



**Identificación de coberturas mediante procesamiento de imágenes satelitales para
monitoreo del paisaje ecológico**

Cristian Camilo Acevedo Moreno

Trabajo de investigación presentado para optar al título de Bioingeniero

Tutor

José David López Hincapié Doctor (PhD) en Ingeniería

Universidad de Antioquia

Facultad de Ingeniería

Bioingeniería

Medellín, Antioquia, Colombia

2024

Cita

C. C. Acevedo Moreno [1]

Referencia

- [1] C. C. Acevedo Moreno, "Identificación de coberturas mediante procesamiento de imágenes satelitales para monitoreo del paisaje ecológico", Trabajo de grado profesional, Bioingeniería, Universidad de Antioquia, Medellín, Antioquia, Colombia, 2024.

Estilo IEEE (2020)



Grupo de Investigación Sistemas Embebidos e Inteligencia Computacional (SISTEMIC).

Centro de Investigación Ambientales y de Ingeniería (CIA).



Centro de Documentación de Ingeniería - CENDOI

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

Dedico este trabajo a mi amada madre, Luz Esperanza Moreno, quien ha sido mi mayor fuente de amor, apoyo y sabiduría a lo largo de mi vida. Su inquebrantable aliento y orientación han sido la brújula que ha guiado mi camino personal, académico y profesional. Agradezco infinitamente su presencia constante y su inmenso sacrificio para asegurarse de que tuviera todas las oportunidades para crecer y aprender. A mis queridos abuelitos, María Evelia Murillo y Hernán Acevedo, y mi papa Hernán Acevedo, cuya ausencia física no disminuye el impacto de su amor y enseñanzas en mi vida. Aunque ya no estén conmigo, su legado de amor, determinación y sabiduría sigue vivo en mi corazón y en cada logro que alcanzo. Siempre estaré agradecido por todo lo que me enseñaron y por el amor incondicional que me brindaron. A todos ellos, les dedico este trabajo como un modesto tributo a su inmenso amor y sacrificio, y como un recordatorio constante de su impacto perdurable en mi vida. Gracias por todo.

Agradecimientos

Quiero expresar mi más sincero agradecimiento al profesor José David López y a la profesora Claudia Victoria Isaza por su excepcional liderazgo y orientación. Gracias a ellos, tuve el privilegio de participar a lo largo de mi carrera en diferentes proyectos, permitiéndome superar cada vez más mis límites y contribuir con soluciones innovadoras a problemas de gran relevancia social y ambiental. Estoy profundamente agradecido por el impacto positivo que su mentoría ha tenido en mi desarrollo profesional y personal.

Asimismo, deseo agradecer de todo corazón a María Félix Alarcón, quien me brindó un apoyo incansable en el cumplimiento de esta meta. Su constante respaldo y aliento fueron fundamentales en cada etapa de este camino hacia el logro de mis objetivos. También quiero reconocer y agradecer a Carolina Giraldo y a María Camila Velandia por su valiosa asesoría, apoyo técnico y respaldo moral. Su colaboración desinteresada contribuyó significativamente a enriquecer este proyecto y a mi crecimiento personal y profesional.

TABLA DE CONTENIDO

RESUMEN	10
I. INTRODUCCIÓN	12
II. PLANTEAMIENTO DEL PROBLEMA	13
III. JUSTIFICACIÓN	14
IV. OBJETIVOS	15
V. MARCO TEÓRICO	16
Teledetección	16
Sensores remotos	18
Sensores ópticos	18
Sensores de radar	19
Resoluciones	21
Resolución temporal	21
Resolución espacial	22
Resolución espectral	23
Resolución radiométrica	24
Plataformas de Observación Terrestre (Satélites)	26
NASA: LANDSAT	26
NASA: Terra y Aqua (MODIS)	27
Agencia Espacial Europea: SENTINEL	29
MAXAR: WorldView	31
PlanetLabs: SkySat	32
Firma espectral y coberturas	33
Índices espectrales	36
Caracterización de suelo y vegetación	36

Índice de Vegetación de Diferencia Normalizada (NDVI)	36
Índice de Suelo Ajustado (SAVI)	37
Índice de Vegetación Mejorado (EVI)	38
Índice de Vegetación de Diferencia Normalizada Verde (GNDVI)	40
Índice normalizado de diferencia de humedad (NDMI)	40
Índice de vegetación de área foliar (SLAVI)	41
Índice normalizado del borde rojo (NDRE)	42
Caracterización de cuerpos de agua	43
Índice de Agua Normalizada (NDWI)	43
Índice de Diferencia de Agua Normalizado Modificado (MNDWI)	44
Caracterización para construcciones	45
Índice de Diferencia Normalizada Edificada (NDBI)	45
Sistemas de Información Geográfica (SIG)	46
Google Earth Engine (GEE)	48
Registro en la plataforma	50
Scripts	52
Docs	54
Assets	55
Preprocesamiento de Imágenes Satelitales con Google Earth Engine (GEE)	55
Corrección atmosférica	55
Corrección radiométrica	56
Eliminación de nubes y sombras	57
VI. METODOLOGÍA	58
Contexto geográfico y temporal de estudio	58
Definición de coberturas y etiquetado	61

Entrenamiento	65
Validación	67
VII. RESULTADOS	68
VIII. CONCLUSIONES	73
IX. RECOMENDACIONES	75
REFERENCIAS	76

LISTA DE TABLAS

Tabla 1. Características generales a nivel de resolución para algunos satélites.....	33
Tabla 2. Bandas disponibles para Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A	60
Tabla 3. Precisión e índice Kappa obtenidos de la validación de los modelos.	71
Tabla 4. ConsumersAccuracy obtenido para la validación de los modelos.	72
Tabla 5. ProducersAccuracy obtenido para la validación de los modelos.	72
Tabla 6. Área calculada para cada cobertura a partir de los resultados de clasificación.....	72

LISTA DE FIGURAS

Fig. 1. Sistema global de observación terrestre.....	16
Fig. 2. Espectro electromagnético.....	17
Fig. 3. Bandas de interés para los sensores ópticos e imagen de referencia.	19
Fig. 4. Bandas de interés para los sensores SAR e imagen de referencia.	20
Fig. 5. Resoluciones asociadas a los sensores remotos.....	21
Fig. 6. Imágenes satelitales con diferentes resoluciones espaciales.....	22
Fig. 7. Imágenes satelitales con diferentes resoluciones espaciales.....	23
Fig. 8. Comparación entre resoluciones espectrales.	24
Fig. 9. Resolución radiométrica.	25
Fig. 10. Línea de tiempo serie de satélites Landsat.....	27
Fig. 11. Datos generales Satélite Terra.	28
Fig. 12. Datos generales Satélite Aqua.	29
Fig. 13. Satélites operados por el programa de observación de la tierra Copérnico.	30
Fig. 14. Satélites comerciales administrados por la compañía DigitalGlobe en 2016.	31
Fig. 15. Constelación de satélites administrados por PlanetLabs.	32
Fig. 16. Firma espectral de algunas coberturas terrestres.	34
Fig. 17. Esquema guía para identificación de características en coberturas.	35
Fig. 18. Descripción del rango de valores para el NDVI.	37
Fig. 19. Comparación entre los resultados de un área para los índices SAVI y NDVI.	38
Fig. 20. Comparación entre los resultados del índice NDVI (superior) vs EVI (inferior).....	39
Fig. 21. Comparación entre los resultados del índice NDVI vs NDWI.	43
Fig. 22. Comparación entre los resultados del índice NDVI vs NDWI vs MNDWI.	44
Fig. 23. Índice NDBI aplicado a la ciudad de Madrid.	45
Fig. 24. Aplicaciones comunes para manipulación y procesamiento de información geográfica.....	47
Fig. 25. Representación Raster y vectorial.....	48
Fig. 26. Interfaz gráfica de Google Earth Engine.	49
Fig. 27. Registro del proyecto en Google Earth Engine.....	51
Fig. 28. Interfaz de usuario de Google Earth Engine.	52
Fig. 29. Área de trabajo para la gestión del proyecto.....	53
Fig. 30. Algunos ítems disponibles en la sección de documentación.	54

Fig. 31. Área de interés definida para el estudio.....	59
Fig. 32. Invernaderos presentes en la zona de interés.	61
Fig. 33. Bosque presente en la zona de interés.....	62
Fig. 34. Zonas de viviendas presentes en la zona de interés.	63
Fig. 35. Carretera presente en la zona de interés.....	63
Fig. 36. Suelo desnudo presente en la zona de interés.	64
Fig. 37. Zonas de cultivo presentes en la zona de interés.	64
Fig. 38. Pastizal presente en la zona de interés.	65
Fig. 39. Comparación de la imagen satelital para el área de interés representada por sus bandas RGB con la disponible por el editor de GEE.	68
Fig. 40. Resultado del etiquetado manual.	69
Fig. 41. Resultado de clasificación - (Sup. -Izq.) Random Forest, (Sup. -Der.) CART, (Inf. -Izq.) KNN y (Inf. -Der.) Gradient Tree Boost.	70
Fig. 42. Matrices de confusión para los modelos evaluados.....	71

RESUMEN

El Grupo Herpetológico de Antioquia (GHA), en colaboración con el Grupo de Investigación en Sistemas Embebidos e Inteligencia Computacional (SISTEMIC), ha dedicado cerca de una década al empleo de la bioacústica como herramienta para el monitoreo de los ecosistemas naturales de Colombia. Su labor implica la captura y procesamiento de audios de diversas áreas de interés, con el propósito de realizar análisis de conectividad ecológica. Los resultados notables de estos análisis han subrayado la importancia de comprender más a fondo el paisaje y las coberturas específicas que lo componen en áreas particulares, con el fin de enriquecer los resultados de los análisis acústicos con información geoespacial, lo que amplía la capacidad de identificar patrones de comportamiento.

El objetivo principal de este proyecto de investigación fue establecer un marco metodológico utilizando técnicas de procesamiento de imágenes satelitales para la identificación y clasificación de coberturas en un área de estudio de más de 3000 hectáreas correspondiente al municipio de El Carmen de Viboral y sus alrededores. Para lograr esto, se empleó Google Earth Engine, una plataforma que facilita el análisis y la visualización de datos geoespaciales a gran escala. Se entrenaron modelos supervisados de clasificación como: Random Forest, Classification and Regression Trees (CART), K Nearest Neighbors (KNN) y Gradient Tree Boost, para identificar coberturas como: bosque, cultivos, pastos, suelo desnudo, y algunas relacionadas a la huella humana, como viviendas, carreteras e invernaderos.

Esta investigación brinda al GHA una herramienta invaluable para comprender y gestionar la composición del paisaje de manera mucho más efectiva, ya que el conocimiento detallado de las coberturas del suelo y su distribución en el paisaje enriquece la capacidad para identificar patrones de comportamiento de las especies y contribuye significativamente a una comprensión más profunda de la dinámica ecológica de los ecosistemas estudiados.

Palabras clave — **Imágenes satelitales, teledetección, procesamiento de imágenes, índices espectrales para cobertura vegetal, Google Earth Engine**

ABSTRACT

The Herpetological Group of Antioquia (GHA), in collaboration with the Embedded Systems and Computational Intelligence Research Group (SISTEMIC), has dedicated nearly a decade to the use of bioacoustics as a tool for monitoring natural ecosystems in Colombia. Their work involves capturing and processing audio from diverse areas of interest, with the purpose of performing ecological connectivity analyses. The remarkable results of these analyses have highlighted the importance of deeper understanding of the landscape and its specific coverages in particular areas, in order to enhance acoustic analysis results with geospatial information, thus expanding the ability to identify behavioral patterns.

The main objective of this research project was to establish a methodological framework using satellite image processing techniques for the identification and classification of land cover in a study area of more than 3000 hectares corresponding to the municipality of Carmen de Viboral and its surroundings. To achieve this, Google Earth Engine, a platform that facilitates the analysis and visualization of large-scale geospatial data, was used. Supervised classification models such as: Random Forest, Classification and Regression Trees (CART), K Nearest Neighbors (KNN) and Gradient Tree Boost, were trained to identify coverages such as: forest, crops, pastures, bare soil, and some related to the human footprint, such as houses, roads and greenhouses.

This research provides the GHA with an invaluable tool to understand and manage landscape composition much more effectively, as detailed knowledge of land covers and their distribution across the landscape enriches the ability to identify patterns of species behavior and contributes significantly to a deeper understanding of the ecological dynamics of the ecosystems studied.

Key Words — **Satellite imagery, remote sensing, image processing, spectral indices for vegetation cover, Google Earth Engine**

I. INTRODUCCIÓN

La clasificación de coberturas es esencial para los proyectos liderados por el Grupo Herpetológico de Antioquia (GHA) y el Grupo de Investigación en Sistemas Embebidos e Inteligencia Computacional (SISTEMIC). Este proceso permite una comprensión más completa de la estructura del hábitat al identificar y categorizar los diferentes tipos de vegetación y elementos naturales presentes en las áreas de interés. Esta comprensión mejora la evaluación de los ambientes donde se despliegan las grabadoras de audio para el monitoreo de especies, y facilita la interpretación de los datos acústicos recopilados. Además, la clasificación de coberturas proporciona información valiosa para la gestión y conservación de los ecosistemas. Al conocer la distribución y composición de las coberturas vegetales, es posible identificar áreas críticas para la biodiversidad y hábitats de especies sensibles. Esto facilita la implementación de medidas de conservación adecuadas y la planificación de acciones para mitigar los impactos negativos de actividades humanas, como la deforestación o la urbanización.

El proceso se basa en el uso de imágenes satelitales obtenidas mediante teledetección, donde los sensores instalados en satélites registran la radiación electromagnética reflejada o emitida por la superficie terrestre. Estas imágenes se procesan y analizan para identificar y clasificar las diferentes coberturas presentes en la superficie terrestre. La información espectral contenida en estas imágenes es fundamental para este proceso, ya que cada tipo de cobertura tiene una firma espectral única que permite distinguirla de otras clases.

El uso de plataformas como Google Earth Engine tiene un impacto positivo en este proceso. Proporciona acceso a una amplia variedad de imágenes satelitales de alta resolución y cobertura global, lo que permite obtener datos actualizados y relevantes para el análisis de coberturas. Además, ofrece herramientas de procesamiento de imágenes avanzadas, como algoritmos de aprendizaje automático y análisis espectral, que facilitan la clasificación automática. La infraestructura de computación en la nube de Google Earth Engine permite procesar grandes volúmenes de datos de manera eficiente y escalable, generando resultados más precisos y detallados en menos tiempo y con menos recursos computacionales.

II. PLANTEAMIENTO DEL PROBLEMA

Las investigaciones en curso enfrentan el desafío de caracterizar de manera precisa y eficiente las coberturas vegetales en las áreas de estudio donde realizan sus proyectos de monitoreo de especies y conservación de ecosistemas en Colombia. La falta de un método integral y tecnológicamente avanzado para identificar y clasificar estas coberturas dificulta la interpretación de los datos recolectados y limita la capacidad de implementar estrategias de conservación efectivas. Actualmente, la información disponible sobre la distribución y composición de las coberturas vegetales en estas áreas es limitada y fragmentada. Esto se debe a la falta de herramientas adecuadas para procesar y analizar grandes volúmenes de datos de imágenes satelitales, así como a la ausencia de técnicas avanzadas de clasificación que permitan diferenciar con precisión las diferentes clases de cobertura.

Por lo tanto, es crucial el desarrollo de un protocolo innovador que combine técnicas de teledetección y procesamiento de imágenes satelitales con algoritmos de clasificación avanzados. Este enfoque debe permitir identificar y delinear con precisión las diferentes coberturas vegetales presentes en las áreas de estudio, proporcionando información detallada sobre su distribución espacial y composición. De esta manera, se podrá mejorar la comprensión de la estructura del hábitat y la dinámica de los ecosistemas, facilitando la toma de decisiones informadas en materia de conservación y gestión ambiental.

III. JUSTIFICACIÓN

El desarrollo de un protocolo específico aprovechando Google Earth Engine y sus modelos de clasificación, permitirá una caracterización detallada y sistemática de las coberturas vegetales en las áreas de estudio. Esto es esencial para comprender la estructura del hábitat y su influencia en la distribución y comportamiento de las especies objeto de estudio del GHA. Este protocolo facilitará la estandarización y reproducibilidad de los métodos utilizados para la clasificación de coberturas, garantizando la consistencia en los resultados obtenidos a lo largo del tiempo y entre diferentes áreas de estudio, lo que es crucial para realizar comparaciones y evaluar cambios en el tiempo.

Dicha plataforma también ofrece ventajas en términos de eficiencia y escalabilidad. Esta herramienta permite el procesamiento de grandes volúmenes de datos de imágenes satelitales de forma rápida y automatizada, lo que reduce el tiempo y los recursos necesarios para llevar a cabo la clasificación de coberturas en áreas extensas y heterogéneas. Por otro lado, proporciona acceso a una amplia variedad de imágenes satelitales de alta resolución y cobertura global, así como a una variedad de algoritmos de clasificación avanzado, lo que se resume en la obtención de resultados precisos y detallados sobre la distribución y composición de las coberturas vegetales en las áreas de estudio.

IV. OBJETIVOS

A. Objetivo general

Establecer un marco metodológico integral para la identificación y clasificación de la complejidad de la estructura vegetal en diversos paisajes de interés, a través del desarrollo y aplicación de técnicas avanzadas de procesamiento de imágenes satelitales.

B. Objetivos específicos

- Desarrollar una metodología para identificar y diferenciar la complejidad de la estructura vegetal en imágenes satelitales
- Definir un flujo de trabajo para clasificar diferentes coberturas de la estructura vegetal a partir de los índices espectrales obtenidos del procesamiento de las imágenes satelitales
- Ejecutar pruebas de validación teniendo en cuenta las necesidades particulares de los paisajes de interés para el grupo Herpetológico de Antioquia

V. MARCO TEÓRICO

La capacidad de utilizar sensores remotos desde el espacio ha transformado la manera en que los ingenieros abordan proyectos y recursos en entornos terrestres y urbanos. La teledetección y el análisis de datos geospaciales permiten evaluar grandes extensiones de terreno de forma rápida y eficiente, proporcionando información crucial para la toma de decisiones informadas en ingeniería. La combinación de tecnologías como la teledetección, los Sistemas de Información Geográfica (SIG) y plataformas como Google Earth Engine (GEE) ha revolucionado la forma en que los ingenieros enfrentan diversos desafíos, desde la identificación de áreas propicias para la construcción de infraestructuras hasta el monitoreo de la salud de ecosistemas. Estos avances requieren un sólido entendimiento de conceptos y términos específicos del área, fundamentales para el éxito de los proyectos.

Teledetección

La **Teledetección** es una disciplina científica que estudia la adquisición de información sobre objetos o fenómenos en la superficie terrestre sin estar en contacto físico con ellos. Esto se logra mediante la captura y análisis de datos obtenidos por sensores remotos dispuestos en plataformas aéreas o espaciales, como satélites, aviones o drones [1].




Fig. 1. Sistema global de observación terrestre.

Nota. Fuente <https://static.uvq.edu.ar/mdm/teledeteccion/unidad-1.html>

La teledetección es una herramienta poderosa que permite estudiar y monitorear la Tierra desde una perspectiva global, proporcionando información sobre aspectos físicos, químicos y biológicos de la superficie terrestre. Permite la observación de la Tierra en diferentes escalas espaciales y temporales, lo que la convierte en una herramienta invaluable para una amplia gama de aplicaciones y campos. Por ejemplo:

- En agricultura, permite el monitoreo de cultivos, la detección de enfermedades y la evaluación de la salud de las plantas.
- En gestión de desastres, facilita la evaluación de daños, la planificación de respuestas y la gestión de riesgos.
- En estudios medioambientales, ayuda en la monitorización de la deforestación, la detección de cambios en la cobertura del suelo y la evaluación de la calidad del agua.

La teledetección se basa en la interacción entre la radiación electromagnética y la superficie terrestre. Los objetos y materiales reflejan, emiten o absorben radiación en distintas longitudes de onda, lo que permite su detección y análisis mediante sensores remotos. El espectro electromagnético abarca todas las frecuencias posibles de radiación, desde las ondas de radio hasta los rayos gamma, y se divide en diferentes bandas espectrales con propiedades únicas y aplicaciones específicas en teledetección. Las distintas longitudes de onda tienen interacciones diferentes con la materia, lo que posibilita su detección y análisis mediante sensores remotos [2].




Fig. 2. Espectro electromagnético.

Nota. Fuente <https://nuevaescuelamexicana.sep.gob.mx/detalle-ficha/4730/>

Dentro de este espectro, y para los fines específicos de la teledetección destacan las siguientes bandas:

- La banda **visible** del espectro abarca longitudes de onda aproximadas de 400 a 700 nanómetros (nm). Esta es la parte del espectro que el ojo humano puede percibir y se utiliza en sensores ópticos para capturar imágenes de la superficie terrestre en colores rojo, verde y azul (RGB).
- La banda del **infrarrojo cercano (NIR)** abarca longitudes de onda aproximadas de 700 a 1300 nm. Esta banda es útil para detectar la vegetación sana, ya que la clorofila en las plantas refleja fuertemente la radiación en esta región del espectro.
- La banda del **infrarrojo medio (MIR)** abarca longitudes de onda aproximadas de 1300 a 3000 nm. Esta banda es sensible a la temperatura y se utiliza para detectar características como la temperatura superficial del suelo y la humedad del suelo.
- La banda del **infrarrojo térmico (TIR)** abarca longitudes de onda mayores a 3000 nm. Esta banda es sensible al calor emitido por los objetos y se utiliza para obtener imágenes térmicas que muestran la distribución de la temperatura en la superficie terrestre.
- Las bandas de interés para la definición de elementos observables sobre las imágenes satelitales, dependerán de los sensores que capturan dicha información, ya que estos se encuentran limitados en su funcionamiento y especialidad.

Sensores remotos

Los **Sensores remotos** son dispositivos electrónicos que registran la radiación electromagnética reflejada o emitida por la superficie terrestre en diferentes bandas del espectro electromagnético, desde diferentes plataformas aéreas o espaciales, como satélites, aviones o drones. Estas señales son registradas y procesadas para extraer información sobre las características de la superficie observada permitiendo su análisis de la Tierra.

Sensores ópticos

Los **Sensores ópticos** o pasivos capturan la radiación visible e infrarroja cercana (NIR) reflejada por la superficie terrestre. Estos sensores son comúnmente utilizados para la observación de la cobertura del suelo, la vegetación, los cuerpos de agua y otros elementos terrestres [3]. Los sensores ópticos más comunes, hacen parte de los satélites Landsat, Sentinel-2, MODIS y WorldView.


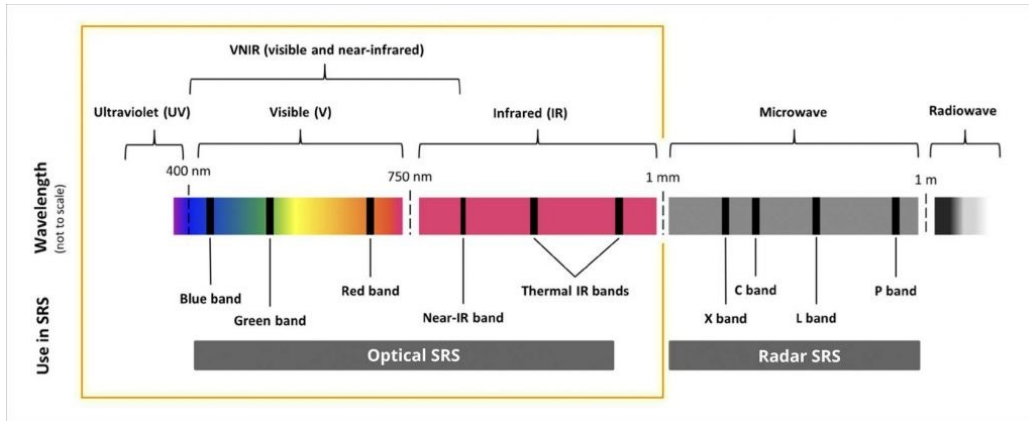


Fig. 3. Bandas de interés para los sensores ópticos e imagen de referencia.

Nota. Fuente <https://reefresilience.org/es/management-strategies/remote-sensing-and-mapping/introduction-to-remote-sensing/optical-and-radar-remote-sensing/>

Sensores de radar

Los **Sensores de Radar con Apertura Sintética (SAR)** o activos, emiten pulsos de microondas hacia la superficie terrestre y registran la energía reflejada por los objetos. Estos sensores son capaces de penetrar la cobertura de nubes y obtener imágenes incluso en condiciones de baja visibilidad. Los sensores tipo SAR se incluyen en satélites como Sentinel-1 y RADARSAT. Las diferentes longitudes de onda del radar a menudo se denominan bandas, con designaciones de letras como X, C, L y P. Cada banda tiene propiedades diferentes. Por ejemplo, la banda L se usa para el mapeo de biomasa y vegetación debido a una mayor penetración en un bosque, lo que permite una mayor interacción entre la señal del radar y las ramas y troncos de árboles grandes.


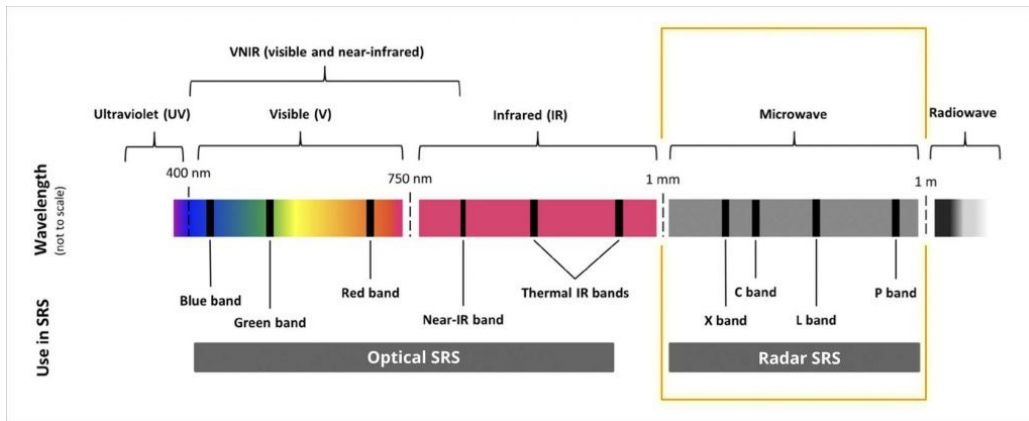


Fig. 4. Bandas de interés para los sensores SAR e imagen de referencia.

Nota. Fuente <https://reefresilience.org/es/management-strategies/remote-sensing-and-mapping/introduction-to-remote-sensing/optical-and-radar-remote-sensing/>

La resolución juega un papel crucial en la calidad y utilidad de las imágenes capturadas por los sensores remotos, ya que esta se refiere a la capacidad de un sensor para capturar detalles finos en la superficie terrestre, ya sea en términos espaciales, espectrales, radiométricos o temporales.




Fig. 5. Resoluciones asociadas a los sensores remotos.

Nota. Fuente https://www.riego.mx/files/seminario/seminario3/seminario3_p1.pdf

Resoluciones

La comprensión de los diferentes tipos de resolución es fundamental para seleccionar los datos adecuados y realizar análisis precisos en una amplia gama de aplicaciones, desde la monitorización ambiental hasta la planificación urbana y la gestión de recursos naturales [4].

Resolución temporal

La **Resolución temporal** se refiere a la frecuencia con la que se adquieren nuevas imágenes de una determinada área. Una mayor resolución temporal significa que se pueden obtener imágenes actualizadas con mayor frecuencia, lo que permite el monitoreo de cambios en la superficie terrestre a lo largo del tiempo.

Los sensores con alta resolución temporal pueden capturar imágenes diarias, semanales o mensuales de una determinada área, lo que permite el análisis de tendencias temporales y la detección de cambios rápidos. De forma general, se puede describir que una alta resolución

temporal corresponde a imágenes diarias o semanales, mientras que una baja resolución temporal serán imágenes tomadas en periodos mensuales o anuales.

Resolución espacial

La **Resolución espacial** es la capacidad del sensor para distinguir detalles finos en la imagen. Se expresa generalmente en metros por píxel y determina el nivel de detalle visible en la imagen. Una mayor resolución espacial significa que el sensor puede captar detalles más pequeños en la superficie terrestre. Los sensores de alta resolución espacial pueden capturar características pequeñas en la superficie terrestre, como edificios individuales, vehículos o árboles, mientras que los sensores de baja resolución espacial pueden capturar áreas más grandes con menos detalle.

Ejemplos de resoluciones espaciales comunes incluyen:

- Alta resolución: Menos de 1 metro por píxel.
- Media resolución: Entre 1 y 30 metros por píxel.
- Baja resolución: Más de 30 metros por píxel.



Fig. 6. Imágenes satelitales con diferentes resoluciones espaciales.

Nota. Fuente <https://eos.com/es/blog/resolucion-espacial/>

Como regla general, se necesitan 3 píxeles para identificar claramente un objeto. Por ejemplo, si tienes una imagen con una resolución de 3 metros, podrás identificar cualquier objeto de 9 o más metros.




Fig. 7. Imágenes satelitales con diferentes resoluciones espaciales.

Nota. Fuente <https://www.gisandbeers.com/pansharpening-mejorando-la-resolucion-de-imagenes-satelite/>

Resolución espectral

La **Resolución espectral** se refiere a la capacidad del sensor para captar diferentes bandas del espectro electromagnético. Cada banda proporciona información sobre características específicas de la superficie terrestre, como la vegetación, el agua, el suelo y otros materiales.

Los sensores con alta resolución espectral pueden capturar múltiples bandas espectrales, lo que permite realizar análisis detallados de la composición y las propiedades de la superficie terrestre.

Ejemplos de resoluciones espectrales comunes incluyen:

- Sensores **multiespectrales**: Capturan varias bandas del espectro visible e infrarrojo cercano.
- Sensores **hiperespectrales**: Capturan muchas bandas espectrales estrechas y continuas, lo que proporciona información detallada sobre la composición de la superficie terrestre.

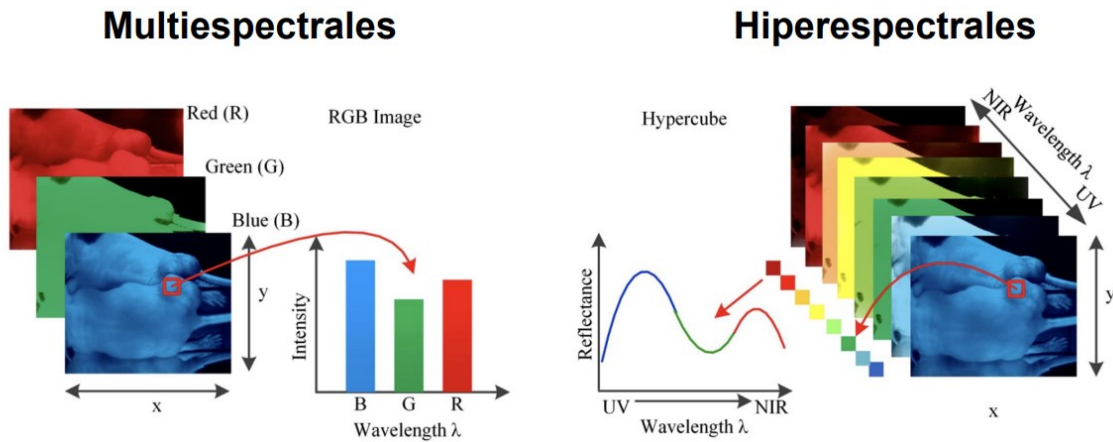


Fig. 8. Comparación entre resoluciones espectrales.

Nota. Fuente https://appliedsciences.nasa.gov/sites/default/files/2021-02/Hyperspectral_Part1_Span_Final.pdf

Es importante mencionar que también existe la resolución **pancromática** la cual captura imágenes en una sola banda o canal, generalmente en la región visible del espectro electromagnético. A diferencia de los sensores multispectrales, que capturan imágenes en varias bandas espectrales simultáneamente, los sensores pancromáticos solo registran la intensidad de la luz en una banda amplia de frecuencias, esto permite que en muchos casos estas imágenes presenten una excelente resolución espacial.

Resolución radiométrica

La **Resolución radiométrica** es una medida de la capacidad de un sensor remoto para discriminar entre diferentes niveles de energía electromagnética capturada en cada píxel de una imagen. Se refiere a la sensibilidad del sensor para detectar y registrar las variaciones en la intensidad de la energía radiante en cada banda espectral. Una mayor resolución radiométrica significa que el sensor puede distinguir entre niveles más finos de brillo o reflectancia en la imagen, lo que resulta en una mayor capacidad para capturar detalles sutiles y variaciones en la superficie terrestre.

La resolución radiométrica se expresa comúnmente en términos de "bits por píxel", lo cual indica el número de niveles de brillo o intensidad que el sensor puede representar para cada píxel en una imagen. Por ejemplo, un sensor con una resolución radiométrica de 8 bits por píxel puede representar 2^8 (256) niveles diferentes de brillo, mientras que un sensor con una resolución de 16

bits por píxel puede representar 2^{16} (65,536) niveles. Cuantos más bits por píxel tenga un sensor, mayor será su capacidad para capturar y representar variaciones sutiles en el brillo de la imagen, lo que resulta en una imagen de mayor calidad y detalle.

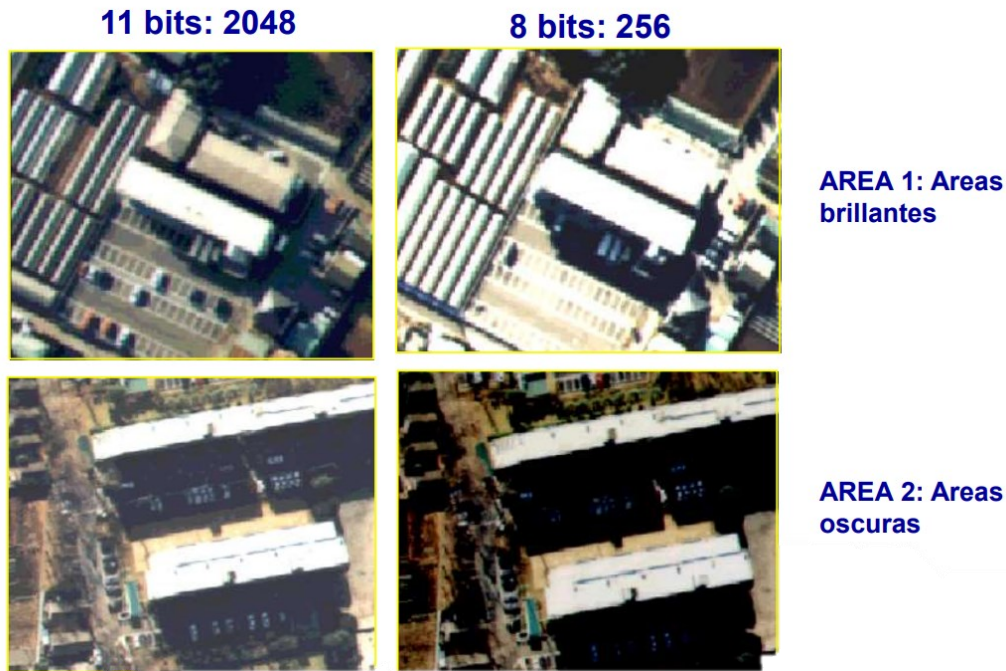


Fig. 9. Resolución radiométrica.

Nota. Fuente https://educatel.web.uah.es/sites/default/files/manuales/tel_ccaa3.pdf

En términos de la calidad de imágenes, tenemos que una mayor resolución radiométrica puede mejorar la calidad de la imagen al reducir el ruido y aumentar el contraste, lo que permite una mejor discriminación entre diferentes características y materiales en la superficie terrestre. Además, los sensores con una alta resolución radiométrica son especialmente útiles para aplicaciones que requieren una discriminación detallada de características de la superficie terrestre, como la detección de cambios sutiles en la vegetación, la identificación de objetos pequeños o la caracterización de materiales con propiedades radiométricas específicas.

La combinación de diferentes resoluciones (espacial, espectral y temporal) permite obtener información detallada y diversificada sobre la superficie terrestre. Por ejemplo, una imagen de alta resolución espacial puede ser útil para la identificación de características individuales, mientras que una serie temporal de imágenes puede ser utilizada para el monitoreo de cambios en la cobertura del suelo a lo largo del tiempo.

Plataformas de Observación Terrestre (Satélites)

Los **satélites y otras plataformas de observación terrestre** son vehículos o dispositivos equipados con sensores remotos que orbitan alrededor de la Tierra o se encuentran en altitudes elevadas para adquirir datos sobre la superficie terrestre. Estas plataformas juegan un papel crucial en la teledetección al proporcionar una visión global y repetitiva de la Tierra, permitiendo el monitoreo continuo de cambios y fenómenos en la superficie terrestre.

Estos satélites son administrados por diversas empresas y organizaciones, siendo algunas de las más destacadas la NASA (Administración Nacional de la Aeronáutica y del Espacio), la ESA (Agencia Espacial Europea), y empresas privadas como DigitalGlobe y Planet Labs. Entre las misiones más mencionadas y utilizadas en el campo de la clasificación de coberturas se encuentran Landsat, operada por la NASA y el Servicio Geológico de los Estados Unidos (USGS), Sentinel, parte del programa Copernicus de la ESA, y WorldView, una serie de satélites de alta resolución operados por DigitalGlobe. Estas misiones proporcionan datos multiespectrales y multitemporales de alta calidad, que son fundamentales para la clasificación y monitorización de coberturas del suelo a escala global [5].

NASA: LANDSAT

La serie de satélites **Landsat** [6], operada por la NASA y el Servicio Geológico de los Estados Unidos (USGS), ha proporcionado imágenes continuas de la Tierra por décadas. La primera misión Landsat, Landsat 1, fue lanzada en 1972, contando actualmente con nueve satélites en órbita, cada uno con mejoras tecnológicas con respecto a su predecesor.

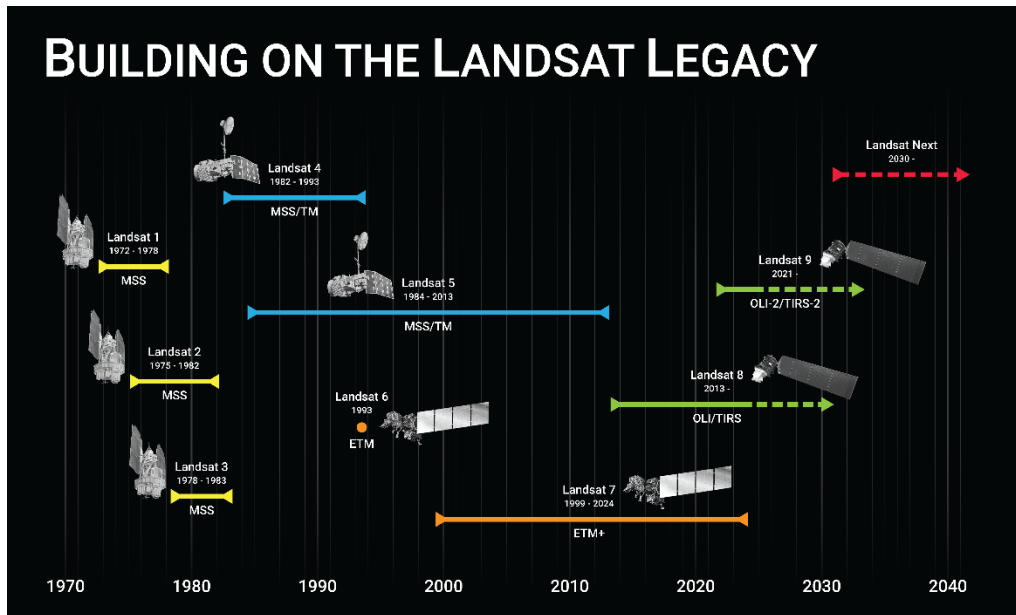


Fig. 10. Línea de tiempo serie de satélites Landsat.

Nota. Fuente <https://landsat.gsfc.nasa.gov/satellites/timeline/>

Los satélites Landsat capturan imágenes de la Tierra en diferentes bandas espectrales, desde el visible hasta el infrarrojo térmico, lo que permite una variedad de análisis, como la detección de cambios en la cobertura terrestre, la monitorización de la vegetación, el mapeo de recursos hídricos y la evaluación de la calidad del aire y del agua.

Los datos de Landsat están disponibles de forma gratuita para el público, lo que ha fomentado su amplio uso en una variedad de campos, desde la ciencia y la investigación hasta la planificación urbana y la gestión de recursos naturales.

NASA: Terra y Aqua (MODIS)

Los satélites Terra y Aqua son dos misiones clave de la NASA, diseñadas para estudiar varios aspectos de la Tierra, incluidos los cambios climáticos, la vegetación, los océanos y la atmósfera. Ambos llevan a bordo el instrumento **MODIS** [7] (Moderate Resolution Imaging Spectroradiometer), que es uno de los sensores más importantes para la observación de la Tierra desde el espacio.

El satélite Terra, lanzado en 1999 fue el primer satélite de la serie Earth Observing System (EOS) de la NASA. Su objetivo principal es estudiar la dinámica de la Tierra y sus sistemas

ambientales. Terra lleva a bordo varios instrumentos que proporcionan datos sobre la radiación solar reflejada, la temperatura de la superficie terrestre y la atmósfera, entre otros parámetros.

TERRA

Compuesto por 5 sensores. Cada sensor dispone de características únicas:

- **ASTER:** Radiómetro espacial de emisión y reflexión térmica avanzada
- **CERES:** Sistema de energía irradiada por la tierra y nubes
- **MISR:** Radiómetro espectral con imágenes multiangulares.
- **MODIS.**
- **MOPITT:** Mediciones de contaminación en la troposfera.




Figura : Satélite TERRA. Fuente: http://www.nasa.gov/mission_pages/terra/spacecraft/index.html#.VASsqWCSwUQ

Fig. 11. Datos generales Satélite Terra.

Nota. Fuente <https://es.slideshare.net/leugimxw/introduccion-al-sensor-modis-y-sus-productos>

Por otro lado, el satélite Aqua, lanzado en 2002, hace parte también de la serie EOS y fue diseñado para complementar las observaciones de Terra, especialmente en el estudio de los océanos y la atmósfera. Al igual que Terra, Aqua también está equipado con el instrumento MODIS, que proporciona datos sobre la temperatura superficial del mar, la cobertura de nubes, la calidad del aire y otros parámetros atmosféricos y oceánicos.

AQUA

Compuesto por 6 sensores. Cada sensor dispone de características únicas:

- AIRS: Sondeo atmosférico infrarrojo.
- AMSU-A: Unidad de sondeo avanzado de microondas.
- HSB: Sondeo de humedad para Brasil.
- AMSR-E: Radiómetro avanzado de escaneo de microondas-EOS.
- MODIS.
- CERES.




Figura : Satélite AQUA. Fuente: <http://aqua.nasa.gov/about/instruments.php>

Fig. 12. Datos generales Satélite Aqua.

Nota. Fuente <https://es.slideshare.net/leugimxw/introduccion-al-sensor-modis-y-sus-productos>

La relación entre los satélites Terra, Aqua y el sensor MODIS es crucial para obtener una cobertura completa y continua de la Tierra y sus sistemas ambientales. Dado que Terra y Aqua orbitan la Tierra en órbitas sincronizadas, pasando por el ecuador aproximadamente a las 10:30 de la mañana y de la tarde, hora local, todos los días, juntos proporcionan observaciones diarias casi completas de la superficie terrestre. Esto permite un monitoreo constante de los cambios en la Tierra.

Agencia Espacial Europea: SENTINEL

La constelación de satélites **Sentinel** [8], desarrollada por la Agencia Espacial Europea (ESA), forma parte del programa Copérnico de la Unión Europea para la observación de la Tierra con el propósito de proporcionar datos de manera gratuita y abierta para diversas aplicaciones. Los satélites Sentinel incluyen sensores ópticos, SAR y otros instrumentos para el monitoreo de la atmósfera, los océanos y la superficie terrestre.

Las cinco versiones principales de estas misiones ofrecen capacidades específicas para la monitorización de la Tierra. Sentinel-1 consta de dos satélites SAR que proveen imágenes radar de apertura sintética para diversas aplicaciones como la vigilancia marítima y el monitoreo de desastres naturales. Sentinel-2, con dos satélites ópticos, proporciona imágenes multispectrales de

alta resolución, útiles para la monitorización de la vegetación y la agricultura. Sentinel-3, una serie de satélites, ofrece mediciones precisas de parámetros oceanográficos y de la superficie terrestre. Sentinel-4 está destinado a proporcionar mediciones atmosféricas desde una órbita geostacionaria para monitorizar la calidad del aire en Europa. Mientras que Sentinel-5, desde una órbita polar, se centra en mediciones globales de composición atmosférica, incluyendo contaminantes y gases de efecto invernadero. Estas misiones representan una contribución significativa para la observación de la Tierra y abordan una amplia gama de necesidades ambientales, de seguridad y agrícolas.




Fig. 13. Satélites operados por el programa de observación de la tierra Copérnico.

Nota. Fuente <https://www.cursosteledeteccion.com/wp-content/uploads/2017/09/11-e1504273139266.jpg>

MAXAR: WorldView

Maxar Technologies [9] es una empresa líder en tecnología espacial y geoespacial que se formó a través de la fusión de varias compañías, incluida DigitalGlobe. DigitalGlobe, por otro lado, era una empresa independiente y líder en el campo de la observación de la Tierra y la provisión de imágenes y datos geoespaciales de alta resolución. La fusión con Maxar Technologies en 2017 dio lugar a la integración de los servicios y tecnologías de DigitalGlobe en el portafolio más amplio de Maxar, que incluye capacidades en áreas como comunicaciones espaciales, robótica, fabricación de satélites y sistemas espaciales.

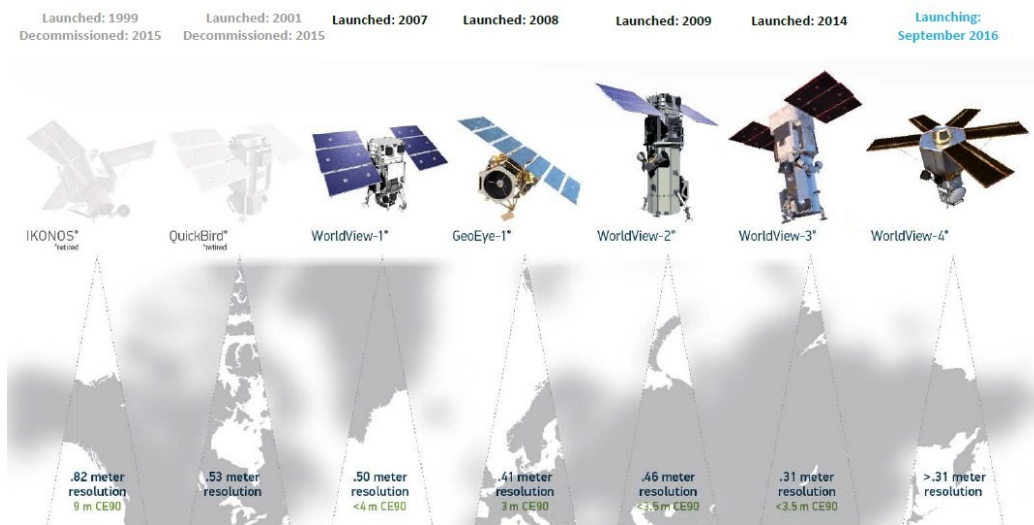


Fig. 14. Satélites comerciales administrados por la compañía DigitalGlobe en 2016.

Nota. Fuente <https://latamsatelital.com/wp-content/uploads/flota.jpg>

Los satélites de la serie WorldView, destacan por su capacidad para proporcionar imágenes de alta resolución con una claridad excepcional, siendo parte del Programa de Misiones de Terceros de la ESA en el que la ESA tiene un acuerdo con European Space Imaging (EUSI) para distribuir productos de datos de las misiones.

WorldView-1, lanzado en 2007, marcó un hito al convertirse en el primer satélite comercial de imágenes con una resolución espacial de 50 cm, ofreciendo una claridad sin precedentes en la visualización de la superficie terrestre. WorldView-2, lanzado en 2009, fue el primer satélite comercial multispectral de alta resolución con 8 bandas. Por otro lado, WorldView-3, lanzado en 2014, combinó la alta resolución espacial con una capacidad multispectral avanzada. Aunque

similar a WorldView-2, WorldView-3 se ubicó en una órbita más baja, lo que mejoró su capacidad para capturar imágenes detalladas de la superficie terrestre y sus características. Por último, WorldView-4, lanzado en 2016, consolidó aún más la posición de MAXAR en el mercado de la observación de la Tierra al proporcionar imágenes pancromáticas de 31 cm e imágenes multiespectrales de 1,23 m.

PlanetLabs: SkySat

Planet Labs [10] es una empresa privada con sede en San Francisco, California, que se dedica al desarrollo y operación de constelaciones de satélites para la observación de la Tierra. Fundada en 2010 tiene como objetivo principal proporcionar una cobertura diaria, global y asequible de la superficie terrestre utilizando una red de satélites de pequeño tamaño. Planet Labs administra varias constelaciones de satélites, incluyendo PlanetScope, RapidEye y SkySat.



Fig. 15. Constelación de satélites administrados por PlanetLabs.

Nota. Fuente <https://www.planet.com/products/planet-imagery/>

PlanetScope se compone de numerosos satélites de pequeño tamaño que proporcionan una cobertura diaria y global de la Tierra, lo que permite un monitoreo continuo de cambios en la superficie terrestre. Por otro lado, RapidEye se centra en la obtención de imágenes multiespectrales para aplicaciones agrícolas, ambientales y de gestión de recursos naturales. SkySat, por su parte, se caracteriza por su capacidad de capturar imágenes de alta resolución con un enfoque en aplicaciones comerciales, gubernamentales y de seguridad.

Cada plataforma de observación terrestre tiene sus propias características y capacidades, lo que las hace adecuadas para diferentes aplicaciones y necesidades de monitoreo. La elección de la plataforma y el sensor adecuados dependerá directamente de las necesidades del estudio a realizar, donde factores como el área de interés, la cantidad de imágenes disponibles, la frecuencia de observación, y en general, la calidad de imagen requerida (resoluciones) serán cruciales para la definición de la plataforma más adecuada.

A continuación, podemos observar las características generales a nivel de resolución para las plataformas y misiones comúnmente relacionadas al análisis de coberturas, permitiendo así la identificación de parámetros clave para el planteamiento de estudios futuros.

Tabla 1. Características generales a nivel de resolución para algunos satélites

Satélites	Resoluciones			
	Temporal	Espacial	Espectral	Radiométrica
<u>NASA Landsat 8</u>	16 días	30 m	Visible, infrarrojo cercano, medio y térmico (11 bandas)	12 y 8 bits
<u>NASA Terra&Aqua MODIS</u>	2 veces al día	250 m	Visible (36 bandas)	12 bits
<u>ESA Copernicus Sentinel-2</u>	5 días	10-60 m	Visible, infrarrojo cercano y medio (13 bandas)	12 bits
<u>MAXAR WorldView-4</u>	Entre 1 y 4.5 días	0.3-4 m	Visible (36 bandas)	11 bits
<u>Planet Labs SkySat</u>	Entre 4 a 5 días	0.5-3.6 m	Visible, infrarrojo cercano y medio (5 bandas)	16 bits

Firma espectral y coberturas

La **Firma espectral** es la "huella" única que un objeto o una superficie deja en el espectro electromagnético. Esencialmente, es el patrón de reflectancia o emisión de luz de un objeto en diferentes longitudes de onda del espectro electromagnético [11]. Esta firma espectral puede ser característica de ciertos materiales, como el agua, la vegetación, el suelo desnudo, los edificios, entre otros.

Cada material interactúa de manera única con la radiación electromagnética, reflejando, absorbiendo o transmitiendo diferentes longitudes de onda de luz. Por ejemplo, la vegetación suele

reflejar fuertemente en la región del infrarrojo cercano, mientras que el agua absorbe más luz en esa región.

Al analizar estas firmas espectrales, los científicos y los investigadores podemos identificar y distinguir diferentes características del terreno, lo que es fundamental para la interpretación de imágenes satelitales y la clasificación de la cobertura terrestre en aplicaciones como la agricultura, la cartografía, la gestión ambiental y la detección de cambios en el uso del suelo.

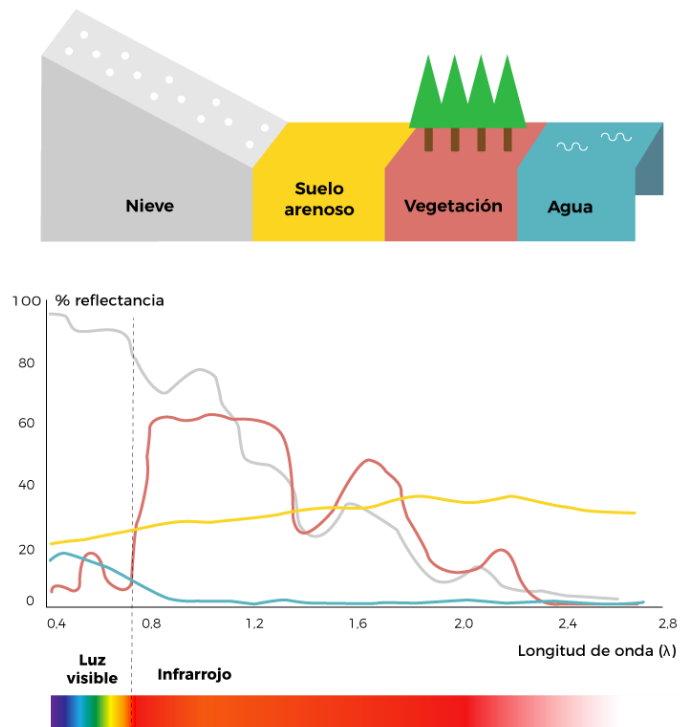


Fig. 16. Firma espectral de algunas coberturas terrestres.

Nota. Fuente <https://www.edu-sat.com/teledeteccion/?lang=es>

En la siguiente imagen, se describe mediante un diagrama las características generales de coberturas como: vegetación, suelo, cultivos y nieve o nubes, definiendo cómo estas pueden ser identificadas en una imagen satelital mediante el uso de diferentes bandas espectrales.

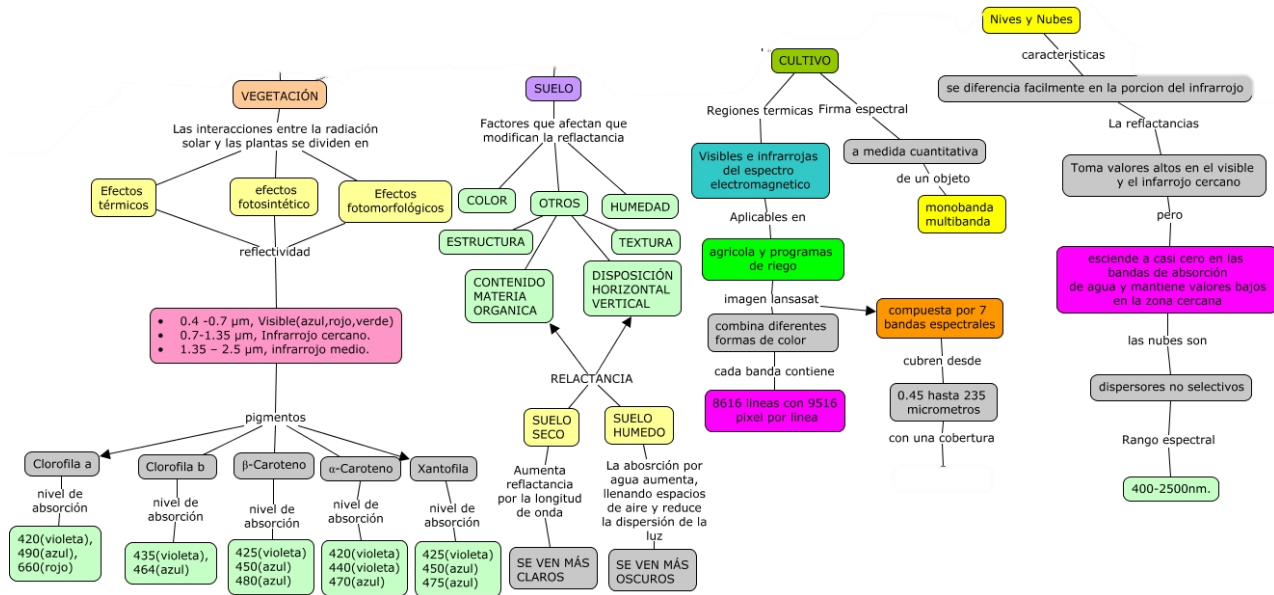


Fig. 17. Esquema guía para identificación de características en coberturas.

Nota. Fuente <https://cmapublic.ihmc.us/rid=1RR1BVN2L-116L3P4-2WN9/firma%20espectral.cmap>

En el análisis de imágenes satelitales, las coberturas se refieren a las diferentes características de la superficie terrestre que se pueden identificar y clasificar en una imagen. Estas coberturas pueden incluir tipos de terreno como bosques, cultivos, cuerpos de agua, áreas urbanas, etc.

Las firmas espectrales son las huellas o perfiles espectrales únicos que cada tipo de cobertura deja en los datos capturados por un sensor remoto. Estas firmas espectrales están determinadas por la manera en que cada material refleja, absorbe o emite energía electromagnética en diferentes longitudes de onda. Cada cobertura tendrá una firma espectral característica debido a sus propiedades físicas y químicas únicas.

Entonces, la relación entre las coberturas y las firmas espectrales es que las coberturas se pueden identificar y clasificar en una imagen satelital mediante el análisis de las firmas espectrales asociadas a cada una de ellas. Los algoritmos de clasificación de imágenes utilizan esta información para asignar píxeles individuales de la imagen a clases específicas de cobertura, basándose en la similitud de sus firmas espectrales con las firmas espectrales de referencia previamente definidas para cada tipo de cobertura.

Índices espectrales

Los **Índices espectrales** son combinaciones matemáticas de los valores de reflectancia en diferentes bandas espectrales de una imagen satelital. Estos índices están diseñados para resaltar características específicas del terreno o fenómenos naturales que pueden no ser evidentes en las imágenes individuales de una banda. La combinación de información de diferentes bandas espectrales permite obtener una visión más completa y detallada de la superficie terrestre. Por ejemplo, la combinación de bandas en el infrarrojo cercano y medio puede proporcionar información sobre la salud de la vegetación y la distribución del agua en el suelo. La visualización de imágenes en diferentes colores falsos, donde cada banda se asigna a un color específico, puede resaltar características y patrones que no son visibles en imágenes en colores naturales.

En la actualidad, existen un sinfín de índices espectrales definidos para diferentes sensores y aplicaciones, encontrándose en su mayoría en el siguiente portal: <https://www.indexdatabase.de/>. Para efectos prácticos de este manual, mencionaremos aquellos que suelen ser más relevantes para identificar: suelo, agua, cultivos y construcciones [12].

Caracterización de suelo y vegetación

Índice de Vegetación de Diferencia Normalizada (NDVI)

El **NDVI** permite monitorear la salud y vigor de la vegetación. Se calcula a partir de la reflectancia de la luz en dos bandas específicas del espectro electromagnético: la banda roja (visible) y la banda infrarroja cercana (NIR).

- Fórmula general del NDVI = $(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$
- NDVI (Landsat 8) = $(B5 - B4) / (B5 + B4)$
- NDVI (Landsat 4 - 7) = $(B4 - B3) / (B4 + B3)$
- NDVI (Sentinel 2) = $(B8 - B4) / (B8 + B4)$

La clorofila en las plantas absorbe la luz roja para la fotosíntesis, mientras que la estructura celular de las hojas refleja la luz infrarroja cercana. Cuanto más verde y densa sea la vegetación, mayor será la absorción de luz roja y la reflectancia en la banda infrarroja cercana. Debido a esto, el NDVI toma valores entre -1 y 0.8. Valores altos (entre 0.6 y 0.8) indican vegetación muy densa,

como las selvas tropicales. Valores bajos (entre 0 y 0.3) indican vegetación escasa o estresada, como pastos o arbustos.




Fig. 18. Descripción del rango de valores para el NDVI.

Nota. Fuente <https://www.cursosteledeteccion.com/ndvi-que-es-y-para-que-sirve/>

Índice de Suelo Ajustado (SAVI)

El **Índice de Suelo Ajustado (SAVI)** es un índice espectral utilizado para estimar la cantidad y vigor de la vegetación presente en una superficie terrestre. Este índice fue desarrollado en 1982 por Huete como una mejora al índice NDVI (Índice de Vegetación de Diferencia Normalizada), con el objetivo de minimizar la influencia del brillo del suelo en áreas con poca cobertura vegetal.

- Fórmula: $SAVI = ((NIR - Red) / (NIR + Red + L)) * (1 + L)$, donde:

NIR: Reflectancia en la banda del infrarrojo cercano

Red: Reflectancia en la banda del rojo

L: Factor de ajuste del suelo, generalmente entre 0 y 1 (valor recomendado: 0.5)

Rango de valores: SAVI varía entre -1 y 1. Los resultados de este índice se especifican de la siguiente forma:

- Valores positivos: Presencia de vegetación.
- Valores cercanos a 0: Suelo desnudo o con poca vegetación.
- Valores negativos: Zonas con agua o nieve.

Este índice permite minimizar la influencia del suelo en la estimación de la vegetación, lo que resalta un poco más la cantidad de vegetación que el NDVI en áreas con poca cobertura vegetal, siendo útil para el monitoreo de la vegetación en zonas áridas y semiáridas.

Como todo índice, puede presentar algunas limitaciones relacionadas a sus variables, como la elección del factor L, el cual puede afectar significativamente los resultados, no es tan sensible a cambios en la biomasa como otros índices espectrales y puede ser afectado por la atmósfera y la topografía del terreno.




Fig. 19. Comparación entre los resultados de un área para los índices SAVI y NDVI.

Nota. Fuente <https://www.gisandbeers.com/calculo-del-indice-vegetacion-savi/>

Índice de Vegetación Mejorado (EVI)

El **Índice de Vegetación Mejorado (EVI)** es un índice espectral utilizado para estimar la cantidad y vigor de la vegetación presente en una superficie terrestre. Este índice fue desarrollado en 1997 por Huete et al. como una mejora al índice NDVI (Índice de Vegetación de Diferencia Normalizada), con el objetivo de minimizar la influencia del suelo y la atmósfera en la detección de la vegetación, especialmente en áreas con alta biomasa.

- Fórmula: $EVI = 2.5 * ((NIR - Red) / (NIR + 6 * Red - 7.5 * Azul + 1))$

El rango de valores para EVI varía entre -1 y 1.

- Valores positivos: Presencia de vegetación.

- Valores cercanos a 0: Suelo desnudo o con poca vegetación.
- Valores negativos: Nubes, nieve o hielo.

De forma general se tiene que EVI presenta una mayor sensibilidad a la cantidad de vegetación que el NDVI, especialmente en áreas con alta biomasa, pero una menor sensibilidad a la atmósfera y al suelo. Normalmente se utiliza para el monitoreo de la vegetación en áreas con bosques densos o con cultivos.

Debido a la definición de su fórmula, se requieren imágenes satelitales con bandas en el azul, rojo, infrarrojo cercano (NIR) y verde, presentando un bajo desempeño para áreas con poca cobertura vegetal.




Fig. 20. Comparación entre los resultados del índice NDVI (superior) vs EVI (inferior).

Nota. Fuente <https://vineview.com/evi-vs-ndvi-whats-difference/>

En la imagen anterior se puede observar que la temperatura de la superficie de interés puede generar cambios en los resultados para el índice NDVI, mientras que los resultados de EVI no se ven afectados por esta variable, presentado resultados más consistentes en el tiempo para una misma área.

Índice de Vegetación de Diferencia Normalizada Verde (GNDVI)

El **GNDVI** es un índice espectral que se utiliza para medir la cantidad de clorofila en la vegetación. Se calcula a partir de la reflectancia de la luz en dos bandas específicas del espectro electromagnético: Banda verde, en la cual la clorofila de las plantas absorbe la luz verde para la fotosíntesis, y la Banda infrarroja cercana (NIR), que corresponde la estructura celular de las hojas que refleja esta luz. Cuanto más densa y verde sea la vegetación, mayor será la reflectancia en esta banda infrarroja cercana (NIR) y mayor será la absorción de luz verde.

- Fórmula general del GNDVI = $(\text{NIR} - \text{GREEN}) / (\text{NIR} + \text{GREEN})$
- GNDVI (Landsat 8) = $(B5 - B3) / (B5 + B3)$
- GNDVI (Landsat 4 - 7) = $(B4 - B2) / (B4 + B2)$
- GNDVI (Sentinel 2) = $(B8 - B3) / (B8 + B3)$

Rango de valores:

- -1 a 0: No hay vegetación (suelo desnudo, agua, nieve)
- 0 a 0.3: Vegetación escasa (pastos, arbustos)
- 0.3 a 0.6: Vegetación densa (cultivos, bosques)
- 0.6 a 0.8: Vegetación muy densa (selvas tropicales)

En este caso, los valores altos del GNDVI indican mayor cantidad de clorofila y, por lo tanto, mayor actividad fotosintética, mientras que los valores bajos indican menor cantidad de clorofila, lo que puede deberse a estrés hídrico, enfermedades, o baja densidad de la vegetación.

Índice normalizado de diferencia de humedad (NDMI)

El Índice de Humedad de Diferencia Normalizada (NDMI) detecta los niveles de humedad en la vegetación utilizando una combinación de bandas espectrales del infrarrojo cercano (NIR) y del infrarrojo de onda corta (SWIR).

Es un gran indicador del estrés hídrico en los cultivos. Cuando las condiciones de sequía extrema afectan los cultivos, el NDMI puede detectar el estrés hídrico en una fase temprana, antes de que el problema se agrave. Además, el uso del NDMI para supervisar el riego en zonas donde los cultivos requieren más agua de la que la naturaleza puede suministrar ayuda a mejorar significativamente el crecimiento de los cultivos. También tiene otra aplicación: la monitorización de los niveles de material combustible, especialmente en zonas propensas a incendios forestales.

El NDMI se calcula utilizando la reflectancia del infrarrojo cercano (NIR) y del infrarrojo de onda corta (SWIR):

- Fórmula general del NDMI = $(\text{NIR} - \text{SWIR}) / (\text{NIR} + \text{SWIR})$

Ejemplos específicos para diferentes sensores:

- Sentinel-2: NDMI = $(\text{B08} - \text{B11}) / (\text{B08} + \text{B11})$
- Landsat 4-5 TM: NDMI = $(\text{B04} - \text{B05}) / (\text{B04} + \text{B05})$
- Landsat 7 ETM+: NDMI = $(\text{B04} - \text{B05}) / (\text{B04} + \text{B05})$
- Landsat 8: NDMI = $(\text{B05} - \text{B06}) / (\text{B05} + \text{B06})$
- MODIS: NDMI = $(\text{B02} - \text{B06}) / (\text{B02} + \text{B06})$

Al igual que la mayoría de los índices, el NDMI tiene valores entre -1 y +1. Valores positivos indican mayor contenido de humedad, mientras que valores negativos señalan menor humedad.

El NDMI es un mejor indicador de la deforestación que el NDVI debido a una disminución menos abrupta de los valores.

Índice de vegetación de área foliar (SLAVI)

El Índice de Área Foliar Específica (SLAVI) es un índice de vegetación que proporciona información valiosa sobre la vegetación y su salud. Este se centra en el área foliar específica de las plantas, que es la relación entre el área de las hojas y su masa. En otras palabras, mide cuánta superficie de hojas hay en relación con la cantidad de material vegetal.

Este índice es útil para evaluar la densidad y salud de la vegetación en un área determinada.

- Fórmula general del SLAVI = $\text{NIR} / (\text{Rojo} + \text{SWIR})$

Los valores del SLAVI pueden variar entre negativos y positivos. Valores positivos indican mayor densidad de hojas verdes y, por lo tanto, una vegetación más saludable. Valores negativos pueden indicar falta de vegetación, como áreas con agua, rocas o suelo desnudo.

El SLAVI se utiliza en monitoreo forestal, estimación de volumen de biomasa vegetal, evaluación de estrés hídrico y otros estudios relacionados con la vegetación.

Índice normalizado del borde rojo (NDRE)

El Índice de Diferencia Normalizada de Borde Rojo (NDRE) es un índice espectral utilizado para analizar la salud y vigor de la vegetación.

Este se construye combinando bandas espectrales como el espectro del Infrarrojo Cercano (NIR) y una banda que abarca un estrecho rango espectral entre el Rojo visible y el NIR.

Es similar al Índice de Vegetación de Diferencia Normalizada (NDVI), pero con una diferencia clave: el NDRE utiliza la banda del borde rojo en lugar del rojo, lo que proporciona más información sobre el comportamiento espectral de la vegetación.

El NDRE es más sensible que el NDVI durante ciertos períodos de maduración del cultivo. Es especialmente útil para cultivos en temporada media y tardía de crecimiento, cuando las plantas ya han acumulado una cantidad significativa de clorofila. La razón detrás de esta sensibilidad es que la luz de borde rojo (utilizada en el NDRE) penetra más profundamente en las hojas que la luz roja (utilizada en el NDVI).

El NDRE es un mejor indicador de las condiciones de las plantas en estas etapas.

- La fórmula general del $NDRE = (NIR - \text{Rojo de Borde}) / (NIR + \text{Rojo de Borde})$

Los valores del NDRE pueden variar entre negativos y positivos. Valores positivos indican mayor contenido de clorofila y, por lo tanto, una vegetación más saludable. Valores negativos pueden señalar falta de vegetación, como áreas con suelo desnudo o rocas.

El NDRE se utiliza principalmente para monitorear el contenido de clorofila como indicador primario de nitrógeno durante todo el ciclo del cultivo. Generar mapas para determinar dónde es necesaria la aplicación de fertilizantes. Evaluar el vigor de la vegetación en imágenes de sensores multispectrales.

Caracterización de cuerpos de agua

Índice de Agua Normalizada (NDWI)

El **Índice de Agua Normalizada (NDWI)** es un índice espectral utilizado para identificar y mapear la presencia de agua en una superficie terrestre. Este se basa en la diferencia de reflectancia en las bandas verde e infrarroja cercana (NIR) de la luz solar, aprovechando las propiedades de absorción y reflectancia del agua en estas bandas.

- Fórmula: $NDWI = (Verde - NIR) / (Verde + NIR)$

El rango de valores NDWI varía entre -1 y 1, donde:

- Valores positivos: Presencia de agua.
- Valores cercanos a 0: Suelo desnudo o vegetación.
- Valores negativos: Nubes, nieve o hielo.

Este índice es útil para la detección de agua en diferentes tipos de superficies, incluyendo vegetación, suelo y nieve, además puede ser utilizado para el monitoreo de cambios en la extensión de las áreas de agua a lo largo del tiempo.

La composición del suelo, la atmósfera y la topografía del terreno pueden afectar los resultados obtenidos por este índice, también suele ser poco preciso en áreas con poca cobertura vegetal o con aguas turbias y no distingue entre diferentes tipos de agua (superficial, subterránea, salada, dulce).




Fig. 21. Comparación entre los resultados del índice NDVI vs NDWI.

Nota. Fuente <https://support.geoagro.com/es/kb/que-es-un-ndwi/>

Índice de Diferencia de Agua Normalizado Modificado (MNDWI)

Este índice se creó con el fin de dar respuesta a la incapacidad del índice NDWI para separar territorios cubiertos del agua. Por este motivo en 2006, se propuso modificar el NDWI intercambiando la banda del Infrarrojo Cercano (NIR) por la banda del Infrarrojo Medio (SWIR), esto con el objetivo de minimizar la influencia del suelo y la vegetación en la detección de agua.

- Fórmula: $MNDWI = (Verde - SWIR) / (Verde + SWIR)$

El rango de valores NDWI varía entre -1 y 1, donde:

- Valores positivos: Presencia de agua.
- Valores cercanos a 0: Suelo desnudo o vegetación.
- Valores negativos: Nubes, nieve o hielo.

Entre las ventajas que se tiene al usar este índice, se encuentra la mejoría en la precisión respecto al NDWI en la detección de agua en áreas con suelo desnudo o con poca vegetación, menor sensibilidad a la atmósfera que el NDVI y capacidad para detectar agua en zonas con alta turbidez o con vegetación acuática.

Aun así, es importante recordar que, dada su definición, este índice requiere imágenes satelitales con bandas en el verde y en el infrarrojo de onda corta (SWIR), donde su precisión puede disminuir a causa de la composición del suelo, la topografía del terreno y la profundidad de las aguas.

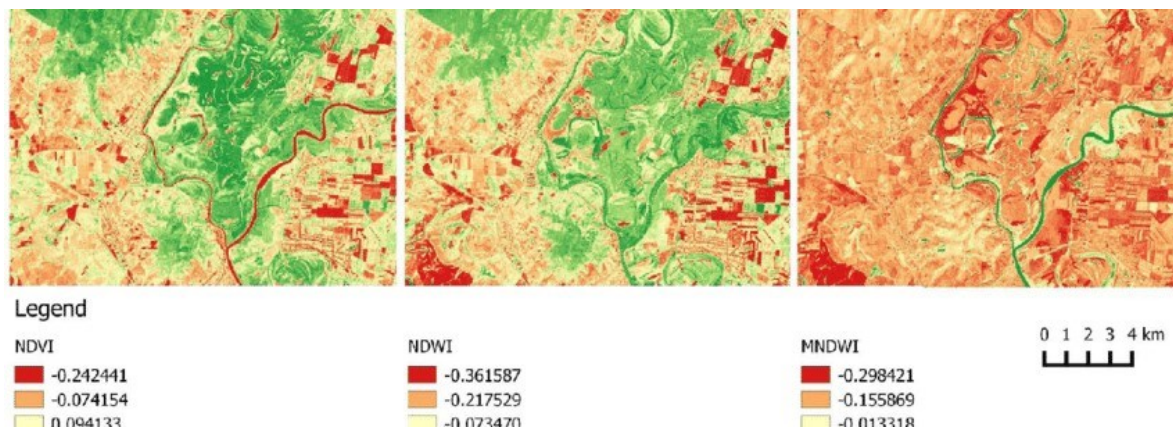


Fig. 22. Comparación entre los resultados del índice NDVI vs NDWI vs MNDWI.

Nota. Fuente

https://www.researchgate.net/publication/309099746_Specific_features_of_NDVI_NDWI_and_MNDWI_as_reflected_in_land_cover_categories

Caracterización para construcciones

Índice de Diferencia Normalizada Edificada (NDBI)

El **Índice de Diferencia Normalizada Edificada (NDBI)** es un índice espectral que permite estimar la cantidad de superficie construida o edificada en un área urbana. Este índice se basa en la diferencia de reflectancia en las bandas verde e infrarrojo cercano (NIR) de la luz solar, aprovechando la alta reflectancia de los materiales de construcción en el infrarrojo cercano.

- Fórmula: $NDBI = (SWIR - NIR) / (SWIR + NIR)$

El rango de valores para NDBI varía entre -1 y 1.

- Valores positivos: Superficies edificadas o con alta densidad de construcción.
- Valores cercanos a 0: Suelo desnudo, vegetación o zonas con baja densidad de construcción.
- Valores negativos: Agua.

Este índice permite estimar la superficie construida en áreas urbanas, pero depende bastante de la resolución espacial de las imágenes satelitales, con el fin de definir a detalle las estructuras asociadas a edificaciones. Por otro lado, también se puede ver afectado por la presencia de vegetación o de agua en la zona urbana, siendo poco preciso en áreas con construcciones de baja altura o con materiales de construcción con baja reflectancia en el infrarrojo cercano.




Fig. 23. Índice NDBI aplicado a la ciudad de Madrid.

Nota. Fuente <https://www.gisandbeers.com/calculo-indice-ndbi-analisis-urbanisticos/>

Los índices espectrales se relacionan estrechamente con la clasificación supervisada de coberturas en imágenes satelitales debido a su capacidad para resaltar características específicas del terreno, vegetación o cuerpos de agua. Durante el proceso de clasificación supervisada, estos índices espectrales se pueden utilizar como variables de entrada junto con otras características espectrales para entrenar y validar modelos de clasificación, como los algoritmos de Random Forest, CART, KNN, entre otros. Al incorporar índices espectrales en el proceso de clasificación, se puede mejorar la precisión y la capacidad de discriminación del modelo, lo que permite una clasificación más precisa de las coberturas en las imágenes satelitales.

Sistemas de Información Geográfica (SIG)

Los **Sistemas de Información Geográfica**, comúnmente conocidos como SIG o GIS por sus siglas en inglés (Geographic Information Systems), son herramientas tecnológicas poderosas que permiten capturar, almacenar, analizar y visualizar datos geoespaciales. Estos sistemas integran datos geográficos, tales como mapas, imágenes satelitales, datos de terreno y atributos asociados a ubicaciones específicas, facilitando la comprensión y la toma de decisiones en una amplia variedad de campos. Un SIG es una combinación de hardware, software, datos geográficos y métodos analíticos diseñados para gestionar información espacial y realizar análisis espaciales. Estos sistemas permiten representar el mundo real de forma digital, utilizando coordenadas geográficas y atributos asociados a ubicaciones específicas.

Los SIG son herramientas fundamentales para la toma de decisiones basada en la ubicación, ya que permiten visualizar y analizar datos geográficos de manera integrada. Esto facilita la identificación de patrones espaciales, la evaluación de riesgos y la planificación de acciones en función de la ubicación. Algunas aplicaciones comunes de los SIG incluyen la gestión de redes de infraestructuras (carreteras, redes de agua, redes eléctricas), el análisis de patrones delictivos, la planificación de rutas y logística, el monitoreo ambiental y la gestión de desastres naturales.



Fig. 24. Aplicaciones comunes para manipulación y procesamiento de información geográfica.

Nota. Fuente <https://mappinggis.com/2022/07/aplicaciones-gis-open-source/>

Los Sistemas de Información Geográfica (SIG) se basan en dos tipos de modelos de datos espaciales: Raster y Vectorial. A nivel del modelo de datos, Raster representa la información espacial como una cuadrícula de celdas, donde cada celda contiene un valor que representa una propiedad del terreno (ej. elevación, temperatura). La precisión depende del tamaño de la celda o pixel. Esta representación es adecuada para realizar análisis que requieren valores continuos (ej. análisis de pendiente, modelado hidrológico). Por otro lado, la representación vectorial almacena la información espacial como puntos, líneas y polígonos, definidos por sus coordenadas y atributos. Ofrece mayor precisión al representar objetos con sus coordenadas exactas, y es independiente de la escala, lo que permite ampliar sin perder calidad. Es ideal para análisis topológicos (ej. conectividad de redes, análisis de vecinos). Normalmente los archivos vectoriales suelen ser más pequeños que los Raster, especialmente para datos con poca complejidad geométrica.

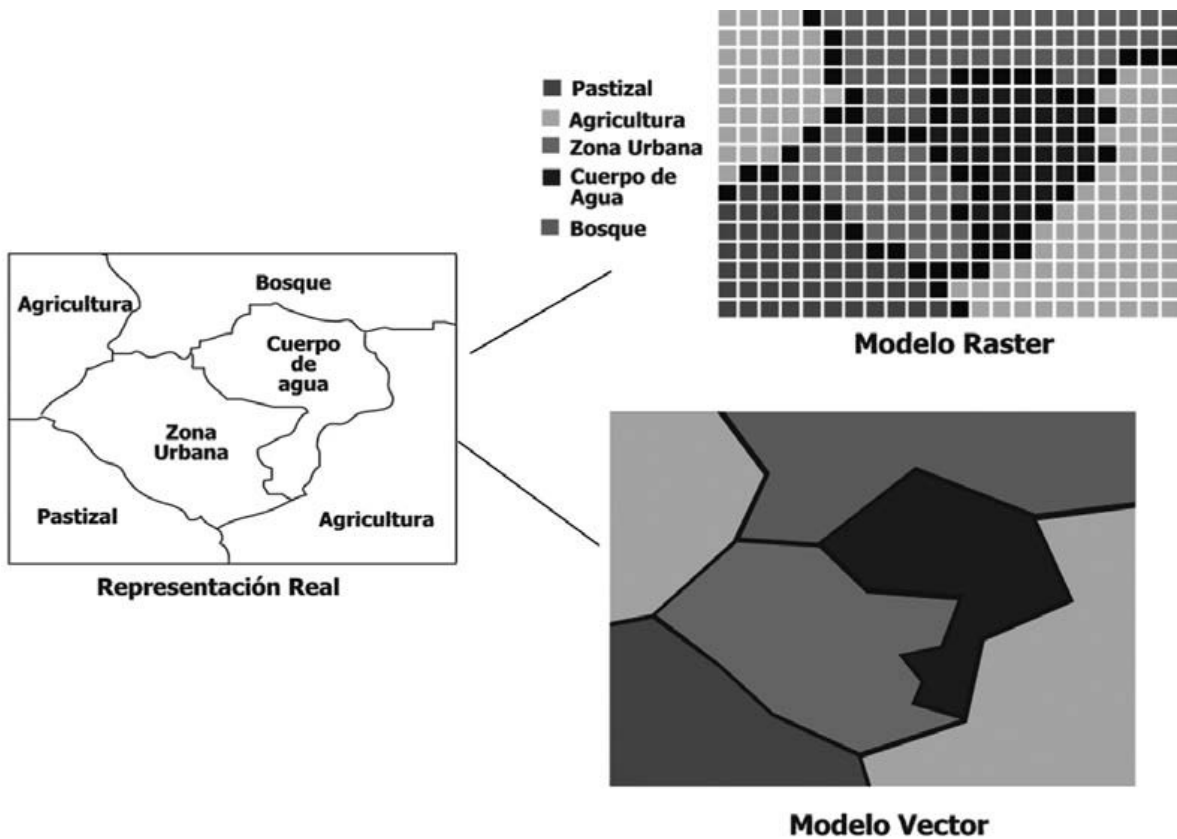


Fig. 25. Representación Raster y vectorial.

Nota. Fuente https://www.researchgate.net/publication/281464139_Sistemas_de_informacion_Geografica

Google Earth Engine (GEE)

Google Earth Engine (GEE) es una plataforma en la nube desarrollada por Google que facilita el análisis y procesamiento eficiente de grandes volúmenes de datos geoespaciales. Ofrece acceso a una amplia variedad de imágenes satelitales y datos geoespaciales, junto con herramientas integradas para análisis y procesamiento. GEE es utilizado por investigadores, científicos, desarrolladores y profesionales de diversos campos debido a su capacidad para manejar datos geoespaciales de alta resolución, series temporales históricas, datos de radar y climáticos. La plataforma utiliza la infraestructura de computación en la nube de Google para realizar cálculos rápidos y distribuidos en grandes conjuntos de datos, lo que la convierte en una herramienta poderosa y escalable para el análisis espacial. Los datos están disponibles de forma gratuita para usuarios registrados, lo que hace que GEE sea accesible para una amplia gama de usuarios.

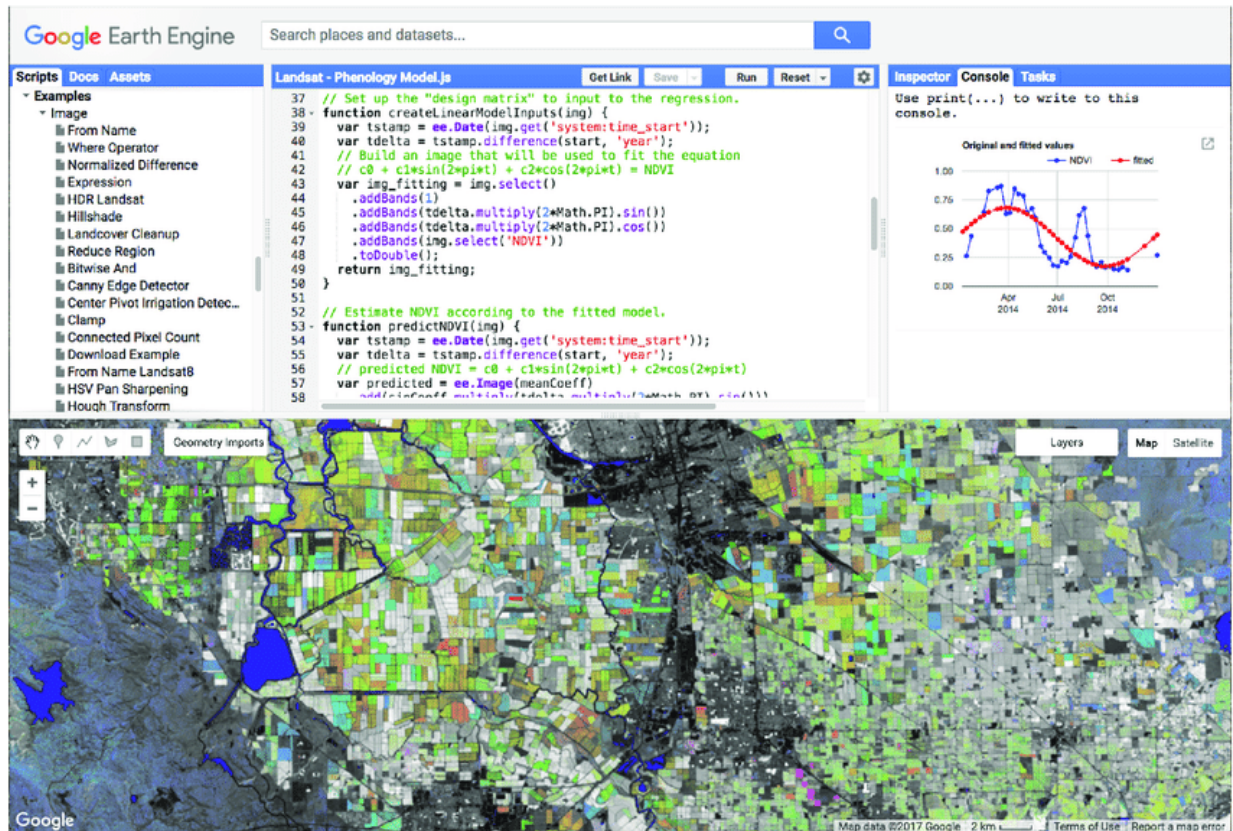


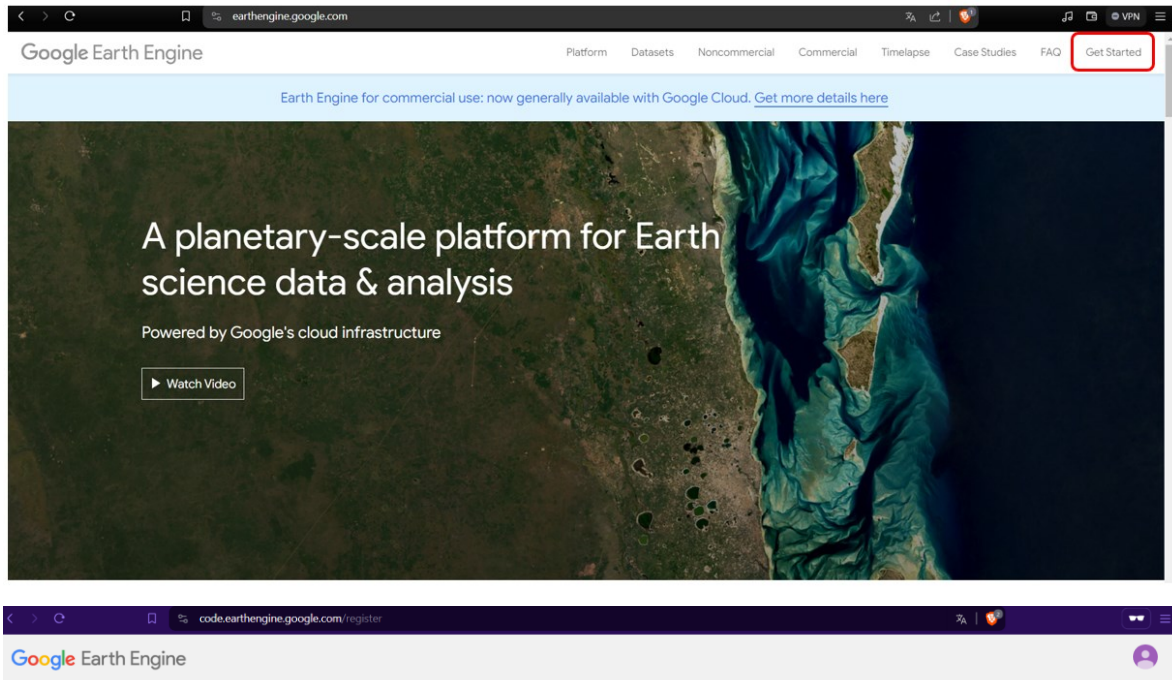
Fig. 26. Interfaz gráfica de Google Earth Engine.

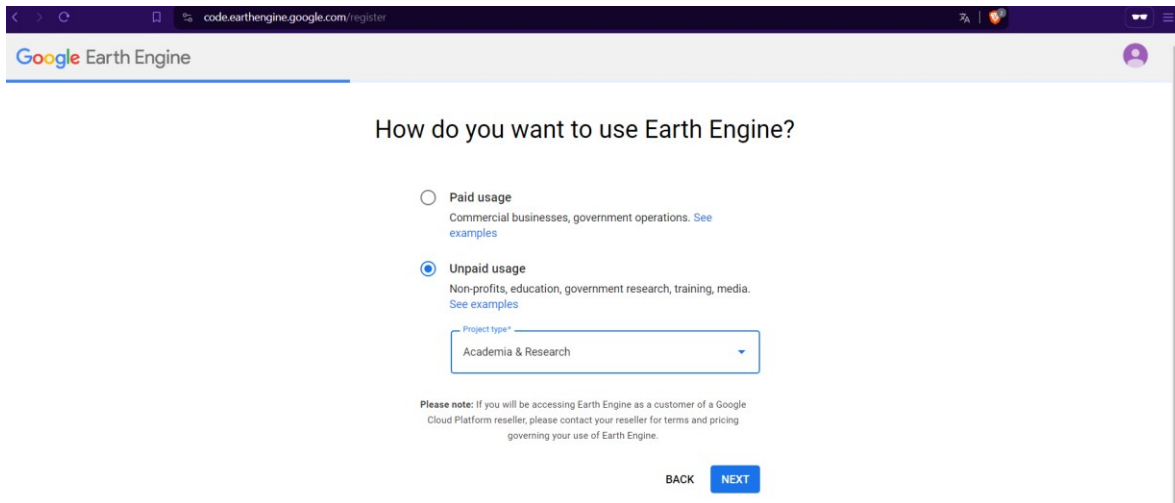
Nota. Fuente https://www.researchgate.net/figure/The-Earth-Engine-interactive-development-environment_fig3_318246365

Google Earth Engine ofrece acceso a una extensa variedad de datos geospaciales, desde imágenes de satélite hasta información climática y topográfica, eliminando la necesidad de descargar y almacenar grandes conjuntos de datos. Su infraestructura de procesamiento en la nube de Google permite realizar análisis complejos de manera rápida y eficiente, facilitando tareas que serían difíciles de ejecutar en equipos locales. Además, Earth Engine ofrece interfaces de programación intuitivas en JavaScript y Python, lo que permite realizar análisis personalizados sin necesidad de experiencia en programación, respaldado por tutoriales y recursos en línea. Su comunidad global activa fomenta la colaboración y el intercambio de experiencias y soluciones a través de foros y grupos de discusión. Finalmente, su gratuidad para fines de investigación, educación y usos sin fines de lucro lo convierte en una herramienta accesible para una amplia audiencia de usuarios.

Registro en la plataforma

Para acceder a Google Earth Engine, los usuarios deben registrarse en la plataforma: <https://earthengine.google.com/>, utilizando una cuenta de Google. Una vez registrados, tienen acceso completo a los datos y herramientas de la plataforma, así como a la documentación y recursos de aprendizaje.





code.earthengine.google.com/register

Google Earth Engine

How do you want to use Earth Engine?

Paid usage
Commercial businesses, government operations. [See examples](#)

Unpaid usage
Non-profits, education, government research, training, media. [See examples](#)

Project type*
Academia & Research

Please note: If you will be accessing Earth Engine as a customer of a Google Cloud Platform reseller, please contact your reseller for terms and pricing governing your use of Earth Engine.

BACK NEXT

Fig. 27. Registro del proyecto en Google Earth Engine.

Cabe recordar que Google Earth Engine configura, almacena y ejecuta el proyecto desde Google Cloud Platform, por lo que en el formulario de inscripción solicitara información adicional para la creación del espacio de trabajo.

Es importante recordar que para el uso de Google Earth Engine se requieren conocimientos básicos de programación y teledetección, ya que muchas operaciones se realizan mediante scripts de JavaScript que utilizan la API de Earth Engine. Sin embargo, la plataforma también ofrece interfaces gráficas para usuarios menos técnicos. Existen guías, ejemplos y documentación disponible en: <https://developers.google.com/earth-engine/guides/>

Al finalizar el registro del proyecto, se tendrá acceso a la interfaz de usuario, en la cual se puede gestionar el repositorio o área de trabajo a nivel de archivos (scripts, carpetas y proyectos), visualizar el código desarrollado y visualizar resultados a nivel de consola o visual en la vista geográfica.

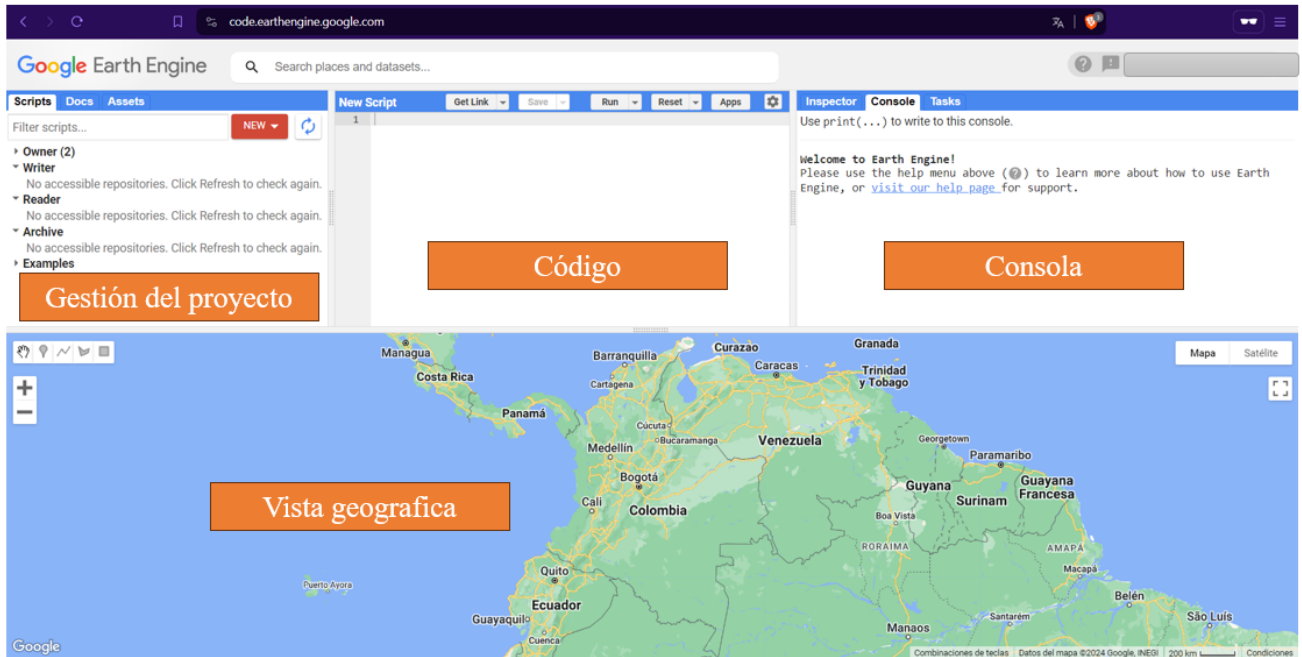


Fig. 28. Interfaz de usuario de Google Earth Engine.

Los proyectos dentro de Google Earth Engine (GEE) se administran como repositorios de código, estos se describen como un contenedor virtual donde puedes almacenar, organizar y compartir tus scripts, mapas y aplicaciones, en otras palabras, es como una biblioteca digital donde se puede guardar el trabajo y acceder a él desde cualquier lugar.

Scripts

En el área de gestión de proyectos se podrán crear nuevos repositorios o proyectos, carpetas y archivos de código (scripts).

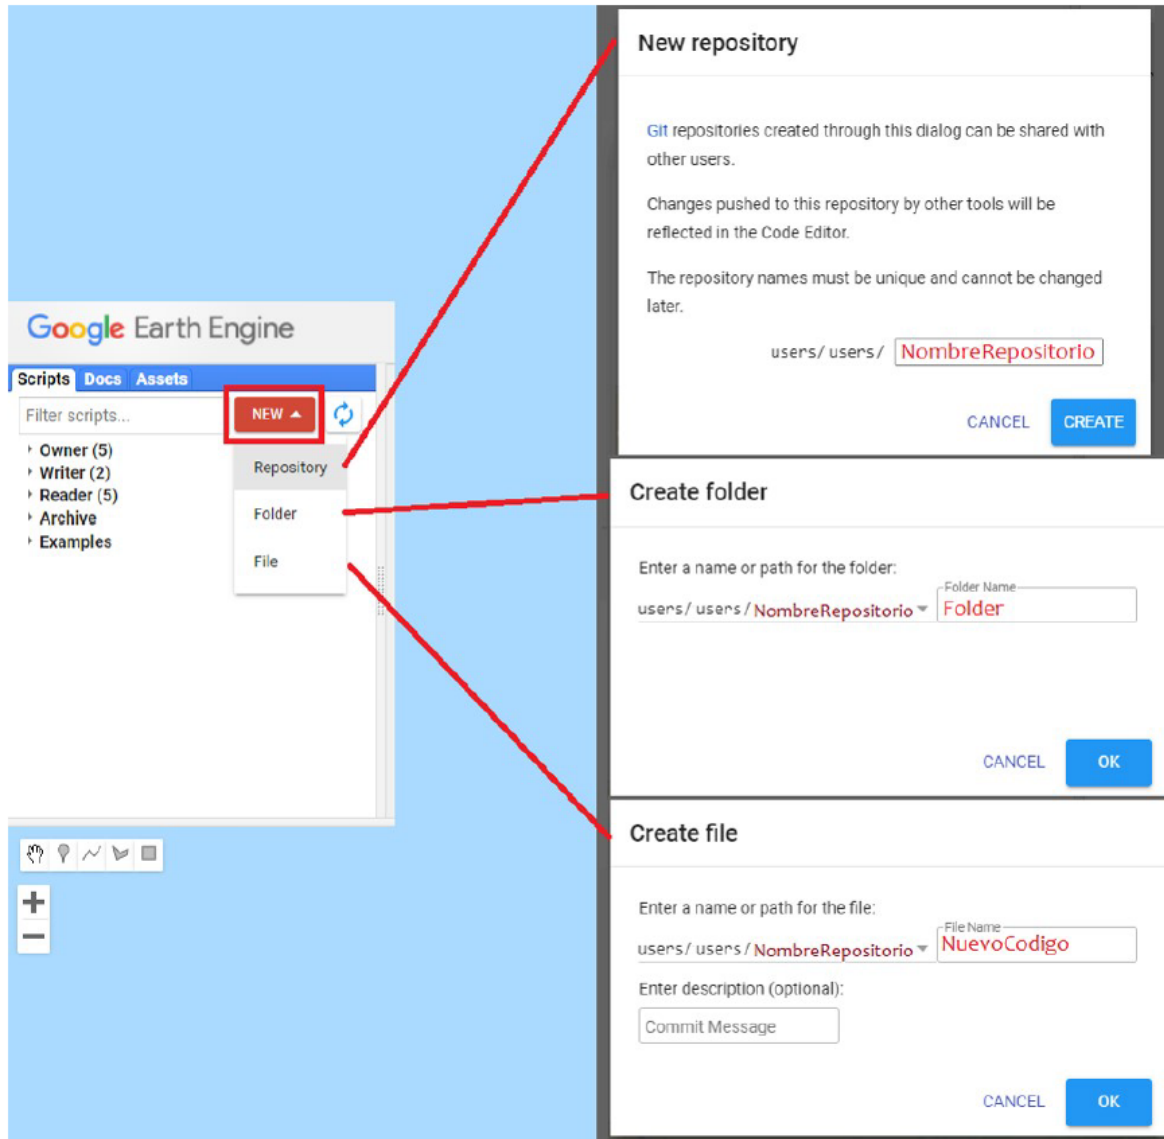


Fig. 29. Área de trabajo para la gestión del proyecto.

Dentro de este mismo apartado se encuentra un submenú con las siguientes descripciones:

- **Owner (Propietario):** en esta sección se almacenan los scripts creados por el usuario.
- **Writer (Editor):** en esta sección se almacenan los scripts creados por otros usuarios y que pueden acceder para editar, esto debido a que contara con permisos sobre estos.
- **Reader (Lector):** en esta sección se almacenan los scripts creados por otros usuarios, los cuales se pueden ver o leer, pero no se podrán editar, ya que no se contarán con permisos sobre estos.
- **Archive (Archivo):** en esta sección se pueden almacenar scripts que ya no estén en uso constante o activos en el proyecto actual, y que aún no se desean eliminar.

- **Examples (Ejemplos):** en esta sección se accede a ejemplos de código para hacer algunas tareas específicas. Por ejemplo, existe un apartado para Feature Collection que presentara el código para medir la distancia entre dos puntos ubicados en el mapa.

Docs

En el apartado de Docs, se encuentra la documentación oficial de Google Earth Engine, donde se describen sus principales métodos o funciones, y los parámetros requeridos para la implementación de estas.

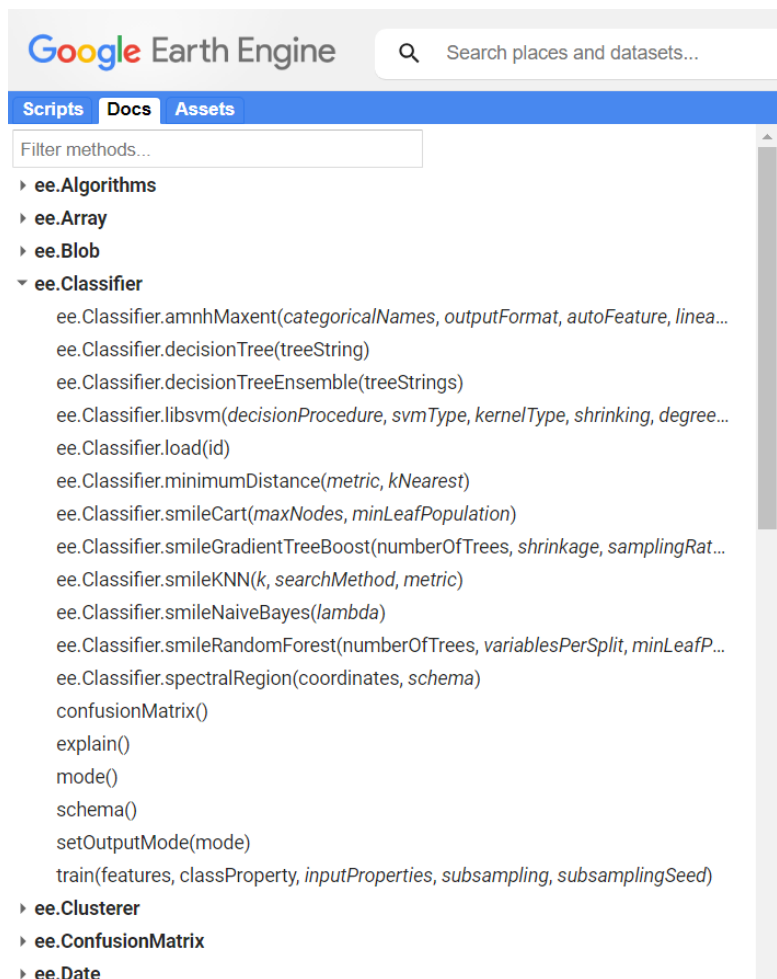


Fig. 30. Algunos ítems disponibles en la sección de documentación.

Assets

Esta es una sección donde se pueden almacenar y administrar datos, scripts y aplicaciones. Los activos pueden ser de cualquier tipo, como:

- **Conjuntos de datos:** Imágenes, ráster, vectoriales, etc.
- **Scripts:** Código JavaScript o Python para realizar análisis espaciales.
- **Aplicaciones:** Aplicaciones web desarrolladas con Google Earth Engine.

Preprocesamiento de Imágenes Satelitales con Google Earth Engine (GEE)

El preprocesamiento de imágenes satelitales con GEE se refiere a una serie de pasos y técnicas aplicadas a las imágenes satelitales antes de utilizarlas para análisis o visualización. Estos pasos pueden incluir la corrección atmosférica para eliminar efectos atmosféricos no deseados, la calibración radiométrica para convertir los valores digitales de las imágenes en unidades físicas de reflectancia, la eliminación de nubes y sombras para mejorar la calidad de la imagen y la alineación de imágenes de diferentes fechas o sensores. El preprocesamiento es fundamental para asegurar la calidad y consistencia de los datos antes de realizar análisis cuantitativos o cualitativos. En GEE, muchas de estas técnicas de preprocesamiento están disponibles como funciones predefinidas que pueden aplicarse fácilmente a las imágenes satelitales cargadas en la plataforma, lo que facilita el acceso a datos listos para su uso en diversas aplicaciones.

Corrección atmosférica

La corrección atmosférica es un proceso utilizado en el análisis de imágenes satelitales para eliminar o reducir los efectos no deseados causados por la atmósfera terrestre en la radiación electromagnética que llega al sensor del satélite. La atmósfera puede dispersar, absorber o atenuar la radiación electromagnética, lo que afecta la calidad de las imágenes capturadas por el sensor.

Existen varios métodos para corregir estos efectos atmosféricos. Uno de los enfoques comunes es utilizar modelos físicos que simulan la interacción de la luz con los componentes atmosféricos, como el vapor de agua, los aerosoles y los gases. Estos modelos pueden tener en cuenta la composición atmosférica, la geometría de la escena y la longitud de onda de la radiación electromagnética. Otro enfoque común es el método de la referencia oscura, que utiliza áreas en la

imagen que se supone que son completamente oscurecidas por la atmósfera, como cuerpos de agua profundos o sombras en el terreno. Al comparar la radiación medida en estas áreas con la radiación esperada, se puede estimar y corregir el efecto atmosférico en toda la imagen.

En GEE se encuentran disponibles imágenes con niveles de preprocesamiento básico y otras con correcciones atmosféricas. Por ejemplo, Sentinel 2 ofrece productos con cálculo de reflectancia en el techo de la atmósfera (TOA-S2) y corrección completa hasta reflectancia en la superficie (BOA-S2_SR). Se recomienda el uso de BOA-S2_SR en proyectos que requieran clasificación de imágenes, estudios multitemporales, entre otros, ya que emplea un modelo físico para eliminar el efecto atmosférico en los valores de la reflectancia. Para cargar estas imágenes en GEE, es necesario comprender el concepto de colecciones, que agrupan imágenes relacionadas, facilitando la búsqueda y selección de datos según criterios espaciales y temporales mediante filtros aplicados a colecciones como "COPERNICUS/S2_SR" para nivel 2A y "COPERNICUS/S2" para nivel 1C [13].

Corrección radiométrica

La calibración radiométrica es un proceso utilizado para convertir los valores digitales registrados por el sensor en unidades físicas de radiación electromagnética, como la reflectancia o la radiancia. Esto es importante para garantizar que los valores registrados por el sensor sean consistentes y comparables entre diferentes imágenes y plataformas satelitales. Este proceso implica varios pasos, que pueden incluir la corrección de los valores digitales por la respuesta del sensor, la compensación por la influencia de la atmósfera, la eliminación de efectos de iluminación y la normalización de la imagen para que los valores reflejen adecuadamente la cantidad de radiación electromagnética que llega a la superficie terrestre [14].

En Google Earth Engine, la calibración radiométrica se realiza mediante el uso de imágenes satelitales que ya han sido preprocesadas y calibradas por los proveedores de datos. Esto significa que los valores digitales de las imágenes han sido ajustados para representar valores de reflectancia o radiancia en lugar de simplemente valores de píxeles. Cuando los usuarios acceden a imágenes satelitales en Google Earth Engine, como las proporcionadas por Landsat o Sentinel, estas ya están calibradas radiométricamente. Esto significa que los valores digitales de los píxeles en las imágenes

representan la cantidad de radiación electromagnética reflejada o emitida por la superficie terrestre en unidades físicas.

Eliminación de nubes y sombras

Las nubes y las sombras obstruyen la visión directa de la superficie terrestre, lo que dificulta la interpretación de características como la vegetación y los cuerpos de agua, limitando así su utilidad para diferentes aplicaciones. Además, alteran la señal radiométrica al afectar la cantidad de luz solar que llega a la superficie terrestre y se refleja hacia el sensor del satélite, lo que puede distorsionar los valores radiométricos registrados en las imágenes y complicar la comparación entre diferentes fechas. Esto, a su vez, puede afectar la precisión del análisis cuantitativo, especialmente en aplicaciones que requieren mediciones precisas de la reflectancia o la temperatura de la superficie.

En Google Earth Engine, la eliminación de sombras y nubes se puede abordar mediante diversas técnicas y herramientas disponibles en la plataforma. Uno de los enfoques consiste en aplicar filtros por calidad de píxeles, utilizando bandas de calidad que indican la confiabilidad de cada píxel y seleccionando solo aquellos de alta calidad, descartando los afectados por nubes u otros tipos de contaminación. Además, se pueden crear composiciones de imágenes que minimicen el impacto de las nubes, utilizando técnicas como la composición de la mediana o la mínima de múltiples imágenes. Asimismo, se pueden aplicar máscaras predefinidas o crear máscaras personalizadas para identificar y eliminar píxeles afectados por nubes y sombras, como el uso del algoritmo Fmask para detectar nubes y sombras en imágenes Landsat. En casos donde las nubes u otras obstrucciones cubren solo una parte de la escena, se puede recurrir al fusinado de imágenes de diferentes fechas y coberturas para obtener una imagen completa y libre de nubes y sombras. Además, en áreas con cobertura nubosa, los datos de radar pueden ser útiles, ya que pueden penetrar a través de las nubes y proporcionar información sobre la superficie terrestre debajo de ellas, lo que permite complementar o reemplazar datos ópticos en ciertas situaciones. Estos enfoques ofrecen distintas opciones para abordar la eliminación de sombras y nubes en Google Earth Engine, y la técnica específica a utilizar dependerá del tipo de imágenes disponibles, las características de la escena y los requisitos del análisis.

VI. METODOLOGÍA

La metodología propuesta se ha desarrollado con el objetivo de llevar a cabo la clasificación de coberturas en una región específica de Colombia. Se emplea un enfoque de entrenamiento supervisado sobre imágenes satelitales, utilizando los modelos de clasificación disponibles en Google Earth Engine. Este método, adaptable y escalable, se ha diseñado para ser aplicable no solo en la zona de estudio actual, sino también en otras áreas del territorio nacional que requieran análisis similares.

Contexto geográfico y temporal de estudio

Se definió como área de interés el territorio del municipio El Carmen de Viboral y las veredas Rivera, La Aurora, Betania, Viboral y San Isidro, debido a su relevancia en la representación de una amplia variedad de coberturas terrestres. Estas áreas abarcan una diversidad de paisajes, que van desde zonas urbanas hasta áreas rurales y boscosas, lo que proporciona una muestra representativa de los diferentes tipos de coberturas presentes en la región. Además, la inclusión de estas veredas permite capturar la heterogeneidad espacial característica del municipio, lo que enriquece el análisis y la comprensión de las dinámicas de uso del suelo y cobertura vegetal en el área de estudio.

La cabecera municipal registra una temperatura promedio de 17°C y se encuentra a una altitud de 2.150 metros sobre el nivel del mar, clasificándose como una zona de tierra templada o piso mesotérmico. Este tipo de clima favorece la agricultura intensiva, siendo conocida por la producción de rosas y otros productos agrícolas destinados a un mercado amplio. Además, la altitud propicia la formación de lluvias orográficas, lo que se refleja en una vegetación variada y la presencia de helechos arborescentes, indicadores de una notable adaptación y estabilidad ecológica. Por otro lado, la zona oriental presenta temperaturas promedio entre 22°C y 24°C, con altitudes que van desde los 900 hasta los 1800 metros sobre el nivel del mar, siendo un área intermedia entre la zona templada y caliente. En contraste, la zona occidental tiene temperaturas promedio más bajas, entre 8°C y 13°C, con altitudes de 2300 a 3000 metros sobre el nivel del mar, siendo óptima para el cultivo de papa debido a sus condiciones ecológicas específicas [15].



Fig. 31. Área de interés definida para el estudio.

En cuanto al satélite y dataset de imágenes a utilizar para esta zona, se definió el uso Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A, ya que proporciona imágenes de reflectancia de superficie (SR) que han sido corregidas atmosféricamente, lo que significa que los efectos atmosféricos, como la dispersión de moléculas de aire y la absorción de gases y aerosoles, han sido tenidos en cuenta y corregidos. Esto garantiza una mayor precisión en la interpretación de las imágenes y una mejor representación de las condiciones reales de la superficie terrestre en la zona de interés. Además, las imágenes del producto Level-2A están compuestas por mosaicos de 110 x 110 km² en geometría cartográfica, lo que proporciona una cobertura amplia y consistente de la zona de interés. Esta subdivisión de la Tierra en mosaicos predefinidos, con una gran superposición entre baldosas vecinas, asegura una representación homogénea y detallada de toda el área de estudio.

Este conjunto de imágenes dispone de las siguientes bandas:

Tabla 2. Bandas disponibles para Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A

Nombre	Escala	Tamaño de píxel	Longitud de onda	Descripción
B1	0.0001	60 metros	443,9 nm (S2A) / 442,3 nm (S2B)	Aerosoles
B2	0.0001	10 metros	496,6 nm (S2A) / 492,1 nm (S2B)	Azul
B3	0.0001	10 metros	560 nm (S2A) / 559 nm (S2B)	Verde
B4	0.0001	10 metros	664,5 nm (S2A) / 665 nm (S2B)	Rojo
B5	0.0001	20 metros	703,9 nm (S2A) / 703,8 nm (S2B)	Borde rojo 1
B6	0.0001	20 metros	740,2 nm (S2A) / 739,1 nm (S2B)	Borde rojo 2
B7	0.0001	20 metros	782,5 nm (S2A) / 779,7 nm (S2B)	Borde rojo 3
B8	0.0001	10 metros	835,1 nm (S2A) / 833 nm (S2B)	NIR
B8A	0.0001	20 metros	864,8 nm (S2A) / 864 nm (S2B)	Borde rojo 4
B9	0.0001	60 metros	945 nm (S2A) / 943,2 nm (S2B)	Vapor de agua
B11	0.0001	20 metros	1613,7 nm (S2A) / 1610,4 nm (S2B)	SWIR 1
B12	0.0001	20 metros	2202,4 nm (S2A) / 2185,7 nm (S2B)	SWIR 2
AOT	0.001	10 metros		Espesor óptico del aerosol
WVP	0.001	10 metros		Presión de vapor de agua. La altura que ocuparía el agua si el vapor se condensara en líquido y se distribuyera uniformemente por la columna.
SCL		20 metros		Mapa de clasificación de escenas (el valor 0 "Sin datos" está enmascarado)
TCI_R		10 metros		Imagen en color verdadero, canal rojo
TCI_G		10 metros		Imagen en color verdadero, canal verde
TCI_B		10 metros		Imagen en color verdadero, canal azul
MSK_CLDPRB		20 metros		Mapa de probabilidad de nube (falta en algunos productos)
MSK_SNWPRB		10 metros		Mapa de probabilidad de nieve (falta en algunos productos)
QA10		10 metros		siempre vacío
QA20		20 metros		siempre vacío
QA60		60 metros		máscara de nube

Por último, se filtró la colección de imágenes para seleccionar solo aquellas en las que el porcentaje nubosidad sea inferior al 15%, esto garantiza una buena visibilidad de la superficie terrestre. Además, se filtró aún más la colección para seleccionar solo las imágenes capturadas en un rango de fechas específico, en este caso, desde el 30 de septiembre de 2023 hasta el 30 de marzo de 2024, donde se seleccionó solo la primera imagen que cumplió con todos los criterios de filtrado establecidos anteriormente.

Definición de coberturas y etiquetado

Las coberturas seleccionadas para la clasificación abarcan una diversidad de elementos que recubren la superficie terrestre, cada uno con atributos únicos que los hacen fácilmente identificables en las imágenes satelitales. En este contexto, se detallan a continuación las etiquetas y las características distintivas de cada cobertura a ser clasificada.

Invernaderos: Áreas cubiertas por estructuras de invernadero utilizadas para el cultivo protegido de plantas. Estas estructuras pueden tener formas y tamaños variados y suelen ser fácilmente identificables por su geometría regular y su característica tonalidad en imágenes satelitales.



Fig. 32. Invernaderos presentes en la zona de interés.

Bosque: Áreas cubiertas por vegetación arbórea densa y diversa. Los bosques suelen tener una apariencia distintiva en imágenes satelitales debido a la presencia de copas de árboles que crean un patrón de sombreado y textura en la superficie.



Fig. 33. Bosque presente en la zona de interés.

Viviendas: Áreas urbanas o rurales caracterizadas por la presencia de estructuras residenciales. Las viviendas suelen ser visibles en imágenes satelitales como patrones regulares o agrupamientos de edificaciones con formas y tamaños diversos.




Fig. 34. Zonas de viviendas presentes en la zona de interés.

Carreteras: Infraestructuras lineales destinadas al tránsito vehicular. Las carreteras son identificables en imágenes satelitales por su forma alargada y regular, y su tonalidad más clara en comparación con el entorno circundante.



Fig. 35. Carretera presente en la zona de interés.

Suelo desnudo: Áreas desprovistas de vegetación o cobertura superficial. El suelo desnudo puede presentarse en imágenes satelitales como áreas de tonalidad uniforme y baja reflectancia en comparación con otras coberturas.



Fig. 36. Suelo desnudo presente en la zona de interés.

Cultivos: Áreas dedicadas al cultivo de plantas agrícolas. Los cultivos pueden ser identificados en imágenes satelitales por su patrón regular, cambios estacionales y tonalidades específicas asociadas con diferentes tipos de cultivos.



Fig. 37. Zonas de cultivo presentes en la zona de interés.

Pastos: Áreas utilizadas para el pastoreo de animales. Los pastos suelen tener una apariencia uniforme y una tonalidad más clara en comparación con otras coberturas, especialmente durante períodos de crecimiento activo.



Fig. 38. Pastizal presente en la zona de interés.

Entrenamiento

El proceso de entrenamiento de los modelos implica la utilización de una cantidad específica de puntos de referencia como insumo. Estos puntos de referencia se asocian con ubicaciones geográficas donde se identifica una cobertura específica y se colocan manualmente en la imagen satelital. Posteriormente, se procede a dividir este conjunto de datos en dos subconjuntos: el conjunto de entrenamiento y el conjunto de validación. Esta división es fundamental para evaluar la capacidad predictiva del modelo y su capacidad para generalizar a datos no vistos.

El conjunto de entrenamiento se utiliza para ajustar los parámetros del modelo y aprender los patrones presentes en los datos. Por otro lado, el conjunto de validación se reserva para evaluar el rendimiento del modelo en datos que no han sido utilizados durante el entrenamiento. Esto ayuda

a detectar posibles problemas de sobreajuste (cuando el modelo se ajusta demasiado a los datos de entrenamiento y no puede generalizar bien) o sub ajuste (cuando el modelo es demasiado simple para capturar la complejidad de los datos).

Una vez que se ha completado la segmentación del conjunto de datos y se han definido los conjuntos de entrenamiento y validación, se procede a implementar el modelo de clasificación utilizando el conjunto de entrenamiento. Este modelo se ajusta a los datos de entrenamiento y se evalúa su rendimiento utilizando el conjunto de validación. Dependiendo de los resultados de esta evaluación, el modelo puede ser ajustado y refinado para mejorar su capacidad predictiva antes de su aplicación en datos no etiquetados.

Cada uno de los modelos de clasificación supervisada disponibles en Google Earth Engine presenta características distintivas que los hacen adecuados para diferentes situaciones. El modelo Random Forest se destaca por su capacidad para construir múltiples árboles de decisión a partir de subconjuntos aleatorios de datos, lo que mejora la precisión y la robustez ante el ruido. Por otro lado, el método Classification and Regression Trees (CART) es conocido por su interpretabilidad y facilidad de visualización, ya que construye un árbol de decisión dividiendo repetidamente los datos en subconjuntos más pequeños. El algoritmo K Nearest Neighbors (KNN) se basa en la proximidad de los datos y no requiere un entrenamiento explícito, lo que lo hace útil para conjuntos de datos pequeños y no lineales. Finalmente, Gradient Tree Boost es eficaz para capturar relaciones no lineales y corregir errores secuencialmente mediante la construcción de múltiples árboles de decisión. La elección del modelo más adecuado dependerá de la naturaleza de los datos y de los objetivos específicos del análisis.

Durante el proceso de entrenamiento del clasificador, todas las bandas de la imagen satelital se tienen en cuenta al extraer características relevantes que se utilizarán como variables predictoras en el modelo. Esto significa que cada banda es tratada como una fuente potencial de información para ayudar al clasificador a distinguir entre las diferentes clases de cobertura.

Validación

Dado a que es crucial evaluar qué tan bien generaliza el modelo a datos no vistos, es decir, a datos que no se utilizaron durante el entrenamiento, se implementan una serie de métricas para evaluar su rendimiento y precisión. Es común que para modelos de clasificación supervisada en teledetección se utilicen métricas como: la exactitud general, la exactitud de usuario, la exactitud de productor y el índice Kappa.

El **accuracy** (precisión) es una medida que indica la proporción de todas las clasificaciones correctas respecto al total de observaciones. Es una métrica útil para evaluar la precisión general del modelo, pero puede no ser suficiente para evaluar su rendimiento en cada clase de cobertura por separado.

La **consumersAccuracy** (confianza) y la **producersAccuracy** (especificidad) son métricas que se enfocan en la precisión de las clasificaciones para cada clase de cobertura. La **consumersAccuracy** se refiere a la proporción de observaciones correctamente clasificadas para una clase específica, según la percepción del usuario. Por otro lado, la **producersAccuracy** se refiere a la proporción de observaciones correctamente clasificadas para una clase específica, según los datos de referencia o ground truth.

El **índice Kappa** es una medida que corrige la exactitud general teniendo en cuenta el acuerdo esperado por azar entre las clasificaciones y los datos de referencia. Proporciona una evaluación más robusta del rendimiento del modelo al considerar el acuerdo observado en relación con el acuerdo esperado al azar.

VII. RESULTADOS

Dentro del marco geográfico y temporal definido en la metodología, se obtuvo una imagen satelital que sintetiza la información de las 23 bandas descriptivas proporcionadas por el conjunto de datos del Harmonized Sentinel-2. Esta imagen, adquirida y seleccionada meticulosamente, constituye una representación detallada y significativa del área de interés en el momento específico del estudio. Es crucial destacar que la imagen disponible a través del editor de Google Earth Engine (GEE) ofrece una mayor resolución espacial, lo que facilita la identificación de las coberturas. No obstante, la imagen satelital completa contiene información adicional que no es perceptible mediante una simple visualización en RGB, y aunque esta última pueda no parecer tan nítida, su contenido resulta fundamental para el proceso de entrenamiento del clasificador, ya que aporta detalles relevantes para la clasificación de las coberturas.



Fig. 39. Comparación de la imagen satelital para el área de interés representada por sus bandas RGB con la disponible por el editor de GEE.

El área de estudio correspondía a alrededor de 3150 hectáreas, donde se establecieron un total de 1820 puntos de referencia, distribuidos uniformemente con 260 puntos asignados a cada tipo de cobertura. Esta información, fundamental para el análisis, constituyó el conjunto de datos primario. Posteriormente, este conjunto de datos se subdividió de manera aleatoria en dos grupos:

uno de entrenamiento, compuesto por 1270 puntos, y otro de validación, que incluyó los restantes 550 puntos.

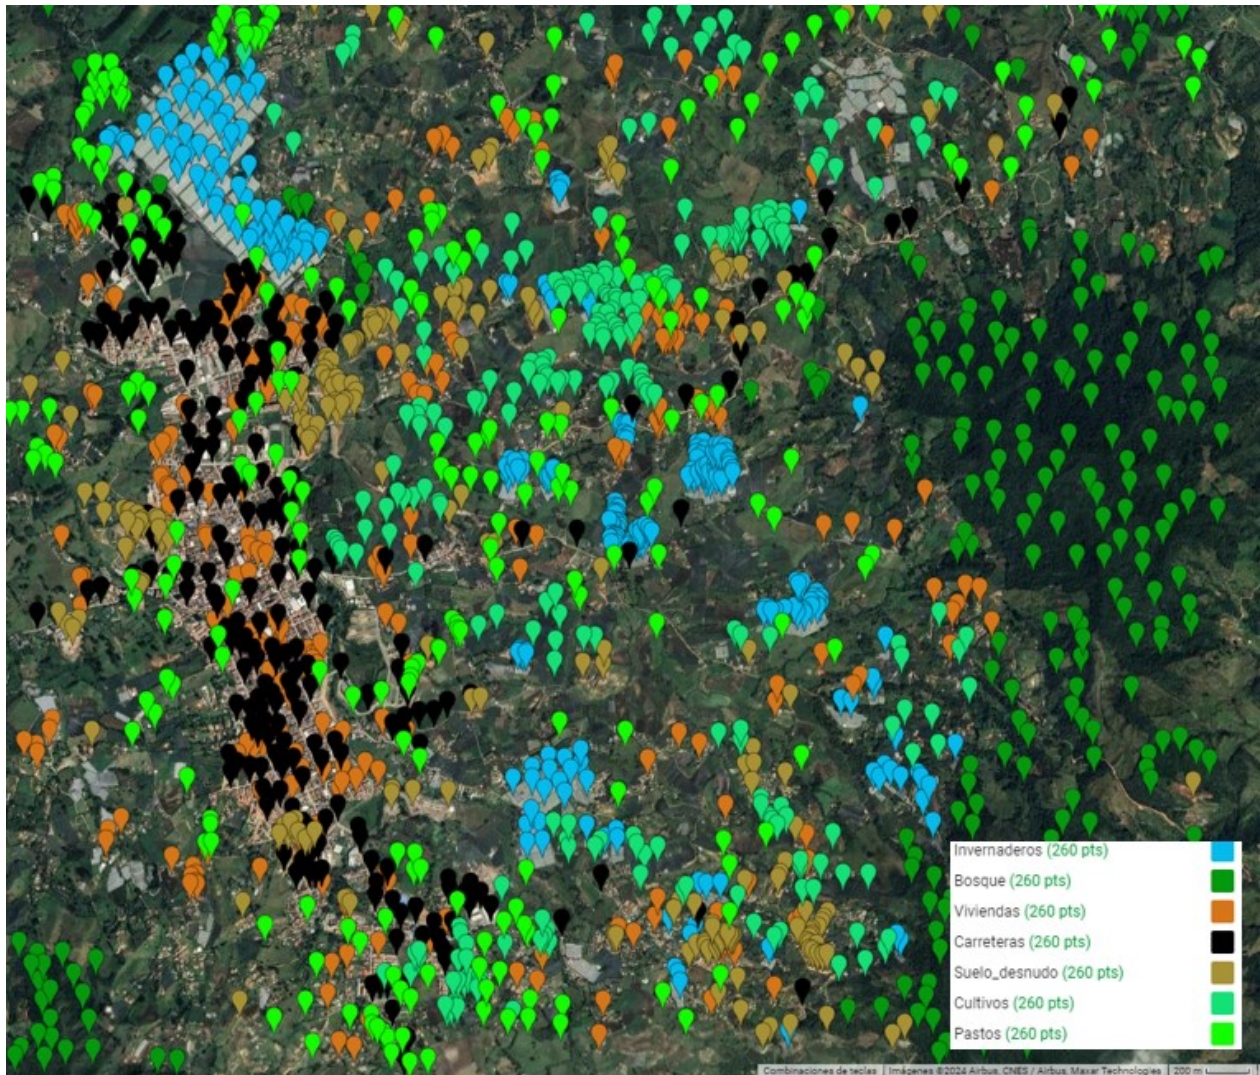


Fig. 40. Resultado del etiquetado manual.

Todos los modelos se configuraron utilizando los valores por defecto en la mayoría de sus parámetros. Sin embargo, se hizo una excepción en el parámetro conocido como "Número de árboles" para los modelos de Random Forest y Gradient Tree Boost, ya que se asignó un valor de 15 árboles para este parámetro con el fin de optimizar el equilibrio entre la complejidad del modelo y su capacidad para capturar patrones en los datos.

A partir del entrenamiento de los modelos, se obtuvo la siguiente imagen como resultado de la clasificación para las coberturas descritas:




Fig. 41. Resultado de clasificación - (Sup. -Izq.) Random Forest, (Sup. -Der.) CART, (Inf. -Izq.) KNN y (Inf. -Der.) Gradient Tree Boost.

Se obtuvieron las matrices de confusión correspondientes a cada uno de los modelos implementados. Estas matrices proporcionan una representación detallada de la precisión de la clasificación al mostrar el número de observaciones correctamente clasificadas y aquellas que fueron erróneamente asignadas a cada clase, permitiendo evaluar el rendimiento del modelo en términos de la precisión, el sesgo y la sensibilidad para cada clase de cobertura.

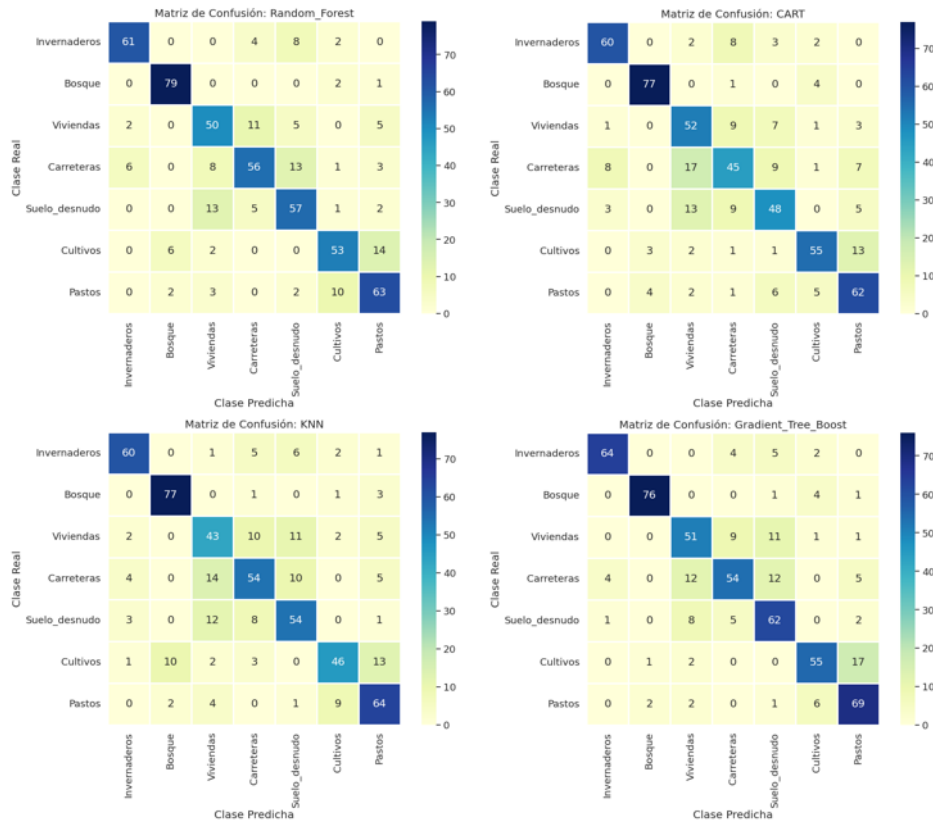


Fig. 42. Matrices de confusión para los modelos evaluados.

Por otro lado, con el fin de evaluar y comparar los modelos de clasificación supervisada, proporcionando información valiosa sobre su capacidad para clasificar correctamente las diferentes clases de cobertura y su rendimiento general en la tarea de clasificación, se obtuvieron las siguientes métricas.

Tabla 3. Precisión e índice Kappa obtenidos de la validación de los modelos.

	accuracy	Índice Kappa
Random_Forest	76,18%	72,20%
CART	72,55%	67,97%
KNN	72,36%	67,73%
Gradient Tree Boost	78,36%	74,75%

Tabla 4. ConsumersAccuracy obtenido para la validación de los modelos.

consumersAccuracy	Random Forest	CART	KNN	Gradient Tree Boost
Bosque	88,41%	83,33%	85,71%	92,75%
Carreteras	90,80%	91,67%	86,52%	96,20%
Cultivos	65,79%	59,09%	56,58%	68,00%
Invernaderos	73,68%	60,81%	66,67%	75,00%
Pastos	67,06%	64,86%	65,85%	67,39%
Suelo desnudo	76,81%	80,88%	76,67%	80,88%
Viviendas	71,59%	68,89%	69,57%	72,63%

Tabla 5. ProducersAccuracy obtenido para la validación de los modelos.

producersAccuracy	Random Forest	CART	KNN	Gradient Tree Boost
Bosque	81,33%	80,00%	80,00%	85,33%
Carreteras	96,34%	93,90%	93,90%	92,68%
Cultivos	68,49%	71,23%	58,90%	69,86%
Invernaderos	64,37%	51,72%	62,07%	62,07%
Pastos	73,08%	61,54%	69,23%	79,49%
Suelo desnudo	70,67%	73,33%	61,33%	73,33%
Viviendas	78,75%	77,50%	80,00%	86,25%

Por último, se realizó un cálculo del área aproximada en hectáreas para cada tipo de cobertura dentro del área de estudio a partir de las imágenes clasificadas generadas por los modelos.

Tabla 6. Área calculada para cada cobertura a partir de los resultados de clasificación.

	Random Forest [ha]	CART [ha]	KNN [ha]	Gradient Tree Boost [ha]
Bosque	675,60	809,37	697,39	738,33
Carreteras	230,43	230,23	236,35	219,37
Cultivos	810,56	751,63	721,09	761,35
Invernaderos	112,04	119,37	121,28	111,94
Pastos	962,76	794,94	996,96	947,47
Suelo desnudo	92,06	140,88	136,95	109,12
Viviendas	251,14	288,17	224,58	247,00

VIII. CONCLUSIONES

Los resultados obtenidos sugieren de forma general que, al entrenar diferentes modelos bajo condiciones iniciales similares, se producen resultados que exhiben similitudes, aunque no son idénticos. Este fenómeno resalta la influencia de múltiples factores en el proceso de entrenamiento y la naturaleza intrínseca de cada algoritmo de aprendizaje automático.

Al contrastar las imágenes derivadas de la clasificación con la imagen de referencia, se observa una notable similitud en la delimitación de las diversas zonas o parches de cada tipo de cobertura entre los modelos analizados. Específicamente, se destaca que Random Forest y KNN ofrecen una delimitación visual más precisa del área boscosa (verde oscuro), mientras que este último no logra delimitar muy bien los invernaderos (gris). No obstante, es crucial reconocer la subjetividad inherente a la interpretación visual de estas clasificaciones en comparación con las métricas obtenidas y los datos de campo proporcionados por expertos en terreno. A pesar de que los algoritmos de clasificación pueden generar clasificaciones objetivas basadas en características espectrales y patrones presentes en los datos, la interpretación visual está influenciada por la percepción individual, la experiencia del observador y la calidad de la imagen. Estos factores pueden conducir a interpretaciones sesgadas, destacando la importancia de considerar tanto la precisión cuantitativa como la interpretación visual al evaluar los resultados de la clasificación en teledetección

Por otro lado, al comparar los resultados de precisión obtenidos para los cuatro modelos, se destaca que Gradient Tree Boost muestra una ligera ventaja sobre los demás. Esta superioridad podría atribuirse a la naturaleza secuencial de este modelo, el cual construye una secuencia de árboles de decisión, cada uno enfocado en corregir los errores del modelo previo. Esta estrategia permite una mejora gradual en la precisión del modelo a medida que se agregan más árboles, lo que posiblemente conduzca a una mayor precisión en comparación con modelos que carecen de esta capacidad de corrección secuencial, como Random Forest y CART. Este hallazgo subraya la eficacia del enfoque de Gradient Tree Boost en la mejora progresiva de la precisión del modelo, lo que puede resultar en un mejor rendimiento en la clasificación de datos de teledetección.

Según las métricas evaluadas, se observa que la precisión de la clasificación de la cobertura de cultivos se mantiene consistentemente por debajo del 70%. Esta situación se atribuye a la considerable variabilidad intrínseca de esta clase, la cual está influenciada por factores como el

tipo específico de cultivo, su extensión territorial y las características del terreno donde se encuentran ubicados. La diversidad en los tipos de cultivos, así como las variaciones en su distribución espacial y características morfológicas, contribuyen a la complejidad de su clasificación y, por ende, a la dificultad para alcanzar una precisión más elevada en su identificación mediante técnicas de teledetección y clasificación supervisada.

En conclusión, la implementación y validación de varios modelos en el proceso de clasificación de imágenes de teledetección resulta fundamental para obtener resultados más precisos y confiables. Al evaluar y comparar múltiples modelos, se puede mitigar el sesgo inherente a un único enfoque de clasificación y se aumenta la probabilidad de encontrar aquel que mejor se ajuste al conocimiento del área de estudio. Este enfoque ayuda a mejorar la capacidad predictiva de los modelos al incorporar diferentes perspectivas y técnicas de clasificación, lo que permite obtener una visión más completa y robusta del paisaje. Además, al evitar la dependencia de un solo modelo, se reducen los riesgos de subestimar la complejidad del área y se maximiza la capacidad para capturar la heterogeneidad y las variaciones presentes en el entorno natural. En última instancia, la implementación de varios modelos y la validación rigurosa de su desempeño contribuyen a mejorar la precisión de las clasificaciones y a generar información más precisa y confiable para la gestión y conservación de los ecosistemas.

Los buenos resultados obtenidos en la clasificación de imágenes de teledetección representan un avance significativo para los propósitos del grupo de investigación. Estos resultados proporcionan una sólida base de datos sobre la composición del paisaje y la distribución de las coberturas en el área de estudio, lo que fortalece los análisis de conectividad ecológica realizados por el grupo. Al tener acceso a información detallada y precisa sobre las coberturas del suelo y su distribución, el grupo puede realizar análisis más rigurosos y fundamentados sobre la interacción de las especies y los procesos ecológicos en el paisaje.

IX. RECOMENDACIONES

Es fundamental comprender profundamente el contexto de aplicación y los datos disponibles, ya que cada necesidad particular requerirá de ajustes sobre la metodología descrita en este proyecto. Se recomienda realizar una exploración exhaustiva de los datos, definiendo correctamente la problemática, el área de interés, la plataforma de observación terrestre y el conjunto de imágenes que brinde el mayor detalle posible de la superficie y sus coberturas. Además, es importante identificar cuidadosamente las características relevantes en las imágenes satelitales (bandas) que serán utilizadas por el modelo para distinguir entre las diferentes clases de cobertura. Una vez seleccionadas estas características, se debe elegir el modelo de clasificación más adecuado para la aplicación, si bien en el proyecto se hizo uso del clasificador basado en `smileRandomForest`, existen otros modelos que pueden brindar un mejor ajuste a la necesidad particular. Durante el proceso de entrenamiento, es importante ajustar los parámetros del modelo de acuerdo con las características de los datos y a realizar una validación exhaustiva para evaluar su rendimiento. Es crucial realizar iteraciones en el proceso de desarrollo del modelo, incorporando mejoras según sea necesario y documentando cada paso del proceso para facilitar el seguimiento y la replicación. Finalmente, se anima a seguir los resultados y lecciones aprendidas que comparte la comunidad, esto con el fin de fomentar el aprendizaje colaborativo y la mejora continua en el campo de la clasificación de coberturas en imágenes satelitales.

REFERENCIAS

- [1] F. Sacristán Romero, “La Teledetección satelital y los sistemas de protección ambiental,” *Civilizar*, vol. 5, no. 9, p. 1, 2005.
- [2] SEP, “Espectro electromagnético,” *Gob.mx*. [Online]. Disponible en: <https://nuevaescuelamexicana.sep.gob.mx/detalle-ficha/4730/>.
- [3] “Teledetección óptica y por radar,” *Reefresilience.org*. [Online]. Disponible en: <https://reefresilience.org/es/management-strategies/remote-sensing-and-mapping/introduction-to-remote-sensing/optical-and-radar-remote-sensing/>.
- [4] A. Calle y P. Salvador, “Revisando el concepto de resolución en teledetección,” *Org.es*. [Online]. Disponible en: https://www.aet.org.es/revistas/revista37/Numero37_09.pdf.
- [5] L. García, Mauricio, J. Brondo, and M. Arbelo, *Satélites de teledetección para la gestión del territorio*. 2012.
- [6] “Landsat science,” *Landsat Science | A joint NASA/USGS Earth observation program*, 30-Nov-2021. [Online]. Disponible en: <https://landsat.gsfc.nasa.gov>.
- [7] “MODIS Web,” *Nasa.gov*. [Online]. Disponible en: <https://modis.gsfc.nasa.gov/about/design.php>.
- [8] “Explore Copernicus satellite missions,” *Sentinel Online*. [Online]. Disponible en: <https://sentinels.copernicus.eu/web/sentinel/home>.
- [9] “Constellation,” *Maxar.com*. [Online]. Disponible en: <https://www.maxar.com/maxar-intelligence/constellation>.
- [10] “SkySat,” *Planet.com*. [Online]. Disponible en: <https://developers.planet.com/docs/data/skysat/>.
- [11] “Teledetección – Edusat,” *Edu-sat.com*. [Online]. Disponible en: <https://www.edusat.com/teledeteccion/?lang=es>.
- [12] “NDBI,” *Arcgis.com*. [Online]. Disponible en: <https://pro.arcgis.com/es/pro-app/3.1/arcpy/image-analyst/ndbi.htm>.
- [13] C. A. Franco, H. H. Hamon, and D. A. Herrera, “Preprocesamiento y procesamiento de imágenes Sentinel 2 con Google Earth Engine.” Unpublished, 2019.
- [14] J. F. Rodrigo Herrero, “Armonización de datos de satélite mediante zonas homogéneas,” *Universidad de Valladolid*, 2021.
- [15] GRUPO GESTIÓN DEL RIESGO OFICINA DE CONTROL ESTRATÉGICO – CORNARE, “Evaluación y Zonificación de Riesgos por avenida torrencial, inundación y movimiento en masa y dimensionamiento de procesos erosivos en el municipio de El Carmen de Viboral,” 2012.