [
  "#9220c6", // Áreas urbanas (1) - Morado
  "#008000", // Bosques (2) - Verde oscuro
  "#14c1ee", // Cuerpos de agua (3) - Azul claro
  "#FFD700", // Pastizales (4) - Amarillo dorado
  "#D3D3D3", // Suelo descubierto (5) - Gris
  "#c2390a", // Tierras agrícolas (6) - Rojo
  "#FFFFFF" // Nubes (7) - Blanco
];

// Añadir imágenes clasificadas al mapa
Map.addLayer(classified, {min: 1, max: 7, palette: paleta}, "LULC - Clasificación SVM");
Map.addLayer(classified_umc, {min: 1, max: 7, palette: paleta}, "LULC - Clasificación con UMC");

//-----
//// --- 10) Exportar imagen resultante a Google Drive (con UMC aplicada) ---
Export.image.toDrive({
  image: classified_umc,
  description: 'LC_area_SVM_2025_UMC',
  scale: 10,
  region: geometry,
  fileFormat: 'GeoTIFF'
});

```

Anexo 8. Clasificación No Supervisada para la zona de estudio

```
//Creado por Elizabeth Meneses y Godofredo Rojas Mata

// Clasificación no supervisada empleando K-Means

// Obtener una colección de imágenes Sentinel 2
var img = ee.ImageCollection('COPERNICUS/S2')
    .filterDate('2025-01-01', '2025-03-31')
    .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
    .filterBounds(geometry)
    .map(function(image){ return image.clip(geometry) })
    .median();

// Entrenar datos con imágenes
var training = img.sample({
  region: geometry,
  scale: 10,
  numPixels: 5000
});

// Agrupación de K-Means (6 clústeres)
var kmeans = ee.Clusterer.wekaKMeans(6).train(training);
var kmeansresult = img.cluster(kmeans);

// Clasificación de clips en la región
var kmeansresultclip = kmeansresult.clip(geometry);

// -----
// 🔍 Aplicar Unidad Mínima de Cartografía (UMC)
// UMC: 9 píxeles conectados (900 m2)
var umc_pixels = 9;
var kmeans_umc = kmeansresultclip.updateMask(
  kmeansresultclip.connectedPixelCount(100, true).gte(umc_pixels)
);

// -----
// Definir paletas de colores para los clústeres
var palette = ['yellow', 'green', 'black', 'gray', 'white', 'blue']; // Asegúrate de tener suficientes colores
```

```

var cluster_vis = {
  'min': 0,
  'max': 5, // K-Means genera clústeres del 0 al 5 (6 clases)
  'palette': palette
};

// Parámetros de visualización de imagen Sentinel 2
var visparams = {
  'bands': ['B4', 'B3', 'B2'],
  'min': 0,
  'max': 3000,
  'gamma': 1.4,
};

// Agregar capas al mapa
Map.centerObject(geometry);
Map.addLayer(geometry, {}, 'Región');
Map.addLayer(img, visparams, 'Imagen Sentinel 2');
Map.addLayer(kmeansresultclip, cluster_vis, 'K-Means original');
Map.addLayer(kmeans_umc, cluster_vis, 'K-Means con UMC');

// -----
// Exportar resultado clasificado con UMC a Google Drive
Export.image.toDrive({
  image: kmeans_umc,
  description: 'KMeans_Resultado_UMC',
  scale: 10,
  region: geometry,
  maxPixels: 1e13
});

```