

AGROSAVIA

Corporación colombiana de investigación agropecuaria

Sensores Remotos: Imágenes Satelitales, Drones y Machine Learning Aplicado a Agricultura Digital.



AGROSAVIA

Corporación colombiana de investigación agropecuaria

ACADEMIA AGROSAVIA

CLAUDIA MILENA SERPA IMBETT, PhD

Posdoctorado MINCIENCIAS - AGROSAVIA C.I Turipaná – CERETÉ



CLAUDIA
MILENA
SERPA
IMBETT,
PhD

Página web:

Claudia Milena Serpa Imbett,
PhD

<https://cmsipage.netlify.app/>



CLAUDIA MILENA SERPA IMBETT, PhD



Acerca de Mí

Claudia Milena Serpa Imbett, PhD

Soy investigadora científica, PhD. Actualmente, realizo Posdoctorado en sistemas de Agricultura digital e IA para gestión agrícola y ganadera en AGROSAVIA. Consultora especializada en la aplicación de tecnologías ópticas avanzadas. Con más de 15 años de experiencia en el campo de la óptica, fotónica, y sensores remotos y proximales, he dedicado mi carrera a desarrollar soluciones innovadoras.

Mi formación académica incluye un Doctorado en Ingeniería de la Universidad Pontificia Bolivariana, sede Medellín, con una pasantía de investigación en la Universidad de Campinas (Brasil). He publicado más de 30 artículos en revistas indexadas y congresos científicos. Además, he liderado proyectos de investigación con financiación externa y participado activamente en el diseño de soluciones tecnológicas basadas en software, así como en procesos de patentamiento de tecnologías.



Recursos Descargables



Sensores Remotos

Guía completa sobre aplicaciones de sensores remotos en agricultura moderna.

[Descargar PDF →](#)



Óptica y Fotónica en Agro 4.0

Fundamentos físicos para la de implementación de sistemas ópticos en agricultura digital.

[Descargar PDF →](#)



Agricultura Digital

Curso introductorio sobre transformación digital en el sector agrícola.

[Acceder al Curso →](#)



Redacción de Proyectos

Pautas para elaboración de propuestas de investigación científica exitosas.

[Descargar Material →](#)



Redacción de Artículos Científicos

Metodología paso a paso para redacción y publicación de artículos científicos en revistas indexadas.

[Ver Recursos →](#)



Sensores de Fibra Óptica

Aplicaciones avanzadas de sensores de fibra óptica en monitoreo de sistemas eléctricos - Curso impartido a Siemens - Colombia.

[Descargar PDF →](#)

RECURSOS
DESCARGABLES



Docencia Universitaria y Formación Especializada



Trabajo de Grado UNISINU - Ing Eléctrica

Plataforma web desarrollada para el programa de Ingeniería Eléctrica de UNISINU, enfocada en proyectos de grado y recursos académicos especializados en el área eléctrica.

[Acceder a la Plataforma →](#)



Chatbot Elektra - Trabajo de Grado UNISINU

Asistente virtual inteligente especializado en ingeniería eléctrica, desarrollado como trabajo de grado para UNISINU. Proporciona información técnica y apoyo académico.

[Interactuar con Elektra →](#)



Repositorio de Curso Sensores Remotos y Machine Learning

Repositorio académico completo con materiales, ejercicios prácticos y proyectos del curso de sensores remotos aplicados con técnicas de machine learning.

[Explorar Repositorio →](#)

RECURSOS
DESCARGABLES

Explorando el repositorio del Curso de Teledetección

Ir al enlace:

[Teledetección - Curso | teledeteccion-curso](#)

<https://claumiseimbett1.github.io/teledeteccion-curso/>



Explorando el
repositorio
del Curso de
Teledetección



Teledetección: Imágenes Satelitales, Drones y Machine Learning Aplicado a Agricultura Digital

Transforma datos espaciales remotos en decisiones inteligentes 🌱

 Curso dictado en la Universidad de Magdalena para los programas de Maestría y Doctorado en Ingeniería y para AGROSAVIA - Colombia

Este repositorio contiene los materiales, ejemplos y recursos del curso especializado en **Teledetección (Sensores Remotos)** con énfasis en aplicaciones agrícolas y uso de inteligencia artificial.



Descripción

Curso de formación avanzada en teledetección óptica y radar, con énfasis en imágenes multiespectrales y algoritmos de machine learning. Integra radiometría de campo, preprocesamiento digital y clasificación supervisada para implementar soluciones reales en agricultura de precisión usando herramientas de software libre como QGIS, SNAP y Python.

Entidad organizadora: AGROSAVIA – Centro de Investigación Turipaná



Explorando el repositorio del Curso de Teledetección

Objetivos

Objetivo General

Formar participantes en fundamentos, técnicas y aplicaciones de teledetección mediante sensores remotos, con énfasis en plataformas satelitales y drones, procesamiento digital de imágenes y aprendizaje automático aplicado al monitoreo de variables biofísicas.

Objetivos Específicos

-  Explicar principios físicos de la teledetección y la interacción electromagnética
-  Identificar características técnicas de plataformas Sentinel, Landsat, MODIS y drones
-  Aplicar conceptos de resolución espacial, espectral, temporal y radiométrica
-  Realizar preprocesamiento de imágenes (correcciones radiométricas, atmosféricas, geométricas)
-  Comprender índices espectrales (NDVI, NDRE, SAVI) y su relación con cobertura vegetal
-  Aplicar técnicas de machine learning (SVM, Random Forest, XGBoost)
-  Diferenciar sensores pasivos (ópticos, térmicos, hiperspectrales) de activos (radar SAR, LIDAR)

Explorando el repositorio del Curso de Teledetección

Módulos del Curso (36 horas)

Módulo 1: Fundamentos de Teledetección (6 horas)

- Definición y alcance de la teledetección (óptica y radar)
- Tipos de sensores: pasivos y activos
- Plataformas: satélites, drones, aviones, sensores proximales
- Interacción de la radiación electromagnética con la materia
- Firmas espectrales y radiometría proximal

Módulo 2: Imágenes Pasivas (18 horas)

- Sensores ópticos multiespectrales e hiperespectrales
- Plataformas Sentinel-2, Landsat 8/9, MODIS, drones (DJI, Micasense)
- Índices espectrales: NDVI, NDRE, SAVI, NDWI
- Radiometría de campo con espectrómetros
- Procesamiento con QGIS, SNAP, Google Earth Engine, Python

Módulo 3: Imágenes Activas y Machine Learning (12 horas)

- Radar SAR: bandas L, C, X y polarización VV, VH, HV, HH
- LIDAR: principios y aplicaciones topográficas
- Algoritmos ML: SVM, Random Forest, XGBoost
- Clasificación supervisada y no supervisada
- Procesamiento con Google Earth Engine y Python

Explorando el repositorio del Curso de Teledetección

Estructura del Repositorio

```
Teledeteccion-Curso/
├── codigo/ # 🐍 Notebooks Python y scripts de análisis
│   ├── NDVI_Satellite.ipynb
│   ├── ClasificadorRF*.ipynb
│   ├── XGBoost*.ipynb
│   └── 13-Segmentación_Kmeans/
├── datasets/ # 🗄️ Datos satelitales y ejemplos
│   ├── NDVI_Sentinel2.tif
│   ├── VH.tif, VV.tif
│   └── Ejemplo_FirmasEspectrales/
├── QGIS_SNAP/ # 🗺️ Proyectos QGIS
├── documentos/ # 📄 Material teórico del curso
├── datasheet-drones/ # 🚁 Especificaciones técnicas drones
└── tutorial-y-aprendizaje/ # 📖 Material de apoyo y tutoriales
```


Explorando el repositorio del Curso de Teledetección

Tecnologías y Herramientas

Software Libre:

-  Python: rasterio, scikit-learn, geopandas, matplotlib
-  QGIS: Análisis geoespacial
-  SNAP: Procesamiento imágenes Sentinel
-  Google Earth Engine: Análisis en la nube
-  Google Colab: Ejecución de notebooks

Plataformas Satelitales:

-  Sentinel-1/2 (ESA)
-  Landsat 8/9 (NASA/USGS)
-  MODIS (NASA)

Drones Multiespectrales:

-  DJI Phantom 4 Multiespectral
-  DJI Mavic 3 Multiespectral
-  MicaSense RedEdge-MX

Público Objetivo

-  Investigadores y técnicos en proyectos agroambientales
-  Estudiantes y profesionales de ingeniería, agronomía, geografía, física, biología
-  Productores agrícolas interesados en monitoreo remoto
-  Público general que desee competencias básicas en teledetección

Requisitos Previos

-  Manejo básico de software informático
-  Deseable: conocimientos básicos de Python
-  Deseable: conocimientos de SIG (QGIS, SNAP, Google Earth Engine)

Explorando el repositorio del curso de teledetección

Público Objetivo

-  Investigadores y técnicos en proyectos agroambientales
-  Estudiantes y profesionales de ingeniería, agronomía, geografía, física, biología
-  Productores agrícolas interesados en monitoreo remoto
-  Público general que desee competencias básicas en teledetección

Requisitos Previos

-  Manejo básico de software informático
-  Deseable: conocimientos básicos de Python
-  Deseable: conocimientos de SIG (QGIS, SNAP, Google Earth Engine)

Instalación y Uso

1. Clona el repositorio:

```
git clone https://github.com/claumiseimbett1/teledeteccion-curso.git
```

2. Instala las dependencias de Python:

```
pip install numpy matplotlib rasterio scikit-learn geopandas
```

3. Abre los notebooks en Jupyter o Google Colab

4. Sigue las instrucciones de cada módulo

Instructora

Claudia Milena Serpa Imbett, PhD.

-  Posdoctoral MINCIENCIAS
-  Docente Universitaria UNISINU – Montería
-  [claumiseimbett1](#)

Pasos para clonar el repositorio

1. Abrir terminal/línea de comandos

Windows: Cmd, PowerShell o Git Bash

Mac/Linux: Terminal

2. Navegar a la carpeta donde quieres el proyecto:

En el bash o directamente en la carpeta con click izquierdo – Terminal.

cd Desktop

o la ruta donde quieras guardarlo

cd Documents/Proyectos

Pasos para clonar el repositorio

3. Clonar el repositorio

bash

git clone <https://github.com/claumiseimbett1/teledeteccion-curso.git>

4. Entrar al directorio clonado

bash

cd teledeteccion-curso

5. Verificar que se clonó correctamente

bash

ls

o en Windows:

dir

Pasos para clonar el repositorio

Comandos adicionales útiles:

Ver el estado del repositorio:

bash

git status

Ver las ramas disponibles:

bash

git branch -a

Actualizar con cambios remotos:

bash

git pull origin main

Para realizar la clonación del repositorio se debe tener una cuenta en GitHub

Abriendo una cuenta en Google COLAB

1. Tener una cuenta de Google

- Si ya tienes Gmail, YouTube o Google Drive, ya tienes cuenta
- Si no tienes: ve a accounts.google.com y crea una

2. Acceder a Google Colab

- Ve a colab.research.google.com
- O busca "Google Colab" en Google

3. Iniciar sesión

- Clic en "**Sign in**" (Iniciar sesión)
- Usa tu cuenta de Google
- Acepta los términos y condiciones

4. Crear tu primer notebook

- Clic en "**New notebook**" (Nuevo notebook)
- O selecciona un ejemplo de la galería

Abriendo una cuenta en Google COLAB

- **Conectar Google Drive (opcional pero útil):**

```
from google.colab import drive  
drive.mount('/content/drive')
```

- **Características importantes:**

Gratis: Incluye acceso a GPU y TPU limitado

Sin instalación: Funciona en el navegador

Colaborativo: Puedes compartir notebooks

Integración: Conecta con GitHub y Google Drive

- **Librerías típicas para teledetección**

```
!pip install rasterio earthpy folium geopandas
```

... y otras mas que estaremos usando en el curso.

Abriendo una cuenta en Google Earth Engine

1. Requisitos previos

Tener una cuenta de Google activa

Especificar el tipo de uso (académico, comercial, no comercial)

2. Solicitar acceso

Ve a earthengine.google.com

Clic en "**Sign Up**" o "**Get Started**"

Inicia sesión con tu cuenta de Google

3. Completar formulario de registro

Deberás proporcionar:

Información personal: Nombre, afiliación institucional

Tipo de proyecto: Académico, investigación, ONG, comercial

Descripción del uso: Para qué usarás Earth Engine

País y organización

Abriendo una cuenta en Google Earth Engine

- **4. Para uso académico/educativo**
- Selecciona "**Noncommercial**" o "**Academic**"
- Proporciona información de tu institución educativa
- Menciona que es para un curso de teledetección
- **5. Esperar aprobación**
- El proceso puede tardar **1-7 días**
- Google revisa manualmente las solicitudes
- Recibirás un email de confirmación
- **6. Acceder después de la aprobación**
- Ve a code.earthengine.google.com
- Inicia sesión con tu cuenta de Google
- Acepta los términos de servicio

Abriendo una cuenta en Google Earth Engine

Para estudiantes y profesores:

Tipo de uso: Academic Research/Education

Descripción: "Curso de teledetección y machine learning

para análisis de imágenes satelitales con fines educativos"

Institución: [Nombre de tu universidad/institución]

Información adicional útil:

- Menciona que es para aprendizaje/enseñanza
- Especifica el enfoque en agricultura/medio ambiente
- Incluye el nombre del curso o proyecto

Abriendo una cuenta en Google Earth Engine

Alternativas mientras esperas:

- **Google Earth Engine Apps**
- Puedes usar aplicaciones públicas sin cuenta
- Explora earthengine.google.com/apps

Tutoriales públicos

- Revisa la documentación en developers.google.com/earth-engine





Encuesta

MENTIMETER



INICIAMOS

CONTENIDO

1. Fundamentos de teledetección


2. Imágenes pasivas

3. Imágenes activas



MODULO 1

FUNDAMENTOS DE TELEDETECCIÓN



CONTENIDO

1. Fundamentos de teledetección

2. Imágenes pasivas

3. Imágenes activas



¿Qué es la teledetección?

Es un conjunto de técnicas y tecnologías que permiten **obtener información sobre la superficie terrestre u otros objetos a distancia**, sin necesidad de estar en contacto directo con ellos. Esto se logra mediante la **captación y análisis de la radiación electromagnética** que los objetos emiten, reflejan o absorben.



¿Cómo funciona?

A través de sensores, pueden estar ubicados en:

Plataformas como: Satélites, Drones, Aviones, Globos estratosféricos.

Los sensores registran diferentes tipos de radiación (visible, infrarroja, microondas, etc.)





El (los) sensor(es) captura(n) la radiación
“REFLEJADA, TRANSMITIDA O ABSORBIDA” de
manera remota, por lo que la TELEDECCIÓN
también se denomina “SENSADO REMOTO”



Tipos de TELEDETECCIÓN


- **PASIVA:** Captura la radiación natural, principalmente la luz solar **reflejada**. Ejemplo: imágenes satelitales ópticas (como las de Sentinel o Landsat).
- **ACTIVA:** El sensor emite su propia señal (como un radar o un LIDAR) y mide el “**tiempo**” rebote. Esto permite operar de noche y en condiciones de nubosidad.

Aplicaciones de la TELEDECCIÓN o SENSADO REMOTO

- **Agricultura de precisión:** monitoreo de cultivos, estrés hídrico, estimación de biomasa.
- **Silvicultura:** detección de deforestación, salud del bosque.
- **Gestión ambiental:** evaluación de desastres naturales, monitoreo de cuerpos de agua.
- **Geología:** detección de fallas, análisis de suelos y minerales.
- **Urbanismo:** crecimiento urbano, uso del suelo.
- **Cambio climático:** monitoreo de glaciares, temperatura de la superficie terrestre.

Conceptos básicos

- Sensor
- Plataforma
- Resolución



Sensor

Un **sensor** es el **dispositivo que capta la información** desde la distancia (sensor remote), midiendo la radiación electromagnética reflejada, emitida o absorbida por los objetos.



Sensor

- **Ópticos** (visible, infrarrojo cercano): como los portados por los satélites Sentinel-2 y drones
- **Térmicos**: detectan energía en el infrarrojo térmico (temperatura).
- **Radar (SAR)**: sensor activo que emite microondas y miden el tiempo de retorno (útil en condiciones de nubosidad o de noche).
- **LIDAR**: emite pulsos láser para medir distancias con gran precisión (usado en topografía y vegetación).



Plataforma

- Es el vehículo que transporta el sensor:
- Puede ser un dron, un satélite, un avión, globo estratosférico, etc.



Plataforma

Tipos de plataformas:

- **Satélites:** como Sentinel, Landsat, MODIS (alta cobertura, menor resolución temporal).
- **Aviones:** vuelos programados para estudios específicos (resolución intermedia).
- **Drones (UAVs):** permiten vuelos a baja altura y alta resolución espacial y temporal.
- **Globos estratosféricos:** permiten observaciones a gran altitud y son más económicos que los satélites

Resolución

Se refiere al **nivel de detalle** con el que se captan los datos.

Resolución

Tipo de resolución	¿Qué significa?	Ejemplo
Espacial	Tamaño mínimo de un objeto detectable (tamaño de píxel)	10 m, 30 m, 1 m...
Espectral	Separación entre longitudes de onda o bandas espectrales	RGB, infrarrojo, hiperespectral
Temporal	Frecuencia con la que se adquieren datos de un mismo lugar	Cada día, cada 5 días...
Radiométrica	Precisión en la medición de la radiación (niveles de gris o bits)	8 bits (256 niveles), 12 bits, etc.

Ejemplo de un sistema de teledetección o sensado remoto



Sensor: Cámara Multiespectral (captura en RGB (visible) + infrarrojo cercano + Infrarrojo de Borde (RedEdge)



Plataforma: Drone



Resolución espacial: 10 cm/píxel y hasta 2.3 cm/píxel volando a 50 m (altísima resolución)




Resolución temporal: según el plan de vuelo, la temporalidad la escoge el usuario.



Resolución espectral: 5 bandas (rojo (R, Red), verde (G, Green), azul (B, Blue), infrarrojo cercano (NIR, Near Infrared), Infrarrojo de borde (RE, RedEdge)

Ejemplo de un sistema de teledetección o sensor remoto

- Altura = 50 m.
- ¿Cuántos pixels hay en un marco si la resolución es de 2,3 cm/pixel?
- FOV es el Field of View o campo de vision que se refiere a la apertura angular del
- Tipo de sensor: multiespectral
- Plataforma es el dron.





Vemos applet del vuelo de un dron

Click en iniciar vuelo

[Simulador FOV Dron](#)

Ejemplo



Sensor: Cámara Multiespectral (captura en RGB (visible) + infrarrojo cercano + Infrarrojo de Borde (RedEdge)



Plataforma: Sentinel-2



Resolución espacial: 10 m/pixel.



Resolución temporal: cada 5 días en el trópico



Resolución espectral: 5 bandas (rojo (R, Red), verde (G, Green), azul (B, Blue), infrarrojo cercano (NIR, Near Infrared), Infrarrojo de borde (RE, RedEdge)

Ejemplo de un sistema de teledetección o sensado remoto

- Altura = 786 km de la superficie terrestre.
- FOV es el Field of View o campo de vision que se refiere a la apertura angular del sensor ¿ Cual es mayor: del satélite o del dron?
- Tipo de sensor: multiespectral
- Plataforma es el satélite



Características del Sentinel – 2.



Altitud: ~786 km



Órbita: Polar, heliosincrónica (pasa por el mismo punto a la misma hora solar local cada día)



Revisita: Cada 5 días (combinando Sentinel-2A y Sentinel-2B)



Resolución espacial:

10 m para bandas RGB y NIR

20 m para bandas Red Edge y SWIR

60 m para bandas de corrección atmosférica



Ancho de barrido (swath): ~290 km




Acceso: Gratuito a través de Copernicus Open Access Hub o Google Earth Engine.


Comparación entre plataformas dron (convencional) y satelital (Sentinel-2)

Tipo de resolución	Drone	Sentinel-2
Espacial	~10 cm/píxel	10 m/píxel
Espectral	5–10 bandas (dependiendo del sensor)	13 bandas (VIS, NIR, SWIR)
Temporal	Según planificación	Cada 5 días (óptimas sin nubes)
Radiométrica	10–14 bits (alta precisión)	12 bits

La Ionosfera

Interacción de la radiación electromagnética con la materia






PROPIEDADES DE LA LUZ

- Las propiedades de la luz son comprendidas por la **óptica** que es una rama de la física que estudia la **luz** y su comportamiento, así como sus interacciones con la materia.
- Se ocupa de fenómenos como la reflexión, la refracción, la dispersión y la difracción, entre otros.

PROPIEDADES DE LA LUZ


- *Existen dos enfoques principales en el estudio de la óptica:*
- **Óptica geométrica:** Se enfoca en la trayectoria rectilínea de la luz y los principios de reflexión y refracción. Aquí se explican cómo se forman las imágenes a través de lentes y espejos, como ocurre en cámaras o telescopios.



PROPIEDADES DE LA LUZ


- *Existen dos enfoques principales en el estudio de la óptica:*
- **2. Óptica física:** Estudia la luz como una onda, analizando fenómenos que no se pueden explicar solo con la óptica geométrica, como la interferencia y la difracción.

Young's Double-Slit Experiment



PROPIEDADES DE LA LUZ

- Las propiedades de la luz también son comprendidas a través de la **fotónica** es el campo de la ciencia y la tecnología que estudia la **generación, manipulación, transmisión y detección de fotones**, es decir, de partículas de luz.
- A diferencia de la electrónica, que usa electrones para procesar y transmitir información, la fotónica utiliza la luz (fotones) para realizar estas funciones.




PROPIEDADES DE LA LUZ

- Algunas áreas clave dentro de la fotónica son:
- **Generación de luz:** Incluye fuentes de luz como los láseres y los diodos emisores de luz (LEDs).




PROPIEDADES DE LA LUZ



- Algunas áreas clave dentro de la fotónica son:
- **2.Transmisión y control de la luz:** Se refiere a cómo la luz se puede guiar a través de fibras ópticas o manipular usando dispositivos como moduladores ópticos.

PROPIEDADES DE LA LUZ

- Algunas áreas clave dentro de la fotónica son:
- **3. Detección de luz:** Incluye tecnologías como los fotodetectores y sensores ópticos.



PROPIEDADES DE LA LUZ

- Algunas áreas clave dentro de la fotónica son:

4. Procesamiento óptico: Involucra la transmisión de datos y procesamiento de información a través de luz, lo que tiene aplicaciones en telecomunicaciones, tecnologías de la información y teledetección.



PROPIEDADES DE LA LUZ



La **óptica** tiene aplicaciones en el desarrollo de instrumentos como gafas y telescopios.



La **fotónica** tiene aplicaciones relacionadas con las **telecomunicaciones** (por ejemplo, a través de la fibra óptica), la **medicina** (láseres en cirugía), la **fabricación de chips** y la **fabricación de** cámaras y sistemas de detección. Además, se considera una tecnología clave en el desarrollo de la computación cuántica y en sistemas de energía más eficientes (paneles solares)



La **biofotónica** investiga la interacción de la luz con sistemas biológicos, lo que permite tanto el análisis y diagnóstico como la intervención en organismos vivos, y esta directamente relacionada con la teledetección y el sensado remoto.


Espectro electromagnético y firmas espectrales




Espectro electromagnético y firmas espectrales

- *Partes de una onda*
- $\lambda = c/f$
- λ es la longitud de onda (wavelength)
- c es la velocidad de la luz $3 \times 10^8 \text{ m/s}$
- f = frecuencia en Hz (Hertz) o s^{-1}

Parts of a wave



ELECTROMAGNETIC SPECTRUM





Espectro
electromagnético y
firmas espectrales

Espectro electromagnético y firmas espectrales

Espectro óptico



Bandas del espectro óptico: frecuencia del orden de 10^{12} Hz (Terahertz) y longitudes de onda de cientos de nanómetros



Espectro electromagnético y firmas espectrales

Espectro óptico


Bandas del espectro óptico: frecuencia del orden de 10^{12} Hz (Terahertz) y longitudes de onda de cientos de nanómetros



Espectro electromagnético y firmas espectrales


- **BANDAS
RADIOFRECUENCIA**

- frecuencia del orden de 10^9 Hz (Gigahertz) y longitudes de onda de m y cm




Espectro electromagnético y firmas espectrales

- 1.1. Bandas de interés y filtros ópticos
 - Banda óptica (300 nm – 2000 nm) que incluye el espectro visible y el infrarojo cercano (NIR, Near Infrared hasta 1100 nm) y el infrarojo (desde 1100 nm hasta 2000 nm).
 - Espectro de radiofrecuencias (1-10 GHz).





Espectro electromagnético y firmas espectrales

Espectro solar




Filtro óptico



El cuerpo negro


- Esta comparación demuestra cómo la física teórica del cuerpo negro se aplica exitosamente a objetos reales como las estrellas.
- Representa un cuerpo negro ideal a 5800 K, que es aproximadamente la temperatura de la superficie del Sol



El cuerpo negro

Radiación de Cuerpo Negro (curva azul)


- Sigue la **Ley de Planck**, que describe cómo un objeto perfecto absorbe y emite radiación electromagnética.
- El pico está alrededor de 500 nm (luz verde-azul), siguiendo la **Ley de Wien**



El cuerpo negro


Radiación Solar Extraterrestre (curva naranja)

- Es la radiación solar real medida fuera de la atmósfera terrestre
- Se aproxima mucho a la curva de cuerpo negro, pero con algunas diferencias importantes:
 - **Líneas de absorción:** Las pequeñas "muecas" en la curva se deben a que ciertos elementos en la atmósfera solar absorben longitudes de onda específicas
 - **Forma ligeramente diferente:** El Sol no es un cuerpo negro perfecto



El cuerpo negro



- **Espectro visible:** La banda coloreada muestra que la mayor parte de la energía solar está en el rango visible (400-700 nm), donde nuestros ojos evolucionaron para ser sensibles
- **Distribución de energía:** Ambas curvas muestran que hay radiación en todo el espectro electromagnético, pero concentrada en el visible e infrarrojo cercano
- **Temperatura estelar:** La forma de la curva nos permite determinar la temperatura del Sol usando las leyes de radiación de cuerpo negro



Espectro electromagnético y firmas espectrales

Fotodiodos de Silicio 300 – 1000 nm.

Fotodiodo de silicio - S series -
HAMAMATSU - de infrarrojos / UV
(directindustry.es)



Espectro electromagnético y firmas espectrales

- 1.4. Ciencia de los materiales de detectores ópticos e IR
- Detectores ópticos son los elementos constitutivos de cámaras digitales.
- Matriz de una cámara digital - Sensores fotodiodo de luz fabricados en silicio para conformación de matrix de píxeles RGB (rojo (Red) verde(Green) azul (BLUE). Matriz de pixeles (Photosite matrix array).



Espectro electromagnético y firmas espectrales

Ciencia de los materiales de detectores ópticos e IR


Tipos de cámaras digitales

- Sensores CCD (Coupling Charge Device).
- Sensor CMOS (Complementary Metallic Oxide Semiconductor)
- El sensor DGO (salida de ganancia doble)
- El sensor SPAD (de fotodiodos de avalancha para entornos oscuros)

[Explicación de los sensores de cámara - Canon Spain](#)


1. Espectro electromagnético – *bandas ópticas*

Camera Sensor




Espectro electromagnético y firmas espectrales

- Configuración de sensores radar (RADAR)
- Proviene del inglés "*Radio Detection and Ranging*", que significa "*Detección y medición de distancias por radio*". A través de la emisión de ondas de radio y la recepción de las señales reflejadas, los radares pueden determinar la distancia, velocidad, dirección y altitud de los objetos.



Espectro electromagnético y firmas espectrales


- Configuración de sensores radar (RADAR)
- Son ondas de radio o microondas, que son parte del espectro electromagnético con frecuencias que van desde 3 kHz hasta 300 GHz, se propagan al igual que en el dominio óptico a la velocidad de la luz (3×10^8)
- Las bandas de frecuencia más comunes en radares son las bandas L, S, C, X, K y Ka



Espectro electromagnético y firmas espectrales

1.5. Configuración de sensores radar (RADAR):

- Bandas de RADAR:
- Banda L (1-2 GHz): Detección de largo alcance y penetración en obstáculos.
- Banda S (2-4 GHz): Radares meteorológicos y de tráfico aéreo.
- Banda C (4-8 GHz): Radares meteorológicos y de comunicaciones.
- Banda X (8-12 GHz): Alta resolución, utilizada en radares de control de tráfico aéreo y radares de imágenes.
- Banda K (18-27 GHz): Radares de corto alcance, como en los automóviles




Espectro electromagnético y firmas espectrales

Configuración de sensores radar
(RADAR):

banda	frecuencia	Longitud de onda	Resolución
P	400 MHz	75 cm	2 cm
L	1,2 GHz	25 cm	6 cm
C	5,5 GHz	5,5 cm	18 cm

Aplicación en Agro




Espectro electromagnético y firmas espectrales

1.5. Configuración de sensores radar (RADAR):

- Banda L (1-2 GHz): En Agricultura alcanza la camada superior de la vegetación y el suelo.
- Banda C (4-8 GHz): Mide el volumen de la vegetación (biomasa) y la camada superior del suelo.
- Banda P (300 – 900 MHz): Penetra el suelo con y sin vegetación.

[Radar embarcado em drone \(RD\) \(radaz.com.br\)](http://radaz.com.br)

Aplicación en Agro




¿Cómo la selección del dominio en el espectro electromagnético (óptico o radar) permite caracterizar las aplicaciones directas de tecnologías de medición?

ÓPTICO




RADAR



Espectro electromagnético y firmas espectrales

Configuración de sensores radar
(RADAR)

Radar embarcado em drone
(radaz.com.br)



Espectro electromagnético y firmas espectrales

Radiometría y fotometría

- Radiometría: mide la radiación electromagnética en términos de su energía independiente de su longitud de onda. Emplea técnicas y conceptos para cuantificar la cantidad de energía en forma de radiación que emite, transmite o refleja una fuente.
- Fotometría: se encarga de medir la luz visible en términos de su percepción por el ojo humano. A diferencia de la radiometría, que mide todas las formas de radiación electromagnética, la fotometría se enfoca en las propiedades de la luz dentro del espectro visible (aproximadamente entre 380 y 750 nanómetros), que es la porción del espectro electromagnético que puede ser vista por el ser humano

¿Qué es la radiometría?

La **radiometría** es la rama de la física que se encarga de **medir la energía de la radiación electromagnética**, en términos de **cantidad absoluta de energía** (sin importar su efecto visual, térmico o biológico). Es fundamental en campos como la **teledetección**, la **astronomía**, la **fotometría**, y la **calibración de sensores**.

En sensores remotos, la **radiometría** permite medir la **cantidad de energía reflejada o emitida por una superficie terrestre**, lo cual se traduce en **valores digitales (DN)** en las imágenes satelitales.

Ejemplo:

Un sensor multiespectral de Sentinel-2 mide cuánta energía refleja una planta en la banda del infrarrojo cercano (NIR). Esto se relaciona con su contenido de agua o vigor fotosintético. Estas tienen unas unidades específicas de las medidas absolutas de energía radiante en cada banda

Espectro electromagnético y firmas espectrales

Unidades radiométricas:

- ✓ *Potencia radiante: energía electromagnética emitida, reflejada o transmitida por una fuente en todas las direcciones por unidad de tiempo (unidad= [W], watt)*

1 W = 1 joule/segundo [J/s]

- ✓ *Irradiancia: mide la cantidad de energía radiante que incide sobre una superficie por unidad de área.*

1 W/m² es la potencia radiante por metro cuadrado.

Espectro
electromagnético y
firmas espectrales

Unidades radiométricas.

✓ Intensidad radiante: *mide la cantidad de energía radiante emitida por una fuente en una dirección específica dentro de un ángulo sólido (estereorradián).*

1 W/sr es la potencia radiada por unidad de ángulo sólido (estereoradian).

1. Espectro electromagnético – *bandas ópticas*

Unidades radiométricas:

- ✓ **Radiancia:** *mide la potencia radiante emitida o reflejada por una superficie en una dirección dada por unidad de área y por unidad de ángulo sólido.*

1 W/m²·sr es la radiación emitida desde una superficie en una dirección específica.

- ✓ **Energía radiante:** *cantidad total de energía emitida o recibida en forma de radiación electromagnética.*

1 joule [J] es la unidad de energía que corresponde a 1 vatio por segundo (1 J = 1 W·s).

Principales magnitudes radiométricas

Magnitud	Símbolo	Unidad SI	¿Qué mide?
Potencia radiante	Φ	Watt (W)	Energía por segundo (flujo total)
Irradiancia	E	W/m ²	Energía recibida por unidad de área
Radiancia	L	W/m ² ·sr	Energía por unidad de área, por ángulo sólido
Energía radiante	Q	Joule (J)	Cantidad total de energía emitida, recibida o transferida

Importancia de las magnitudes radiométricas en teledetección.



Calibrar sensores ópticos (satélites, cámaras, drones)



Comparar imágenes tomadas en diferentes fechas o sensores



Estimar propiedades biofísicas de la vegetación, como:



Contenido de clorofila



Índices de vegetación (NDVI, SAVI)



Biomasa



Temperatura superficial (radiometría térmica)

Resolución radiométrica

- Es la **capacidad de un sensor para discriminar pequeñas diferencias en la intensidad de la radiación electromagnética**. Se expresa en **bits**.
- **DN (Digital Number)**: Valor numérico que representa la cantidad de radiación registrada por el sensor en una banda específica.
- Con **mayor resolución radiométrica**, el sensor puede **detectar sutiles diferencias de reflectancia** en la vegetación.

Resolución radiométrica

Resolución	Niveles digitales (DN)	Precisión
8 bits	256 niveles (0–255)	Baja
10 bits	1.024 niveles (0–1023)	Media
12 bits	4.096 niveles	Alta
16 bits	65.536 niveles	Muy alta

Resolución radiométrica de sensores en plataformas comerciales de teledetección

Sensor	Resolución radiométrica	Resolución espacial(/pix)
Sentinel-2	12 bits	10 m (bandas clave)
Landsat 8/9 OLI	12 bits	30 m
Drones	10–12 bits	5–20 cm
(Micasense y DJI)	14 bits	2.3 cm
MODIS	12 bits	250–1000 m

Espectro electromagnético y firmas espectrales

Unidades fotométricas

- ✓ **Flujo luminoso:** mide la cantidad total de luz emitida por una fuente en todas las direcciones. Es la medida de la potencia de luz visible que percibe el ojo humano.

1 lumen = 1 candela * 1 estereorradián.

- ✓ **Intensidad luminosa:** mide la cantidad de luz que una fuente emite en una dirección particular dentro de un ángulo sólido. Es la cantidad de flujo luminoso por unidad de ángulo sólido.

1 candela = 1 lumen * estereorradián.

- ✓ **Iluminancia:** mide la cantidad de luz que incide sobre una superficie. Es el flujo luminoso por unidad de área.

1 lux = 1 lumen/m².

1. Espectro electromagnético – *bandas ópticas*

Unidades fotométricas

- ✓ **Luminancia - Candela por metro cuadrado (cd/m^2):** La luminancia mide el brillo percibido de una superficie que emite o refleja luz. Tiene en cuenta la intensidad luminosa y el área desde la cual se emite la luz.

1 candela/ m^2 es la cantidad de candelas emitidas por unidad de área en una dirección dada.

- ✓ **La eficacia luminosa:** mide la eficiencia con la que una fuente de luz convierte energía eléctrica en luz visible.


1 lumen * watt = Flujo luminoso (lm) / Potencia consumida (W).

Resumen de magnitudes fotométricas

Magnitud	Símbolo	Unidad SI	¿Qué mide?
Flujo luminoso	Φ_v	lumen (lm)	Cantidad total de luz visible emitida
Intensidad luminosa	I_v	candela (cd)	Luz emitida en una dirección
Iluminancia	E_v	lux ($\text{lx} = \text{lm}/\text{m}^2$)	Luz que incide sobre una superficie
Luminancia	L_v	cd/m^2	Luz reflejada o emitida por una superficie en una dirección dada

Importancia de la fotometría


- La fotometría se basa en la **curva de luminosidad fotópica**, que representa la respuesta del ojo humano a diferentes longitudes de onda, con un pico en los **555 nm (verde)**.
- Evaluación de **iluminación artificial para crecimiento vegetal**
- Control de **ambientes indoor o bajo invernadero**
- Comparaciones de intensidad luminosa en sistemas agrovoltaicos o silvopastoriles con sombra



¿Qué es la radiometría de campo y su uso en teledetección?

La **radiometría de campo** en teledetección es una herramienta clave para validar, calibrar y entrenar modelos predictivos con sensores remotos:

- Cámaras multiespectrales en satélites o drones (matriz de píxeles 2D)
- Sensor multiespectral de diferentes bandas (pixel 1D)
- Espectrómetros “portátiles” (pixel 1D o matriz de pixel sensible a alrededor 1000 longitudes de onda). *Nota aclaratoria: “espectrómetros portátiles no son sensores remotos, son sensores proximales, y se convierten en remotos cuando son portados por plataformas”.*
- *¿Se podría a través de sensores multiespectrales estimar el espectro de un objeto?. Radiómetro multiespectral.*



¿Qué es la radiometría de campo y su uso en teledetección?

Es la medición **in situ** de la **energía electromagnética reflejada o emitida** por una superficie (como un cultivo o pasto) mediante **instrumentos especializados**, como espectrómetros portátiles o radiómetros multispectrales.

Estas mediciones:

- Se hacen sobre el terreno (parcelas, paddocks o lotes)
- Se registran en condiciones controladas (ángulo solar, nubes, humedad)
- Se usan como **referencia terrestre, es decir los valores de dicha energía en la superficie sensada en términos de unidades radiométricas.**

¿Para que se utiliza la radiometría en campo?

La radiometría de campo se utiliza para:

1. **Validar imágenes satelitales o de drones**
2. **Calibrar sensores remotos (corrección atmosférica, geométrica, radiométrica)**
3. **Extraer la firma espectral de cultivos o coberturas específicas**
4. **Entrenar modelos de ML** con variables biofísicas reales (ej. biomasa, humedad, clorofila)



Comparación de dos plataformas radiométricas

Característica	Satélites (ej. Sentinel-2)	Drones (ej. MicaSense, Parrot Sequoia)
Resolución espacial	10–30 m	5–20 cm
Bandas espectrales	Discretas (4–13 bandas)	Discretas (4–6 bandas típicamente)
Ventaja	Cobertura amplia y frecuente	Alta resolución y flexibilidad temporal
Limitación	No tan preciso sin calibración Requiere paneles de calibración	

Característica de un “sensor proximal”, espectrómetro portátil

Característica

Rango espectral

Resolución espectral

Qué mide

Relación con sensores
remotos

Detalle

Visible hasta SWIR (ej. 350–
2500 nm)


Alta (1–10 nm)

Reflectancia espectral
continua por superficie
vegetal

Sirve como “verdad de
campo” para calibrar sensores
multiespectrales o
hiperespectrales

¿Qué es la corrección radiométrica?

La **corrección radiométrica** es un proceso fundamental en teledetección que busca eliminar o minimizar **errores o distorsiones** en los datos registrados por sensores remotos (drones, satélites o cámaras portátiles) relacionados con la **cantidad de energía electromagnética** medida.





Importancia de la radiometría y su relación con las medidas de sensores remotos

¿Qué mide un sensor remoto?

Un sensor no mide directamente la **reflectancia** de la vegetación, sino la **radiancia** que llega al sensor ($1 \text{ W/m}^2 \cdot \text{sr}$), la cual está afectada por:

- 🌫️ **Condiciones atmosféricas** (nubes, vapor de agua, aerosoles)
- ☀️ **Ángulo solar y hora del día**
- 🛰️ **Sensibilidad del sensor**
- 🌊 **Reflejos del suelo u objetos cercanos**
- 💡 **Variación en la iluminación (sol/sombra)**

¿Para qué sirve la corrección radiométrica?



Convertir los datos en **valores comparables y estandarizados**.



Obtener **reflectancia de superficie real**, que puede usarse para:



Calcular índices de vegetación como **NDVI, NDRE**



Comparar diferentes fechas, sensores o zonas



Entrenar modelos de predicción de variables biofísicas

Tipos de corrección radiométrica

Tipo de corrección



Corrección instrumental



Corrección atmosférica



Calibración con panel blanco



Conversión DN → Reflectancia

Aplicación

Ajusta errores del sensor, como líneas espectrales, ruido o sensibilidad


Elimina efectos de la atmósfera (ej. con modelos como Sen2Cor, 6S)

En campo con cámaras multispectrales o espectrómetros

Transforma números digitales (DN) a valores de reflectancia ($\text{W/m}^2/\text{sr}/\mu\text{m}$ (radiancia, irradiancia o radiancia espectral) a reflectancia)

Ejemplo de calibraciones radiométricas.

- Para plataforma dron:
 1. Colocas un panel de calibración antes y después del vuelo (blanco con reflectancia conocida).
 2. El software usa esa información para corregir las imágenes.
 3. Los valores de las bandas (Rojo, NIR, etc.) ahora representan reflectancia de la vegetación, no solo "valores crudos" afectados por luz o sombras.
- Para plataforma satelital:
 1. Las imágenes de nivel L1C de Sentinel contienen radiancia sin corregir (afectada por atmósfera).
 2. Las de nivel L2A ya están corregidas atmosféricamente y son ideales para trabajar con índices de vegetación o ML.



Importancia de la radiometría en campo en el contexto de la teledetección

- La radiometría de campo es el puente fundamental entre el mundo físico real y los datos obtenidos desde sensores remotos. Sin ella, las imágenes satelitales o de drones pueden ser **inexactas o poco comparables** entre fechas o sensores.
- Es fundamental la corrección radiométrica es el proceso que convierte los datos brutos de los sensores remotos en información útil, precisa y comparable, eliminando efectos externos como iluminación, sensor o atmósfera.
- A partir de la corrección radiométrica se pueden obtener correctamente los índices de vegetación.






Espectro electromagnético y firmas espectrales

Las ondas electromagnéticas


Espectro electromagnético y firmas espectrales



2.1. REFLEXIÓN,
TRANSMISIÓN Y
ABSORCIÓN



2.2. POLARIZACIÓN




2.3. LONGITUD DE
PENETRACIÓN DE ONDAS
ELECTROMAGNÉTICAS



2.4. MATERIALES
LAMBERTIANOS


Electromagnetic Waves

Espectro
electromagnético y
firmas espectrales




Espectro electromagnético y firmas espectrales

- Reflexión, Transmisión y Absorción




Espectro electromagnético y firmas espectrales

- Reflexión, Transmisión y Absorción




Espectro electromagnético y firmas espectrales

- Reflexión, Transmisión y Absorción




Espectro electromagnético y firmas espectrales

- Reflexión, Transmisión y Absorción
- **Objeto Negro:** Absorción
- **Objeto Blanco:** Reflexión
- **Objeto Rojo:** Refleja Rojo y absorbe el resto de longitudes de onda
- **Objeto Verde:** Refleja Verde y absorbe el resto de longitudes de onda.





Espectro electromagnético y firmas espectrales

- Reflexión, Transmisión y Absorción




Continuous Spectrum



Espectro electromagnético y firmas espectrales

Espectro electromagnético y firmas espectrales

Polarización



Espectro electromagnético y firmas espectrales


Longitud de penetración de ondas electromagnética:

La longitud de penetración de una onda electromagnética, también conocida como profundidad de penetración o profundidad de skin (skin depth en inglés), es la distancia a la que la amplitud de una onda electromagnética decrece significativamente cuando se propaga a través de un material conductor o absorbente. Esta profundidad depende de las propiedades del material y la frecuencia de la onda.

$$\delta = \frac{1}{\sqrt{\pi f \mu \sigma}}$$

- δ = Profundidad de penetración o longitud de penetración (en metros).
- f = Frecuencia de la onda electromagnética (en Hz).
- μ = Permeabilidad magnética del material (en H/m o henrios por metro).
- σ = Conductividad eléctrica del material (en S/m o siemens por metro).

2. Conceptos de propagación de ondas electromagnéticas. *Caso particular la óptica*




Espectro electromagnético y firmas espectrales

ÓPTICO



RADAR



Espectro electromagnético y firmas espectrales

- Materiales Lambertianos
- Un material lambertiano es un tipo de superficie ideal que refleja la luz de manera difusa siguiendo la Ley de Lambert. Esta ley establece que la intensidad luminosa reflejada desde una superficie difusa es independiente del ángulo de observación, lo que significa que la superficie parece tener el mismo brillo cuando se ve desde cualquier ángulo.
- Un material lambertiano, como el yeso blanco o el papel mate, tiene un brillo uniforme desde cualquier punto de vista. Esto se debe a que la luz es dispersada de manera homogénea, haciendo que no se produzcan brillos ni reflejos especulares.
- Los materiales lambertianos se emplean en estudios de iluminación para **calibrar fuentes de luz** y medir la reflectividad de superficies. Un reflector lambertiano es útil para **dispersar la luz de manera uniforme** en un ambiente controlado.






Figure 4.3 – Lambertian surface.

Espectro electromagnético y firmas espectrales

- 2.4. Materiales Lambertianos
 - Superficie especular: (no Lambertiana):
 - Es un tipo de superficie que refleja la luz de manera **coherente** y **direccional**, creando un reflejo claro y nítido, similar a un espejo. las superficies especulares reflejan la luz en un solo ángulo, lo que resulta en una imagen reflejada más definida.
 - Superficies difusas:
 - dispersan la luz en múltiples direcciones aleatorias.



Espectro electromagnético y firmas espectrales

Firmas espectrales – propiedades
espectrales de la vegetación

Espectro electromagnético y firmas espectrales



3.1. Biofotónica



3.2. Firma espectral

3. Propiedades espectrales de la vegetación

La **biofotónica** investiga la interacción de la luz con sistemas biológicos, lo que permite tanto el análisis y diagnóstico como la intervención en organismos vivos.

Tópicos

- ✓ Definición de firma espectral
- ✓ Explicar cómo las firmas espectrales difieren para diferentes objetos biológicos o no.
- ✓ Cómo se distinguen los objetos: vegetación, agua, suelo, minerales, rocas según su firma espectral
- ✓ Identificar y explicar las firmas por inspección


Espectro electromagnético y firmas espectrales

3.2. Firma(s) espectral(es)

- ✓ Las firmas espectrales son la combinación de la radiación electromagnética reflejada, absorbida y transmitida o emitida por objetos en distintas longitudes de onda, que pueden identificar de forma única un objeto.
- ✓ Cuando se representa gráficamente la cantidad de radiación electromagnética (normalmente la **intensidad de la radiación reflejada** o **reflectancia en porcentaje**) procedente del material en un rango de longitudes de onda, los puntos conectados sucesivamente producen una curva que se conoce como firma espectral del material o, en otras palabras, curva de respuesta espectral.
- ✓ Son importantes para la interpretación de imágenes de teledetección.

Espectro electromagnético y firmas espectrales

- Firma(s) espectral(es)
- Firmas espectrales de materiales comunes de la Tierra en las bandas NIR (infrarrojo cercano) y SWIR (región infrarroja de onda corta). (tomado de www.rsac1.co.uk/rs.html)



Espectro electromagnético y firmas espectrales

- Firma(s) espectral(es)
- Firma espectral típica de la vegetación (Tomado de Hoffer, R.M. 1978)




Fig. 3.2: Typical spectral signature of green vegetation (source: Hoffer, R.M., 1978)

Espectro electromagnético y firmas espectrales

Firmas Espectrales

- ✓ La vegetación se ve verde (pico de reflexión en el verde 560 nm relacionado con el pigmento de clorofila en las hojas de las plantas).
- ✓ La presencia del pigmento clorofila da como resultado una firma espectral única de la vegetación que nos permite distinguirla fácilmente de otros tipos de características de la cubierta terrestre (no vivas) en una imagen óptica.
- ✓ La reflectancia de la vegetación es baja en las regiones azul y roja del espectro EM, debido a la absorción de longitudes de onda azul y roja responsables de la fotosíntesis.
- ✓ En la región del infrarrojo cercano (NIR), la reflectancia es mucho mayor que en la banda visible debido a la estructura celular de las hojas, que se comportan como reflectores difusos. Por lo tanto, la vegetación puede identificarse fácilmente en la región NIR del espectro.
- ✓ ¿Qué pasa si las hojas se ven amarillas o rojizas?. Reflejan más rojo y menos verde.

Espectro electromagnético y firmas espectrales

- Ejemplo de firmas espectrales de vegetación sana, estresada y severamente estresada (fuente: http://rst.gsfc.nasa.gov/Sect3/Sect3_1.html)




Fig. 3.3: Example of spectral signatures of healthy, stressed and severely stressed vegetations (source: http://rst.gsfc.nasa.gov/Sect3/Sect3_1.html)


Espectro electromagnético y firmas espectrales

Arboles deciduos (a) y tipo aguja(b)

Firma espectral - dependencia con la forma de la vegetación. Arboles tipo deciduos de hoja ancha (a) y coníferos de hoja tipo aguja (b). (Lillesand et.al 2007)



Fig. 3.4: (a) Deciduous tree - Maple; (b) Coniferous tree – Pine
(source: <http://theindoorbonsaitree.com>)



ig. 3.5: Generalised spectral reflectance envelopes for deciduous (broad-leaved) and coniferous (needle-bearing) trees. Each tree type has a range of values at any wavelength (source: Lillesand et. al, 2007)


Espectro electromagnético y firmas espectrales

Firmas Espectrales

- ✓ **Región visible (400-700 nm):** baja reflectancia, alta absorción y transmitancia mínima. El control fundamental de las interacciones energía-materia con la vegetación en esta parte del espectro es la pigmentación de la planta. Parámetros característicos son las reflectancias en el rojo (R – 630 nm), verde (G – 560 nm), y azul (B – 450 nm).
- ✓ **Región NIR (700-1350 nm):** alta reflectancia y transmitancia, muy baja absorción. El control físico son las estructuras internas de las hojas y su forma física. Parámetros característicos son la reflectancia en el “borde rojo” (RedEdge – 720-780) y la reflectancia en el resto de las longitudes de onda cuyo valor el cuasi-constante.
- ✓ **Infrarrojo medio (MIR) (1350-2500 nm):** a medida que aumenta la longitud de onda, tanto la reflectancia como la transmitancia generalmente disminuyen de media a baja, mientras que la absorción aumenta de baja a alta. El control físico primario en estas longitudes de onda del infrarrojo medio (SWIR) para la vegetación es el contenido de agua in vivo.


Espectro electromagnético y firmas espectrales

- Partición de la reflectancia espectral de la vegetación en las regiones visible, NIR y MIR del espectro EM (modificado desde www.cps-amu.org/sf/notes/m1r-1-8.htm)




Espectro electromagnético y firmas espectrales

- Variación de las características de reflectancia espectral de la vegetación según el contenido de humedad de las hojas (modificado de www.cps-amu.org/sf/notes/m1r-1-8.htm)




Espectro electromagnético y firmas espectrales

- Reflectancia de superficies de suelo desnudo. A) mínimamente alterada, B) con predominio de materia orgánica y C) con predominio de hierro (modificado de Stoner y Baumgardner, 1981)



Espectro electromagnético y firmas espectrales

- Características de reflectancia espectral de aguas profundas y claras (modificado de www.cpsamu.org/sf/notes/m1r-1-8.htm)



Espectro electromagnético y firmas espectrales

El Origen del índice de vegetación y su relación con la reflectancia, y las firmas espectrales.

- ✓ Una forma de distinguir suelo de vegetación
- ✓ los suelos tienden a tener aproximadamente la misma reflectancia en las dos bandas (VIS: visible y NIR: infrarrojo cercano),
- ✓ En la vegetación la reflectancia de la banda visible es baja para la radiación ultravioleta y la reflectancia del infrarrojo cercano es alta.
- ✓ Un índice de vegetación define una relación entre la energía reflejada visible de la energía reflejada del infrarrojo; o de manera general hoy en día los índices de vegetación son “formulas” que buscan discriminar con alto contraste la vegetación y otros elementos

Plataformas

Satelitales (Sentinel, Landsat, MODIS, etc.) y aéreas
(drones, aviones)



Plataformas

Satelitales



Plataformas satelitales

Es el **soporte físico** que lleva un sensor remoto (óptico, térmico, radar, etc.) en órbita.

El sensor es el que recolecta datos sobre la superficie terrestre, y la plataforma le proporciona:

- Energía (paneles solares)
- Posicionamiento y navegación (GPS, giroscopios)
- Comunicaciones (antenas para enviar datos a estaciones en tierra)

Tipos de plataformas satelitales

Tipo de órbita	Características principales	Ejemplos de satélites
Heliosíncrona (LEO)	Órbita baja (~700–900 km). Pasa sobre el mismo punto a la misma hora solar.	Sentinel-2, Landsat, MODIS
Geoestacionaria (GEO)	Altura de ~36.000 km. Siempre observa el mismo punto de la Tierra.	GOES, Meteosat
Altas órbitas (MEO)	Más usada en navegación (ej. GPS) que en teledetección	GPS, Galileo (no óptimos para imágenes)

Ejemplos de diferentes plataformas satelitales, características y aplicaciones.

Satélite	Plataforma/Agencia	Sensor principal	Resolución espacial	Frecuencia	Aplicaciones principales
Sentinel-2	ESA / Copernicus	MSI (multispectral Instrument)	10–60 m	5 días	Agricultura, vegetación, agua, suelos. 13 bandas (visible, NIR y SWIR)
Landsat-8/9	NASA / USGS	OLI (Operational Land Imager), TIRS (Thermal InfraRed Sensor)	15–100 m	16 días	Uso del suelo, monitoreo ambiental. 11 bandas (dos son térmicas)
MODIS	NASA	MODIS (36 bandas)	250–1000 m	Diario	Clima, biomasa global, incendios
PlanetScope	Planet Labs (privado)	8 bandas RGB+RedEdge+NIR	3–5 m	Diario	Agricultura, detección de cambios
SPOT 6/7	Airbus	Multispectral	1.5–6 m	Variable	Urbanismo, mapas de detalle
WorldView-3	Maxar (privado)	Multispectral + SWIR	0.31–1.24 m	Variable	Alta precisión urbana, minería, agricultura

Sentinel-2

Satélite de observación de la Tierra que forma parte del programa Copernicus de la Agencia Espacial Europea (ESA), diseñado para monitorear la superficie terrestre de forma regular y gratuita.

Es una **misión compuesta por dos satélites gemelos**:

- **Sentinel-2A** (lanzado en 2015)
- **Sentinel-2B** (lanzado en 2017)

Ambos orbitan a una altitud de **786 km** y trabajan en conjunto para **obtener imágenes cada 5 días** de cualquier punto del planeta, lo que lo hace ideal para aplicaciones dinámicas como la agricultura, monitoreo forestal, cuerpos de agua, y más.

Sentinel-2

Rango espectral	Bandas (nm)	Resolución	Aplicaciones
Visible (RGB)	490–665	10 m	Vegetación, uso del suelo
NIR (Infrarrojo cercano)	705–842	10–20 m	NDVI, salud vegetal
SWIR (Infrarrojo de onda corta)	1375–2190	20 m	Humedad, suelos, estrés
Bandas costeras y atmosféricas	443, 945 nm, etc.	60 m	Corrección atmosférica

Sentinel - 2



Agricultura de precisión: monitoreo de cultivos, estrés hídrico, fertilización



Vegetación y uso del suelo: índices como NDVI, NDRE, clasificación de coberturas



Gestión del agua: calidad, turbidez, cuerpos de agua



Monitoreo de incendios forestales



Minería y geología



Cambio climático y desastres naturales

¿Dónde se descargan las imágenes?



COPERNICUS OPEN
ACCESS HUB



SENTINEL HUB EO
BROWSER



PLATAFORMAS COMO
GOOGLE EARTH ENGINE

Landsat

El Landsat es uno de los programas de observación de la Tierra más antiguos y consistentes del mundo, operado por la NASA y el USGS (Servicio Geológico de EE. UU.). Su objetivo es monitorear los cambios en la superficie terrestre a largo plazo.

Landsat

Satélite	Año de lanzamiento	Estado actual
Landsat 7	1999	activo (limitado por falla de escaneo)
Landsat 8	2013	activo
Landsat 9	2021	activo

Landsat

- **Sensor OLI (Operational Land Imager) – Landsat 8 y 9**
- 9 bandas multispectrales (visible, NIR, SWIR, pancromática)
- Resolución:
 - 30 m en bandas ópticas
 - 15 m en banda pancromática (blanco y negro)
- **Sensor TIRS (Thermal Infrared Sensor) – Landsat 8 y 9**
- 2 bandas térmicas (10 y 11)
- Resolución: 100 m (re-escalada a 30 m)

Landsat



Monitoreo agrícola: salud de cultivos, índices de vegetación (NDVI, NDWI)



Gestión forestal: deforestación, biomasa



Cambio de uso del suelo: urbanización, minería, agricultura



Monitoreo del agua: cuerpos hídricos, humedad del suelo



Incendios: cicatrices de quemas, temperatura superficial

Landsat

USGS EarthExplorer

[Google Earth Engine](#)

Land Viewer (EOS)

[AppEEARS \(NASA\)](#)

Landsat Vs Sentinel

Característica	Landsat 8/9	Sentinel-2
Resolución espacial	15–30 m	10–60 m
Revisita	16 días	5 días (con 2 satélites)
Bandas espectrales	11 (OLI+TIRS)	13 (MSI)
Aplicaciones clave	Cambios a largo plazo	Agricultura, vegetación
Cobertura	Global	Global

MODIS

- El **MODIS** (Moderate Resolution Imaging Spectroradiometer) es un **sensor** instalado en dos satélites de la NASA.

Satélites Terra – lanzado en 1999 **Aqua** – lanzado en 2002

- Ambos satélites tienen órbitas polares sincronizadas con el Sol y están diseñados para ofrecer una **visión global diaria** del planeta.

MODIS

Característica	Detalle
Resolución espacial	250 m, 500 m y 1000 m
Número de bandas	36 bandas espectrales (visible, NIR → TIR)
Cobertura temporal	Global cada 1–2 días
Ancho de escaneo	2,330 km
Datos desde	Año 2000 (Terra)

MODIS



NDVI y EVI (índices de vegetación)



Temperatura de la superficie terrestre (LST)



Cobertura del suelo



Nubes y aerosoles atmosféricos



Incendios (detección de puntos calientes)



Contenido de clorofila en océanos



Nieve y hielo

MODIS

- Cambio climático
- Monitoreo agrícola y forestal a gran escala
- Gestión de recursos hídricos
- Seguimiento de sequías



MODIS

NASA LP DAAC (MODIS Products)

AppEARS

Google Earth Engine

MODIS Subsets (ORNL DAAC)

Plataformas

Drones y aviones



Drones

- Los **drones** o **vehículos aéreos no tripulados (UAVs)** son plataformas aéreas que se utilizan ampliamente en **teledetección**, agricultura, medio ambiente, y muchos otros campos debido a su **flexibilidad** y **bajo costo operativo**.
- Un **dron** en teledetección es una **plataforma aérea** equipada con uno o más **sensores** (cámaras multiespectrales, térmicas, RGB (Visible), LIDAR, etc.) que captura datos desde el aire para analizar la superficie terrestre con gran detalle.



Drones

Tipo de sensor	Qué mide	Aplicaciones típicas
 RGB	Imagen visible (como una cámara convencional)	Cartografía, conteo de plantas, inspecciones
 Multiespectral	4–6 bandas: rojo, verde, azul, NIR, RedEdge	NDVI, salud de cultivos, vigor vegetal
 Térmica (IR)	Temperatura superficial	Estrés hídrico, detección de animales, incendios
 LiDAR	Nubes de puntos 3D (distancias con láser)	Altimetría, estructuras del suelo y vegetación
 Hiperespectral	Decenas a cientos de bandas	Estudios detallados de composición química

Comparación de plataformas: drones vs satélites

Característica	Drones	Satélites como Sentinel-2 o MODIS
Resolución espacial	Muy alta (cm por píxel)	Media a baja (10–1000 m)
Frecuencia de datos	Personalizable (día/hora)	Revisitación periódica (5–16 días)
Área de cobertura	Limitada (ha o km ²)	Amplia (miles de km ²)
Costo por uso	Medio a alto	Bajo (datos gratuitos)
Control del usuario	Total	Limitado (depende de órbita y clima)

¿Cómo se usa un dron en teledetección?



Planificación del vuelo (app tipo Pix4Dcapture o DJI GS Pro).



Captura de datos con cámara multiespectral (Micasense, Parrot Sequoia).



Corrección radiométrica con panel de calibración.



Procesamiento fotogramétrico (Pix4D, Agisoft Metashape, QGIS).



Cálculo de índices vegetativos (NDVI, NDRE, etc.).



Análisis e interpretación con mapas o series temporales.

Aviones

- Los **aviones** son una de las plataformas **aéreas tripuladas** más utilizadas en **teledetección de alta resolución**, especialmente cuando se necesita cubrir grandes extensiones de terreno con **más flexibilidad que los satélites y más cobertura que los drones**.
- Son **aeronaves tripuladas** que vuelan a altitudes medias (usualmente entre **1.000 y 10.000 metros**) y llevan a bordo **sensores especializados** que capturan datos de la superficie terrestre. Se usan ampliamente en cartografía, estudios ambientales, monitoreo agrícola, estudios geológicos, forestales y urbanos.

Aviones

Ventaja

Alta resolución espacial

Mayor cobertura por vuelo

Flexibilidad temporal

Carga útil elevada

Uso de sensores especializados

Descripción

Similar o superior a la de drones

Ideal para zonas grandes (decenas o cientos de km²)

Puede volar cuando y donde se necesite (clima permitido)

Puede llevar sensores grandes, pesados o múltiples a la vez

Cámaras hiperespectrales, LiDAR, térmicas, radar, etc.

Aviones

Plataforma

Aplicación típica

Aviones tripulados ligeros

Agricultura, silvicultura, planificación territorial

Aviones de investigación

Misiones científicas (NASA, ESA, INTA)

Aviones comerciales adaptados

Fotogrametría, cartografía urbana

Aplicaciones en investigación

Estimación de **biomasa y productividad**

Seguimiento de **crecimiento de cultivos o silvopasturas.**

Generación de **modelos digitales de elevación (MDE) y canopias.**

Mapeo detallado de **usos del suelo, deforestación, erosión.**

Calibración/validación de sensores satelitales (como Sentinel o Landsat).

Comparación entre distintas plataformas: Satélite, Avión y dron

Característica	Satélite	Avión	Drone
Resolución espacial	Media	Alta	Muy alta
Cobertura	Global	Regional (100s km ²)	Local (1–100 ha)
Flexibilidad	Baja	Media–Alta	Muy alta
Costo operativo	Bajo (datos libres)	Alto	Medio
Altura de vuelo	>700 km	1–10 km	30–150 m

Material de Autoaprendizaje

<https://eventosytutoriales.my.canva.site/terminosteledeteccion>

Guía Completa e Interactiva de Teledetección

Módulos Interactivos de Teledetección

Guía Interactiva de Teledetección



Introducción al machine learning y la inteligencia artificial

“El machine learning convierte datos en decisiones, imágenes en insights, y curiosidad en conocimiento; en cambio, la inteligencia artificial hace posible lo que antes era impensable”

Machine Learning


Machine learning (aprendizaje automático) es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos capaces de aprender patrones a partir de datos y mejorar su desempeño en una tarea específica sin ser programados de forma explícita para cada caso.

En lugar de seguir instrucciones fijas, un sistema de machine learning utiliza, por ejemplo, datos históricos para entrenar un modelo, el cual luego puede realizar predicciones, clasificaciones, recomendaciones o detección de patrones en nuevos datos

Machine Learning

Machine learning (aprendizaje automático) es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos capaces de aprender patrones a partir de datos y mejorar su desempeño en una tarea específica sin ser programados de forma explícita para cada caso.

En lugar de seguir instrucciones fijas, un sistema de machine learning utiliza, por ejemplo, datos históricos para entrenar un modelo, el cual luego puede realizar predicciones, clasificaciones, recomendaciones o detección de patrones en nuevos datos



Machine Learning

1

DATOS: EJEMPLOS O EXPERIENCIAS DE LOS QUE EL SISTEMA APRENDE.

2

MODELO: REPRESENTACIÓN MATEMÁTICA/ESTADÍSTICA QUE CAPTURA PATRONES DE LOS DATOS.

3

ENTRENAMIENTO: PROCESO DE AJUSTAR LOS PARÁMETROS DEL MODELO USANDO DATOS.


4

EVALUACIÓN: MEDICIÓN DEL DESEMPEÑO DEL MODELO EN DATOS NO VISTOS.

Inteligencia Artificial (IA)

La Inteligencia Artificial (IA) busca crear sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el razonamiento, el aprendizaje, la percepción, la comprensión del lenguaje y la toma de decisiones.

En otras palabras, la IA trata de dotar a las máquinas de la capacidad de simular la inteligencia humana en distintos niveles, desde acciones simples (reconocer una voz o clasificar una imagen) hasta complejas (conducir un vehículo autónomo o diagnosticar una enfermedad).



Inteligencia Artificial



**Aprender de la experiencia
(Machine Learning).**




**Procesar y analizar
grandes volúmenes
de datos.**



**Razonar y resolver
problemas.**



**Percibir el entorno
mediante sensores
(visión, sonido, etc.).**



**Interactuar con
humanos (chatbots,
asistentes virtuales).**

Diferencias IA y ML

Aspecto	Inteligencia Artificial	Machine Learning
Alcance	Campo general	Subcampo de la IA
Método	Usa reglas, lógica, conocimiento experto y ML	Usa algoritmos de aprendizaje basados en datos
Objetivo	Simular inteligencia humana	Aprender de datos para predecir o clasificar
Ejemplo	Un robot que planifica rutas	Un modelo que predice la ruta más rápida con datos históricos

Diferencias entre IA y ML



**IA ES EL UNIVERSO
COMPLETO.**



**ML ES UN PLANETA DENTRO
DE ESE UNIVERSO.**

Machine learning ¿Qué técnicas?



Supervisado →
aprende con
ejemplos correctos.



No supervisado →
descubre patrones
ocultos.



Refuerzo → aprende
de recompensas.



Semi-supervisado →
mezcla etiquetados y
no etiquetados.



Ensembles →
combina modelos
para ser más robusto.

Tipos de aprendizaje en Machine Learning

1. Aprendizaje Supervisado

El modelo aprende con **ejemplos etiquetados** (datos de entrada + la respuesta correcta).

- **Ejemplos en agricultura digital:**

- Predecir **biomasa o rendimiento de un cultivo** a partir de imágenes Sentinel-2 y datos de campo.
- Clasificar parcelas en **cultivo, pasto, agua o bosque** usando entrenamiento con mapas ya validados.
- Detectar **estrés hídrico o nutricional** en potreros de Mombasa con índices espectrales (NDVI, NDRE).

Tipos de aprendizaje en Machine Learning

2. Aprendizaje No Supervisado

El modelo busca **patrones ocultos sin etiquetas**.

- **Ejemplos en agricultura digital:**

- Agrupar potreros en **zonas homogéneas de vigor vegetal** para fertilización diferenciada.
- Detectar **cambios en coberturas de suelo** (deforestación, expansión agrícola).
- Segmentar imágenes satelitales en regiones con distinta **calidad de forraje**.

Tipos de aprendizaje en Machine Learning

3. Aprendizaje Semi-Supervisado

Se combinan **pocos datos etiquetados** con **muchos sin etiquetar**.

- **Ejemplos en agricultura digital:**

- Clasificar cultivos cuando solo hay datos de campo en unas pocas parcelas, pero se tienen miles de imágenes satelitales.
- Mapear **malezas en pasturas**, usando pocas muestras tomadas en terreno y grandes áreas sin etiqueta.

Tipos de aprendizaje en Machine Learning

4. Aprendizaje por Refuerzo

El modelo aprende por **prueba y error**, recibiendo **recompensas o penalizaciones**.

- **Ejemplos en agricultura digital:**

- Optimizar **sistemas de riego inteligentes**, ajustando el agua según humedad satelital + pronóstico climático.
- Planificar **rotación de potreros en sistemas silvopastoriles** para maximizar productividad y bienestar animal.
- Dirigir drones o robots agrícolas para **monitorear cultivos de forma eficiente**.

Tipos de aprendizaje en Machine Learning

5. Aprendizaje por Ensamblados (Ensemble Learning)

Se combinan varios modelos para obtener mayor precisión.

- **Ejemplos en agricultura digital:**

- Usar **Random Forest + XGBoost** para predecir **rendimiento de maíz o pasturas** con datos de satélite + clima + suelo.
- Mejorar la **detección temprana de plagas** en imágenes satelitales combinando distintos clasificadores.

1. Aprendizaje Supervisado

Algoritmo	Descripción	Ejemplo en agricultura digital (satélites)
Regresión Lineal (Simple, Multiple y regularizada como: ElasticNet, Ridge y LASSO)	Relación entre variables continuas.	Predecir biomasa de pasto Mombasa con NDVI de Sentinel-2.
Regresión Logística	Clasifica en dos categorías.	Detectar áreas con estrés hídrico en cultivos de maíz.
Árboles de decisión	Clasificación mediante reglas jerárquicas.	Clasificar tipos de cobertura (cultivo, pasto, bosque, agua) .
Random Forest	Conjunto de árboles de decisión para mayor precisión.	Estimar rendimiento de caña con datos satelitales + clima.
SVM (Máquinas de Vectores de Soporte)	Encuentra fronteras óptimas para separar clases.	Clasificar cultivos vs malezas en imágenes satelitales.
Redes Neuronales Artificiales	Modelos inspirados en el cerebro, flexibles.	Estimar proteína en forraje con imágenes satelitales + datos de campo.

2. Aprendizaje no supervisado

Algoritmo	Descripción	Ejemplo en agricultura digital (satélites)
K-Means (Clustering)	Agrupar datos en clusters según similitud.	Segmentar potreros en zonas homogéneas de vigor .
DBSCAN	Agrupamiento por densidad, detecta anomalías.	Identificar áreas afectadas por plagas o sequías .
PCA (Análisis de Componentes Principales)	Reduce dimensiones conservando información.	Simplificar bandas de Sentinel-2 para análisis más rápido.

3. Aprendizaje semisupervisado

Algoritmo	Descripción	Ejemplo en agricultura digital (satélites)
Label Propagation	Propaga etiquetas de pocos datos hacia no etiquetados.	Clasificar cultivos con pocas parcelas medidas y muchas imágenes.
Autoencoders	Extraen características y reducen ruido.	Mejorar la detección de malezas en potreros con pocas muestras de campo.

4. Aprendizaje por refuerzo

Algoritmo	Descripción	Ejemplo en agricultura digital (satélites)
Q-Learning	Aprende mediante recompensas acumuladas.	Optimizar riego en arrozales usando humedad satelital + clima.
Deep Q-Networks (DQN)	Combina redes neuronales + refuerzo.	Controlar rotación de potreros en sistemas silvopastoriles .

5. Aprendizaje por ensamble

Algoritmo	Descripción	Ejemplo en agricultura digital (satélites)
Bagging (Random Forest)	Combina modelos para reducir varianza.	Predicción robusta de rendimiento de cultivos .
Boosting (XGBoost, LightGBM)	Combina modelos secuenciales para mejorar precisión.	Detección temprana de plagas y enfermedades en cultivos.

Revisión de algunas técnicas de aprendizaje

1. Aprendizaje supervisado

- Regresión Lineal (Simple, Multiple y regularizada como: ElasticNet, Ridge y LASSO)
- Random Forest
- SVM (Máquinas de Vectores de Soporte)

2. Aprendizaje no supervisado

- K-Means (Clustering)
- PCA (Análisis de Componentes Principales)

3. Aprendizaje por Ensamble

- XGBoost

Fundamentos matemáticos

[1] G. James, D. Witten, T. Hastie, and R. Tibshirani, **An Introduction to Statistical Learning with Applications in Python**. New York, NY, USA: Springer, 2023.


[2] A. C. Müller and S. Guido, **Introduction to Machine Learning with Python: A Guide for Data Scientists**. Sebastopol, CA, USA: O'Reilly Media, 2017.

Fundamentos matemáticos

1. Aprendizaje supervisado

- Regresión Lineal
 - a. Simple
 - b. Múltiple
 - c. Regularizada como: ElasticNet, Ridge y LASSO)

Regresión Lineal Simple



Regresión lineal clásica (Estadística Vs. ML)

- **Regresión lineal clásica (estadística):**

- Busca **explicar** la relación entre una variable dependiente YYY y una o varias independientes XXX.
- El interés suele estar en los **coeficientes** (β): cuánto cambia YYY si XXX cambia también.
- Ejemplo: "Por cada hora adicional de estudio, la nota aumenta 0.5 puntos".

Regresión lineal en machine learning (ML):

- Se usa más para **predecir** que para explicar.
- El foco no es tanto el valor de los coeficientes, sino que también llegue a un modelo generalizable para **nuevos datos**.
- Ejemplo: predecir la producción de forraje el próximo mes con datos de clima y suelo.

Regresión lineal clásica (Estadística Vs. ML)

Clásica:

- Normalmente usa **Mínimos Cuadrados Ordinarios (OLS)**.
- Busca minimizar el **error cuadrático promedio**

Machine Learning:

- Puede usar OLS para disminuir el error de ajuste con los datos de entrenamiento, pero también métodos iterativos (ej. Gradient Descent) que buscan minimizar el error y son ideales para manejar grandes volúmenes de datos.
- A menudo incluye **regularización** (Ridge, LASSO, Elastic Net) para evitar sobreajuste.
- El interés es optimizar la **función de pérdida + término de regularización**.

Regresión lineal clásica (Estadística Vs. ML)

3. Validación del modelo

- **Clásica:**

- Se apoya en supuestos (normalidad de errores, homocedasticidad, independencia, no multicolinealidad).
- Usa métricas como R^2 , pruebas de hipótesis, intervalos de confianza.

- **Machine Learning:**

- Relajación de supuestos: no importa tanto si los errores son normales o si hay multicolinealidad.
- Validación se hace con **conjuntos de entrenamiento, validación y prueba**, usando técnicas como **cross-validation** o **validación cruzada**.
- Métricas típicas: RMSE, MAE, R^2

Regresión lineal clásica (Estadística Vs. ML)

4. Aplicación

- **Clásica:**

- Más usada en investigación, ciencias sociales, econometría → para interpretar relaciones.
- Ejemplo: ¿Cómo influye el nivel educativo en el ingreso salarial?

- **Machine Learning:**

- Más usada en predicción y sistemas automáticos → agricultura digital, visión por computadora, series temporales.
- Ejemplo: Predecir biomasa de Mombasa usando datos satelitales e IoT.

Regresión

Modelos

Clasificación



Métricas de evaluación de modelos ML (regresión)

1. MAE – Mean Absolute Error (Error Absoluto Medio)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

- Calcula el **promedio de los errores absolutos**.
- Es fácil de interpretar: indica, en promedio, cuánto se equivoca el modelo en las predicciones.
- Ejemplo: si $\text{MAE} = 2$, significa que en promedio me equivoco **2 unidades** (kg, cm, etc.).

Métricas de evaluación de modelos ML (regresión)

2. RMSE – Root Mean Squared Error (Raíz del Error Cuadrático Medio)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

- Penaliza más los **errores grandes**, porque los eleva al cuadrado.
- Es útil cuando nos importa mucho que no haya errores grandes.
- También, al igual que el anterior, está en las **mismas unidades de la variable** que estamos prediciendo.
- Ejemplo: en agricultura, si predigo biomasa y RMSE = 50 kg/ha, significa que en promedio me equivoco en **50 kg/ha**.

Métricas de evaluación de modelos ML (regresión)

Coeficiente de Determinación - R^2

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

- Mide **qué proporción de la variabilidad de los datos es explicada por el modelo.**
- Varía entre **0 y 1** (aunque puede ser negativa si el modelo es muy malo).
- $R^2 = 1$ el modelo explica toda la variabilidad.
- $R^2 = 0$ el modelo no explica nada (igual que usar el promedio).
- Ejemplo: $R^2 = 0,85 \rightarrow$ el modelo explica el **85% de la variación de los datos.**

Métricas de evaluación de modelos ML (regresión)

- **MAE** → promedio del error (robusto, fácil de interpretar).
- **RMSE** → como el MAE, pero castiga más los errores grandes.
- **R²** → qué tan bien se ajusta el modelo a los datos.



Métricas de evaluación de modelos ML (regresión)

Ejemplo:

- MAE te diría el error promedio en kg/ha.
- RMSE resaltaría si tuviste errores muy grandes en ciertas parcelas.
- R^2 diría qué porcentaje de la variabilidad entre parcelas está bien explicado por tu modelo

Métricas de evaluación de modelos ML (clasificación)

F1-Score

$$F1 = 2 \frac{\text{Precisión} * \text{Recall}}{\text{Precisión} + \text{Recall}}$$

- Es la **media armónica** entre **precisión** y **recall (sensibilidad)**.
- Útil cuando hay **clases desbalanceadas** (ej: 90% sanos, 10% enfermos).

Interpretación:

- **Precisión** = de los que predije como positivos, ¿cuántos realmente lo son?
- **Recall (sensibilidad)** = de los positivos reales, ¿cuántos detecté?
- El **F1-score** equilibra ambas cosas.

Métricas de evaluación de modelos ML (clasificación)

Ejemplo:

- En un modelo que predice si una planta tiene una enfermedad:
- Alta precisión pero bajo recall → casi no doy falsos positivos, pero me pierdo muchos enfermos.
- Alta recall pero baja precisión → detecto casi todos los enfermos, pero doy muchas falsas alarmas.
- F1 mide el **balance** entre ambos.

Métricas de evaluación de modelos ML (clasificación)

AUC – Area Under the Curve (Área bajo la curva ROC)

- Se calcula a partir de la **curva ROC** (Receiver Operating Characteristic).
- La curva ROC grafica:
 - **Eje Y:** Tasa de verdaderos positivos (Recall o Sensibilidad).
 - **Eje X:** Tasa de falsos positivos (1 - Especificidad).

Interpretación:

- $AUC = 1 \rightarrow$ el modelo separa perfectamente las clases.
- $AUC = 0.5 \rightarrow$ el modelo no es mejor que adivinar al azar.
- $AUC < 0.5 \rightarrow$ peor que azar (clasifica al revés).

Métricas de evaluación de modelos ML (clasificación)

Ejemplo en agricultura digital:

- Si quiero clasificar imágenes satelitales en “**pasto sano**” vs “**pasto estresado**”,
 - **AUC = 0.90** significa que hay un 90% de probabilidad de que el modelo dé una puntuación mayor a un píxel realmente “sano” que a uno realmente “estresado”.

Métricas de
evaluación de
modelos ML
(clasificación)

F1-score → equilibrio entre
precisión y recall (útil con
clases desbalanceadas).

AUC → mide la capacidad del
modelo para distinguir entre
clases, independiente del
umbral.

Regresión Lineal simple

- La regresión lineal simple modela la relación entre una variable dependiente y una independiente a través de una recta:

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$$

donde:

y_i = variable dependiente

x_i : variable independiente

β_0 : intercepto

β_1 : pendiente

ε_i : término de error

Regresión lineal simple

- Los coeficientes β_0 y β_1 se estiman con:

$$\beta_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$$

$$\beta_0 = \bar{y} - \beta_1 \bar{x}$$

El objetivo del modelo es **estimar los parámetros** β_0 y β_1 a partir de los datos, usualmente usando el **método de mínimos cuadrados**:

Regresión lineal simple

$$\beta_0 = \bar{y} - \widehat{\beta}_1 \bar{x} \quad \widehat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

Regresión lineal múltiple

- La regresión lineal múltiple extiende la regresión lineal simple a varios predictores:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i$$

donde:

- y_i : variable dependiente
- x_{ip} : variables independientes
- β_0 : intercepto
- β_p : coeficientes de regresión
- ε_i : término de error

Regresión lineal múltiple

El modelo puede escribirse en notación matricial como:

$$Y = X\beta + \varepsilon$$

- donde:
- Y es el vector de respuestas o salida ($n \times 1$)
- X es la matriz de predictores ($n \times p$)
- β es el vector de coeficientes ($p \times 1$)
- ε es el vector de errores ($n \times 1$)

Los parámetros se estiman mediante el método de mínimos cuadrados:

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$

Regresión Lineal Ridge, LASSO, ElasticNet

1. Regresión Ridge (o Tikhonov)

- Minimiza la suma de errores cuadrados más una penalización L2:

$$\widehat{\beta}^{ridge} = \arg \min_{\beta} \left\{ \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\}$$

Regresión Lineal Ridge, LASSO, ElasticNet

2. Regresión LASSO (Least Absolute Shrinkage and Selection Operator)

- Minimiza la suma de errores cuadrados más una penalización L1:

$$\widehat{\beta}^{lasso} = \arg \min_{\beta} \left\{ \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\}$$




Regresión Lineal Ridge, LASSO, ElasticNet

3. Regresión Elastic Net



- Combina L1 (LASSO) y L2 (Ridge) con un parámetro de mezcla α :

$$\begin{aligned} \widehat{\beta}^{EN} = \arg \min_{\beta} & \left\{ \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 \right. \\ & \left. + \lambda \left[\alpha \sum_{j=1}^p |\beta_j| + (1 - \alpha) \sum_{j=1}^p \beta_j^2 \right] \right\} \end{aligned}$$

Representación geométrica de las penalizaciones



Representación grafica de como son las penalizaciones en LASSO y Ridge.



Random Forest

Random Forest es un método de aprendizaje conjunto (*ensemble learning*) que combina múltiples árboles de decisión para crear un modelo más robusto y preciso

Random Forest se basa en el principio de bagging, que reduce la varianza del modelo mediante el promediado de múltiples estimadores.



Random Forest

Conjunto de datos

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$$

Donde:

$x_i \in \mathbb{R}_p$ (p características)

$y_i \in \mathbb{R}$ (regresión) o $y_k \in 1, 2, \dots, K$ (clasificación)

n= número de muestras

Random Forest

Bootstrap Aggregating (Bagging)

Crear B muestras Bootstrap D_b mediante muestreo con reemplazo de los datos originales de cada árbol (unos se repiten y otros quedan fuera (out-of bag, pero son útiles para validación interna).

- Entrenar un árbol T_b (árbol de decisión) para cada muestra
- Combinar predicciones

Regresión:

$$\hat{f}_{RF}(x) = \frac{1}{B} \sum_{b=1}^B T_b(x)$$

Clasificación:

$$\hat{f}_{RF}(x) = \text{mode}\{T_1(x), T_2(x), \dots, T_b(x)\}$$

Random Forest

- **Feature Bagging**

Segunda Fuente de Aleatoriedad

En cada nodo del árbol, en lugar de evaluar todas las variables, solo se consideran m características aleatorias de las p (*predictoras*) totales

- **Decorrelaciona los árboles (mejor Split del conjunto para crecer el árbol), buscando que los arboles sean diferentes entre sí.**

Valores típicos:

Clasificación: $m = \sqrt{p}$

Regresión: $m = \frac{p}{3}$

Random Forest

Crecimiento de árboles

- Cada árbol se expande hasta una cierta profundidad o hasta que mejore el ajuste.
- Normalmente no se podan (a diferencia de los árboles clásicos), porque la diversidad mejora el resultado.

Combinación de resultados

- Una vez contruidos todos los árboles (n árboles en el bosque):
 - **Clasificación:** cada árbol “vota” por una clase, y la clase con más votos es la predicción final (mayoría).
 - **Regresión:** se promedian las predicciones de todos los árboles.

Random Forest

Evaluación del modelo

- Se pueden usar los datos “out-of-bag” (los que quedaron por fuera de cada bootstrap) como validación interna.
- También se emplean métricas clásicas: **MAE**, **RMSE**, R^2 para regresión, o **accuracy**, **F1-score**, **AUC** para clasificación.

Se evalúa con el conjunto de prueba.

Random Forest

Reducción de Varianza

Análisis Matemático

Varianza del Random Forest:

$$\text{var}(\hat{f}_{RF}) = \rho\sigma^2 + \frac{1-\rho}{B}\sigma^2$$

Donde:

σ^2 = varianza de un árbol individual

ρ = correlación promedio entre árboles

B = numero de árboles

Si $B \rightarrow \infty$

$$\text{Var}(\hat{f}_{RF}) \rightarrow \rho\sigma^2$$

Random Forest

Criterios de División - Clasificación

- Medidas de Impureza

Impureza Gini:

$$G = 1 - \sum_{k=1}^k P_k^2$$

Entropía:

$$H = - \sum_{k=1}^k p_k \log(p_k)$$

Donde p_k = proporción de muestras de clase k en el nodo

Random Forest

Out-of-Bag (OOB) Error

Validación Integrada

- Cada árbol usa ~63.2% de muestras únicas
- El 36.8% restante son muestras OOB

$$OOB\ Error = \frac{1}{n} \sum L(y_i, f_{OOB}^{(i)})$$

$f_{OOB}^{(i)}$ = predicción usando solo arboles donde x_i fue OOB

Proporción esperada en bootstrap:

$$1 - \left(1 - \frac{1}{n}\right)^n = 0.632$$

Random Forest

- De las n muestras originales, aproximadamente $0.632n$ aparecerán al menos una vez en la muestra bootstrap
- Aproximadamente $0.368n$ muestras NO aparecerán (estas son las muestras Out-of-Bag)
- Algunas muestras aparecerán múltiples veces (por eso tenemos n muestras totales pero solo).

Random Forest

Esta propiedad es fundamental porque:

- **Validación natural:** El 36.8% de muestras OOB sirven como conjunto de validación
- **Diversidad:** Cada árbol ve un subconjunto diferente de datos
- **Reducción de sobreajuste:** Los árboles no memorizan todo el dataset
- **Estimación de error sin CV:** OOB error es un estimador insesgado del error de generalización.

Random Forest

Estimador Completo

- **Formulación General:**

$$\hat{f}_{RF}(x) = \frac{1}{B} \sum_{b=1}^B T(x; \theta_b, D_b)$$

- D_b = muestra Bootstrap b-esmima
- θ_b = selección aleatoria de características
- $T(x; \theta_b, D_b)$ = árbol b-ésimo

Random Forest

Por qué funciona Random Forest

- **Robustez al sobreajuste**
 - Promediado reduce varianza sin aumentar sesgo
- **No paramétrico**
 - Sin supuestos distribucionales
- **Captura no linealidades**
 - Árboles modelan interacciones complejas
- **Invariante a transformaciones monótonas**
 - No requiere normalización

Random Forest

Puntos Clave


- **Bagging:** Reduce varianza mediante promediado
- **Feature randomness:** Decorrelaciona predictores
- **OOB:** Validación sin conjunto separado
- **Convergencia:** $\text{Var} - \rho\sigma^2$ cuando $B \rightarrow \infty$
- **Balance óptimo:** Bajo sesgo + Baja varianza

Aplicaciones:

- Clasificación y regresión
- Alta dimensionalidad
- Datos con ruido
- Detección de importancia de variables

Random Forest

Decision Tree from Random Forest



Applet para comprender Random Forest

Panel de Configuración:

- **Número de árboles:** Ajustable de 1 a 50 para ver cómo afecta el ensemble
- **Profundidad máxima:** Control sobre la complejidad de cada árbol
- **Muestras por hoja:** Parámetro de regularización
- **Selección de características:** Diferentes estrategias (sqrt, log2, todas)
- **Tipo de problema:** Clasificación o regresión
- **Conjuntos de datos:** Varios patrones sintéticos para explorar

Applet para comprender Random Forest

Visualización:

- **Gráfico de datos:** Muestra los puntos de entrenamiento con colores por clase
- **Límites de decisión:** Visualiza las regiones de clasificación del modelo
- **Vista de árboles individuales:** Cada árbol muestra sus estadísticas
- **Métricas en tiempo real:**

Precisión promedio del bosque

OOB Score (Out-of-Bag)

Profundidad promedio de los árboles

Total de nodos en el bosque

Applet para comprender Random Forest

Uso pedagógico:

- **Explorar el efecto del número de árboles:** Muestra cómo más árboles generalmente mejoran la estabilidad
- **Entender el bootstrap sampling:** Cada árbol se entrena con muestras diferentes
- **Visualizar el voting/averaging:** La predicción final combina todos los árboles
- **Experimentar con diferentes datasets:** Ver cómo el algoritmo maneja diferentes patrones

Applet para comprender Random Forest

Opciones en el applet:

- **$\sqrt{n}$ (Raíz cuadrada):** Si tienes 100 características, cada división considera solo 10
 - Bueno para clasificación
 - Mayor diversidad entre árboles
- **$\log_2(n)$:** Si tienes 100 características, cada división considera ~ 7
 - Más restrictivo
 - Árboles más diversos pero potencialmente menos precisos individualmente
- **Todas:** Usa todas las características (no es Random Forest puro)
 - Menor diversidad
 - Similar a un bosque de árboles normales

Random Forest

Queremos **predecir el rendimiento de un cultivo (kg/ha)** a partir de variables obtenidas por sensores e imágenes satelitales:

- **NDVI** (índice de vegetación).
- **Precipitación acumulada (mm)**.
- **Temperatura media (°C)**.

Esto es un **problema de regresión**, ya que la variable de salida es numérica (rendimiento).

Random Forest

Ejemplo:

Entrenamiento: Se construye un bosque de 200 árboles de decisión.

- **Predicción:** El modelo estima el rendimiento de cada parcela.

Métricas típicas:

- **MAE:** error promedio en kg/ha.

- **RMSE:** penaliza más los errores grandes.

- **R^2 :** qué proporción de la variabilidad del rendimiento explican las variables.

- **Importancia de variables:** El gráfico muestra cuáles variables (NDVI, precipitación, temperatura) influyen más en la predicción.

An aerial photograph of a vast, dense forest of evergreen trees, likely spruce or fir, covering a hillside. The trees are tightly packed, creating a textured, dark green surface. The lighting is soft, suggesting an overcast day or early morning/late afternoon.

Applet para comprender Random Forest

[Random Forest - Herramienta de Enseñanza](#)

SVM (Máquinas de Vectores de Soporte)

SVM (Support Vector Machine o Máquina de Vectores de Soporte) es un algoritmo de aprendizaje supervisado cuyo modelo matemático se basa en encontrar el hiperplano óptimo que separa las clases de datos con el margen máximo.

El objetivo es encontrar un hiperplano definido por:

$$w \cdot x + b = 0$$

- w es el vector de pesos (normal al hiperplano)
- x es el vector de características
- b es el término de sesgo

SVM (Máquinas de Vectores de Soporte)

Función de decisión:

$$f(x) = \text{sign}(w \cdot x + b)$$

Problema de optimización:

Minimizar: $\frac{1}{2} \|w\|^2$

Sujeto a: $y_i(w \cdot x_i + b) \geq 1$ para $i = 1, \dots, n$

Donde $y_i \in \{-1, +1\}$ son las etiquetas de clase.

SVM (Máquinas de Vectores de Soporte)

Kernel trick

Para casos no lineales, se mapean los datos a un espacio de mayor dimensión usando kernels:


Función de decisión: $f(x) = \text{sign}(\sum \alpha_i y_i K(x_i, x) + b)$

Kernels comunes:

- Lineal: $K(x_i, x_j) = x_i \cdot x_j$
- Polinomial: $K(x_i, x_j) = (\gamma x_i \cdot x_j + r)^d$
- RBF (Gaussiano): $K(x_i, x_j) = \exp(-\gamma ||x_i - x_j||^2)$

Los vectores de soporte son aquellos puntos x_i donde $\alpha_i > 0$, y son los únicos que determinan el hiperplano de separación.

SVM gráfico



Ejemplo con SVM

Problema: Queremos clasificar zonas de un cultivo en dos clases usando imágenes satelitales:

- Clase 1: “**estrés hídrico**” 
- Clase 2: “**vegetación sana**” 

Variables (features) de entrada:

- NDVI (índice de vegetación).
- Humedad del suelo.
- Temperatura superficial.

Salida: Etiqueta binaria → 0 = estrés, 1 = sano.

Applet para comprender SVM

SVC with polynomial (degree 3) kernel

LinearSVC (linear kernel)

[SVM Interactive Applet](#)

K-means (k-medias)

K-means es un **algoritmo de Machine Learning no supervisado** que se usa para **clustering** (agrupamiento). Su objetivo es **dividir un conjunto de datos en k grupos** (clusters), de tal forma que:

- Los puntos dentro de un mismo grupo sean **lo más parecidos posible**.
- Los puntos de diferentes grupos sean **lo más distintos posible**.

K-means (k-medias)

Minimizar la suma de distancias cuadradas intracluster:

$$J = \sum_{i=1}^k \sum_{x \in c_i} \|x - \mu_i\|^2$$

K es el numero de cluster

c_i es el conjunto de puntos en el cluster i

μ_i el el centroide del cluster i

$\|x - \mu_i\|^2$ distancia euclidiana al cuadrado.

K-means (k-medias)

Pasos del algoritmo:

1. Inicialización: seleccionar k centroides $\mu_1, \mu_2, \mu_3, \dots, \mu_k$
2. Asignación: Cada punto x_j se asigna al clúster más cercano:

$$c_i = \left\{ x_j : \|x_j - \mu_i\|^2 \leq \|x_j - \mu_l\|^2 : \forall l \in \{1, \dots, k\} \right\}$$


3. Actualización : Recalcular centroides como medidas de puntos asignados:

$$\mu_i = \frac{1}{C_i} \sum_{x \in C_i} x$$

4. Convergencia: Repetir 2-3 hata que centroides no cambien o $\Delta J < \epsilon$

Características de k-means

- Convergencia a mínimo local garantizada
- No garantiza óptimo global
- Resultado depende de inicialización




Ejemplo en Agricultura Digital

- Supongamos que tengo imágenes satelitales de un cultivo y quiero **segmentar áreas según vigor** (NDVI):
- Pongo $k=3$ $\rightarrow$ tres grupos:
 - **Cluster 1:** áreas de bajo vigor (estrés hídrico).
 - **Cluster 2:** vigor medio.
 - **Cluster 3:** alto vigor (pastura sana).
- El algoritmo encuentra los centroides y agrupa los píxeles.
- Resultado: un **mapa temático** con tres zonas de manejo.

Ventajas: No se requiere entrenamiento.

Ideal Clustering

Aplplet para comprender
k-means
K-means Clustering



PCA (Principal Component Analysis)

PCA (Principal Component Analysis o Análisis de Componentes Principales) es una **técnica estadística de reducción de dimensionalidad** que se usa mucho en **machine learning**, y **análisis de datos multivariados**.

- Toma un conjunto de variables originales (muchas veces **correlacionadas**) y las transforma en un **nuevo conjunto de variables** llamadas **componentes principales**.
- Estos **componentes principales**:
 - Son **combinaciones lineales** de las variables originales.
 - Son **no correlacionados entre sí** (transforma a espacios con independencia lineal)
 - Están ordenados según la **cantidad de variabilidad (información)** que explican.
- En pocas palabras: **PCA encuentra nuevas variables (componentes) que resumen la mayor parte de la información de los datos originales, con menos dimensiones.**

PCA (Principal Component Analysis)

Objetivo:

Encontrar proyección lineal que maximice la varianza de los datos proyectados o minimice el error de reconstrucción.

Formulación:

Datos: Matrix $X \in R^{n \times d}$ (n muestras, d dimensiones)

1. Centrado de datos:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$$

Donde $X_c = X - \bar{X}$

PCA (Principal Component Analysis)

- Matriz de covarianza:

$$C = \frac{1}{n-1} X_c^T X_c$$

- Descomposición espectral:

$$C = V \Lambda V^T$$

Donde:

V = matriz de vectores propios (componentes principales)

Λ = matriz diagonal de valores propios $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$

PCA (Principal Component Analysis)

Proyección

Reducción a k dimensiones:

$$Y = X_c V_k$$

Donde V_k contiene los primeros k vectores propios.

Tenemos la varianza:

$$\text{Var}_k = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^d \lambda_i}$$

Error de reconstrucción:

$$E = \|X_c - X_c V_k V_k^T\|_F^2 = \sum_{i=k+1}^d \lambda_i$$

PCA (Principal Component Analysis)

Problema de optimización

$$V_{max} Tr(V^T C V) \text{ s. t. } V^T V = I$$

- Componentes principales = V
- Valores propios = $\frac{\sigma_i^2}{n-1} n$

Pasos para implementar el PCA

- **Estandarizar los datos** (si las variables tienen diferentes escalas).
- **Calcular la matriz de covarianza** entre las variables.
- **Obtener valores propios y vectores propios (autovalores y autovectores)**.
 - Cada autovalor indica cuánta varianza explica el componente.
 - Cada autovector define la dirección del nuevo componente.
- **Ordenar los componentes principales** de mayor a menor varianza explicada.
- **Proyectar los datos originales** en el nuevo espacio de componentes.

Ejemplo

Imagina que mides en cada parcela:

- NDVI (índice de vegetación).
- EVI (índice mejorado de vegetación).
- Humedad del suelo.
- Temperatura superficial.
- Reflectancia en bandas espectrales (azul, verde, rojo, NIR).
- Estos datos pueden estar muy correlacionados (ej. NDVI y EVI).

Ejemplo PCA

Con **PCA**:

- Reduces todas esas variables a **2 o 3 componentes principales**.
- Aún así capturas **80-95% de la variabilidad original**.
- Esto permite:
 - **Visualizar mejor los datos** (gráficos 2D o 3D).
 - **Aligerar el cálculo** en algoritmos de machine learning.
 - **Eliminar redundancia** entre variables.
- Ejemplo práctico: aplicar PCA a imágenes hiperespectrales (200+ bandas) para resumirlas en 3 componentes y generar un **mapa RGB sintético** que concentre la mayor parte de la información.

PCA y cambio de bases en espacios vectoriales

PCA (Análisis de Componentes Principales) es justamente un cambio de base en el espacio de los datos. 😊

¿Cómo se entiende el cambio de base en PCA?

- Tienes tus datos originales en una base formada por las **variables originales** (ej: NDVI, humedad, temperatura, bandas espectrales, etc.).
- PCA calcula los **autovectores de la matriz de covarianza**, que forman una **nueva base ortogonal** (perpendicular entre sí). Osea un nuevo subespacio vectorial con unos autovectores (matriz de covarianza) y autovalores (λ)
- Luego proyecta los datos en esta nueva base.

Es decir:

- Las **direcciones principales** (componentes) son **autovectores**.
- La **importancia de cada dirección** (cuánta varianza explica) está dada por los **autovalores**.

Analogía geométrica PCA

Imagina una nube de puntos en 2D:

- Eje X = NDVI
- Eje Y = humedad

La nube no está alineada con los ejes, sino inclinada.

PCA rota el sistema de coordenadas para que el **primer eje (PC1)** quede alineado con la dirección donde los datos tienen mayor dispersión (varianza). El **segundo eje (PC2)** es ortogonal al primero y explica la segunda mayor parte de la variabilidad.

Así, PCA = **rotación del sistema de referencia** para que los datos se expliquen mejor en menos dimensiones.

Conexión con el Algebra Lineal

Sí, PCA = cambio de base:


$$X \rightarrow Z = X * W$$

X datos originales.

W : matriz de autovectores (la nueva base).

Z : datos en la nueva base (componentes principales).

PCA es un cambio de base hacia una base ortogonal formada por las direcciones de máxima varianza de los datos.



XGBoost

- **XGBoost (Extreme Gradient Boosting)** es una implementación optimizada del algoritmo **Gradient Boosting**, basada en **árboles de decisión**.
- Es muy usado en **regresión, clasificación y ranking**.
- Destaca por su **velocidad, precisión y capacidad de manejar grandes volúmenes de datos**.

Como funciona XGBoost

- Se construye un **conjunto (ensemble)** de **árboles de decisión débiles** (shallow trees).
- Cada árbol **corrige los errores del anterior**.
- Al final, las predicciones de todos los árboles se **suman** para dar el resultado.
- Es como un equipo de expertos: cada árbol aprende de los errores de los anteriores.

Diferencia con Random Forest

- Random Forest: construye muchos árboles independientes y combina resultados (promedio o mayoría).
- XGBoost: construye los árboles de manera secuencial, cada uno aprendiendo de los errores del anterior (boosting).

Ventajas de XGBoost sobre Random Forest

- Muy preciso
- Maneja datos faltantes.
- Optimizado para velocidad y memoria.
- Tiene regularización (L1, L2) → evita sobreajuste.
- Funciona bien en datasets tabulares (ej. datos climáticos + espectrales + suelos).

Matemática de XGBoost

Función objetivo

$$\mathcal{L} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k)$$

Donde

l = función de pérdida

$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2$ (*función de regularización*)

T = número de hojas

ω_j es el peso de la hoja

Matemática de XGBoost

$$\hat{y}_i^t = \hat{y}_i^{t-1} + f_t(x_i)$$

Objetivo en la iteración t, luego de reemplazar los términos:

$$L(t) \approx \sum [l(\hat{y}_i^t, \hat{y}_i^{t-1}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t)$$

D

$$g_i = \frac{\partial l(\hat{y}_i^t, \hat{y}_i^{t-1})}{\partial \hat{y}_i^{t-1}} \text{ (gradiente)}$$

$$h_i = \frac{\partial^2 l(\hat{y}_i^t, \hat{y}_i^{t-1})}{\partial \hat{y}_i^{(t-1)^2}} \text{ (hessiano)}$$

Matemática de XGBoost

- Optimización del Árbol
- Peso óptimo por hoja j:

- $\omega_j = - \frac{G_j}{H_j + \lambda}$

Donde:

- G_j suma de gradientes
- H_j suma de hessianos


Matemática de XGBoost

- η (learning rate): escala
- λ (L2 regularización en pesos)
- γ (penalización por complejidad del árbol)
- max_depth: profundidad máxima
- min_child_weight: H mínimo en nodo hoja


Interpretación

- El modelo aprende relaciones **no lineales** entre NDVI, clima y biomasa.
- El gráfico de **importancia de variables** indica cuáles influyen más (ej. NDVI y precipitación suelen ser dominantes).
- Métricas como **MAE, RMSE y R^2** permiten evaluar la calidad de la predicción.

tree1



tree2



Applet para XGBoost

XGBoost - Gradient Boosting Visualizado



$$f(\text{boy}) = 2 + 0.9 = 2.9$$



$$f(\text{old man}) = -1 + 0.9 = -0.1$$

Qué son los hiperparámetros en ML

- En **machine learning**, los **hiperparámetros** son parámetros que **no se aprenden automáticamente del entrenamiento**, sino que **tú los defines antes de entrenar el modelo** y controlan el comportamiento del algoritmo de aprendizaje.
- **Parámetros**: valores aprendidos por el modelo durante el entrenamiento (por ejemplo, los coeficientes β en una regresión lineal, o los pesos en una red neuronal).
- **Hiperparámetros**: valores definidos por el usuario para guiar cómo se entrenan los parámetros (ejemplo: número de árboles en un Random Forest, tasa de aprendizaje en XGBoost, número de clusters en K-means).

Ejemplos de hiperparámetros en distintos algoritmos

Regresión lineal / LASSO / Ridge:

- Coeficiente de regularización (α o λ) o L1 o L2.

Árboles de decisión / Random Forest:

- Profundidad máxima del árbol (max_depth).
- Número de árboles (n_estimators).
- Número mínimo de muestras por hoja (min_samples_leaf).

XGBoost / Gradient Boosting:

- Tasa de aprendizaje (learning_rate).
- Número de iteraciones (n_estimators).
- Profundidad máxima (max_depth).

Ejemplos de hiperparámetros en distintos algoritmos

K-means:

- Número de clusters (k).
- Número de iteraciones máximas.

SVM (Support Vector Machine):

- Parámetro de penalización (C).
- Tipo de kernel (linear, rbf, poly).
- Parámetro gamma en kernels no lineales.

Ajuste de hiperparámetros

- Para encontrar los valores óptimos se usan técnicas como:
- **Grid Search:** probar combinaciones de hiperparámetros en una cuadrícula.
- **Random Search:** probar combinaciones aleatorias.
- **Bayesian Optimization / AutoML:** búsqueda más inteligente y automática.

Underfitting y overfitting

Underfitting (subajuste)

Ocurre cuando el modelo **es demasiado simple** para capturar la complejidad de los datos.

- El modelo **no aprende lo suficiente** y tiene un **bajo rendimiento tanto en entrenamiento como en validación/prueba**.
- Ejemplo: usar una **regresión lineal simple** para predecir el crecimiento de un cultivo que depende de múltiples variables (clima, suelo, riego, fertilización, etc.). El modelo no logra adaptarse.

Síntomas:

- Error alto en entrenamiento y validación.

Underfitting y overfitting


Overfitting (sobreajuste)

- Ocurre cuando el modelo **es demasiado complejo** y se adapta **excesivamente a los datos de entrenamiento**, incluyendo ruido y patrones irrelevantes.
- El modelo **memoriza** en vez de generalizar, por lo que funciona muy bien en entrenamiento pero **falla con datos nuevos**.
- Ejemplo: un **Random Forest con demasiados árboles profundos** que predice perfectamente el rendimiento de pasto en el conjunto de entrenamiento, pero da valores erráticos con nuevas parcelas.

Síntomas:

- Error muy bajo en entrenamiento, pero alto en validación/prueba.
- Gran diferencia entre desempeño en train y test.

Underfitting y overfitting



Tratamiento de datos para machine learning

1. Revisión inicial de los datos

Explorar el dataset: mirar filas, columnas, tipos de variables (numéricas, categóricas, fechas, texto).

Buscar valores nulos o faltantes (NaN).

Detectar valores atípicos (outliers) con boxplots o reglas estadísticas.

Revisar la distribución de cada variable (histogramas, densidad).

Tratamiento de datos para machine learning

2. Limpieza de datos

Manejo de valores faltantes:

Imputación con la media, mediana o moda.

Imputación con modelos (ejemplo: KNNImputer).

Eliminar registros/columnas si hay demasiados nulos.

Tratamiento de outliers:

Recortar valores extremos.

Aplicar transformaciones (log, sqrt).

Usar métodos robustos a outliers (ejemplo: MAE en vez de MSE).

Eliminar duplicados de registros.

Tratamiento de datos para machine learning

3. Transformación de variables

Normalización o estandarización

Cuando los algoritmos son sensibles a escalas: K-means, PCA, SVM, redes neuronales

Normalización (0–1): MinMaxScaler.

Estandarización (media 0, varianza 1): StandardScaler.

Codificación de variables categóricas:

One-Hot Encoding (para variables sin orden).

Label Encoding (para variables ordinales).

Ingeniería de características:

Crear nuevas variables derivadas (ejemplo: de una fecha → día, mes, año, estación).

Reducir dimensionalidad con **PCA** o selección de características.

Tratamiento de datos para machine learning

4. División del dataset

Separar en **train/test** (70-30, 80-20, etc.).

Usar **validación cruzada (Cross-Validation)** para evaluar de forma robusta.

En series de tiempo usar **TimeSeriesSplit** (manteniendo el orden).

Tratamiento de datos para machine learning

5. Balanceo de clases (solo clasificación)

Si el dataset está desbalanceado (ejemplo: 95% clase A, 5% clase B):

Oversampling: SMOTE (sintético).

Undersampling: reducir la clase mayoritaria.

Class Weights: darle más peso a las clases minoritarias.

Tratamiento de datos para machine learning

6. Preparación final

Guardar los datos transformados con joblib o pickle para reproducibilidad (librería sk-learn de Python)

Documentar los pasos aplicados (pipeline).

Usar Pipeline de sklearn para automatizar transformaciones y entrenamiento.



Códigos bases

En repositorio (IntroML)

0- Preprocesamiento

1- Código para comprensión de overfitting y underfitting

2 – Código de regresión lineal simple

3- Código de regresión lineal LASSO, ElasticNet y Ridge

5- Random Forest - Regresión

6- Random Forest - Clasificación

6- PCA

7-kmeanns

8-XGBoost regresión

9-XGBoost clasificación

10-Red Neuronal-KERAS

Librerías para machine learning en Python

Tratamiento y manipulación de datos

- **pandas** → Manejo de DataFrames (tablas), limpieza, transformación.
- **numpy** → Operaciones numéricas y álgebra lineal eficiente.

Estadística y análisis

- **scipy** → Estadística, optimización, transformadas y más.
- **statsmodels** → Modelos estadísticos clásicos (regresión lineal, ANOVA, series de tiempo).

Librerías para machine learning en Python



Visualización

- **matplotlib** → Gráficos básicos y personalizables.
- **seaborn** → Visualización estadística más estilizada (basada en matplotlib).
- **plotly** → Gráficos interactivos.


Machine Learning (para ir más allá)

- **scikit-learn** → Modelado, clasificación, regresión, clustering.
- **tensorflow / keras** → Redes neuronales y deep learning.
- **pytorch** → Alternativa muy popular para deep learning.

Librerías de Python



Entornos de operación de Python



Del píxel al insight: La clave está en que cada transformación (dato→información→aprendizaje→conocimiento) no es automática sino que requiere modelos, contexto y validación para generar valor real.

El código se convirtió en el lenguaje perfecto para entrenar IAs: estructurado como las matemáticas, abundante como el texto, y valioso como el oro, el mundo vive un momento único donde la tecnología, demanda y capital convergieron perfectamente.

CONTENIDO

1. Fundamentos de teledetección

2. Imágenes pasivas

3. Imágenes activas



CONTENIDO

1. Fundamentos de teledetección


2. Imágenes pasivas

3. Imágenes activas




MODULO 2

IMÁGENES PASIVAS



¿Qué es un sensor óptico pasivo?

Un **sensor óptico pasivo** capta la **radiación solar reflejada** por la vegetación, el suelo, el agua, etc., o la **radiación térmica emitida naturalmente** por los objetos. Se usan ampliamente en satélites, drones y aviones para obtener imágenes multispectrales, hiperespectrales o térmicas.



Tipos de sensores pasivos

Tipo de sensor	Qué detecta	Ejemplos de sensores / plataformas
Multiespectral	Varias bandas del espectro visible e infrarrojo cercano (VIS, NIR, SWIR)	MSI (Sentinel-2), OLI (Landsat), Micasense (drones)
Hiperespectral	Decenas a cientos de bandas estrechas	AVIRIS, PRISMA, sensores científicos como espectrometros
Térmico (IR)	Radiación infrarroja emitida por objetos (calor)	TIRS (Landsat), cámaras térmicas FLIR
RGB (color)	Tres bandas visibles (rojo, verde, azul)	Cámaras digitales comunes

Características de sensores pasivos



Resolución espectral: número y ancho de bandas (más bandas = más precisión espectral).



Resolución espacial: tamaño mínimo de píxel observado (de cm a cientos de m).



Resolución temporal: frecuencia con que se adquieren datos del mismo sitio.

Tipos de sensores pasivos y plataformas

Sensor	Plataforma	Tipo	Resolución espacial
MSI	Sentinel-2	Multiespectral	10–60 m
OLI/TIRS	Landsat 8/9	Multiespectral + térmico	15–100 m
MODIS	Terra/Aqua	Multiespectral	250–1000 m
AVIRIS	Avión	Hiperespectral	5–20 m
Micasense RedEdge	Drone	Multiespectral	<10 cm

Limitaciones



Dependen de **luz solar** → no operan de noche.




Sensibles a nubes y atmósfera → requieren corrección atmosférica.




La calidad de los datos puede verse afectada por **sombra, humedad, y ángulos de observación**.

Sensores multispectral (pasivo)




Sensores multispectral (pasivo)



► Nuevas opciones para la cámara multispectral RedEdge de MicaSense – TYC GIS – GIS, Teledetección y Drones

► Detección en bandas ópticas discretas de gran ancho spectral.

Sensores multispectral (pasivo)




► De 2 a 10- 20 longitudes de onda. De 36-40 longitudes de onda asumida por algunos autores.

► Poseen filtros ópticos espectrales de 10 – 20 nm que captan “bandas de longitudes de onda”.

► Estan portados en cámaras multispectrales comerciales, satélites como el Landsat 8, Sentinel 2 se basan en tecnología multispectral.

Sensores hiperespectral (pasivo)




- ▶ Mas de 20 longitudes de onda, y hasta centenas-
- ▶ Filtros ópticos espectrales menores a 5 nm
- ▶ Cámaras hiperespectrales y espectrómetros son equipos de tecnología hiperespectral
 - ▶ [Tecnología hiperespectral ¿qué es? - ATRIA Innovation](#)


Sensor multispectral vs. hiperspectral

► Diferencias entre tecnología multispectral e hiperspectral

► [Hiperspectral Y Multispectral: Diferencias Entre Ambas \(eos.com\)](#)



Sensor multispectral vs. hiperespectral



이미지 출처: <https://www.nireos.com/hyperspectral-imaging/>

►Diferencias entre tecnología multispectral e hiperespectral

►[art_16384297261981_679853.jpg \(795x405\) \(hellot.net\)](http://art.16384297261981_679853.jpg(795x405)(hellot.net))


Imágenes visibles y de infrarojo (IR)

Cámara del Mavic 3

Cámara del Matrice – Parrot Sequoia

Manejo de Aplicación HYPERSELLITE Y
OPTIFORRAJE


Imágenes visibles y de infrarojo (IR)



Cámaras visibles RGB


ALMACENAMIENTO COMPUTACIONAL
(Ejemplo de Python que indica los tres (3) valores R-G-B)

Cámara RGB (Captura en visible)



Qué es el FOV (Focal Angle of View) y el “Focal Length”

Focal Length and Angle of View



The greater the focal length, the closer the image and the less the angle of view
The less the focal length, the farther the image and the greater the angle of view

Comparación entre ambas tecnologías

- Cámaras (dispositivos electrónicos) para la detección de la reflectancia en ciertas longitudes de onda óptica.
- Determinación de índices de interés en el análisis del estado de cultivos; por ejemplo **NDVI**, **NDRE**, entre otros.

Tecnología
Multiespectral

- Cámaras para la detección de la reflectancia en un espectro de longitudes de onda óptica.
- Imágenes y registros de bandas de longitudes de onda para la diferenciación de enfermedades en cultivos a partir de determinar la banda discriminante (firma espectral)

Tecnología
Hiperespectral

Comparación entre ambas tecnologías

- Detección de valor de reflectancia en cada coordenada (x,y) por longitud de onda ($\lambda_1, \lambda_2...$)

Tecnología
Multiespectral

- Detección de valor de reflectancia en cada coordenada (x,y) por bandas de longitudes de onda ($\Delta\lambda$):
Espectros Ópticos

Tecnología
Hiperespectral






Figura 2: Fluido biológico al microscopio
(Fuente: Headwall Photonics)

Cámaras Multiespectrales



Cámara Hiperespectral





Multispectral Images
From 2 to 10 bands




Hyperspectral Images
Hundreds of bands

xiSPEC hyperspectral

2Mpix multi-linescan
470-900nm

[Learn more](#)




AGROSAVIA
Corporación colombiana de investigación agropecuaria




Tamaño de los sensores (cámaras)

Camera Sensor



Espectro de la luz solar



► Ejemplo típico del espectro de luz solar disponible en la región VIS y NIR. Un ángulo cenital solar de 45°. La integral de toda la curva de la irradiación solar a la distancia media Tierra-Sol (fuera de la atmósfera de la Tierra) 1370 $W \cdot m^{-2}$.

Imágenes visible e infrarojo

► Comparación de una fotografía VIS convencional (a) y su correspondiente fotografía NIR (b) de la misma escena grabada poco después, como se puede ver desde las sombras. Aparece vegetación verde espectacularmente brillante en el NIR y el contraste entre el cielo y las nubes es mucho mayor en comparación con a la fotografía del VIS. [The physics of near-infrared photography - IOPscience](#)



(a)



(b)

Imágenes visibles y de infrarojo (IR)





(a)



(b)

► Otra escena urbana en VIS (a) y NIR (b) que muestra el mismo efecto de dispersión brillante de vegetación en el NIR. Nótese de nuevo el contraste del cielo y también las diferencias de reflexión en las ventanas de la casa a mano derecha.



Imágenes visibles y de infrarojo (IR)



Espectro de sensibilidad típico de un fotodiodo de silicio (según Hamamatsu S 2386). b) Espectros de eficiencia cuántica típicos de los modernos conjuntos de plano focal CCD utilizados en los sistemas modernos de cámaras. La mayoría de las cámaras tienen sensores CCD con iluminación frontal menos costosa, mientras que las cámaras científicas especializadas utilizan los sensores CCD retroiluminados más eficientes. (c) Sensibilidad típica del detector de una cámara réflex digital Canon EOS 450 sin un filtro de bloqueo de infrarrojos

Imágenes visibles y de infrarojo (IR)

(a) Ejemplo de dos espectros de transmisión para los típicos filtros de bloqueo de infrarrojos utilizados en cámaras. (b) Transmisión típica de filtros de transmisión NIR, es decir, filtros de bloqueo VIS. (c) Filtros de bloqueo VIS (izquierda) y de bloqueo NIR (Izquierda)



► Imágenes de una botella y un vaso llenos de vino tinto grabadas solo para VIS light (izquierda), enteras rango VIS y NIR (medio) e IR solamente (derecha).

Imágenes visibles y de infrarojo (IR)



Imágenes visibles y de infrarojo (IR)

Ejemplo de una imagen NIR de las piernas de una mujer que muestra claramente las venas de abajo la superficie de la piel. Estos no se podían ver fácilmente en el VIS.





RGB Camera	
Sensor	4/3 CMOS; Effective pixels: 20 MP
Lens	FOV: 84° Format Equivalent: 24 mm Aperture: f/2.8-f/11 Focus: 1 m to ∞ (with autofocus)
ISO Range	100-6400
Shutter Speed	Electronic shutter: 8-1/8000 s Mechanical shutter: 8-1/2000 s
Max Image Size	5280×3956
Photo Shooting Mode	Single shot: 20 MP Timed: 20 MP JPEG: 0.7/1/2/3/5/7/10/15/20/30/60 s JPEG + RAW: 3/5/7/10/15/20/30/60 s Panorama: 20 MP (raw image)
Video Encoding and Resolution	H.264 4K: 3840×2160@30fps FHD: 1920×1080@30fps
Video Bitrate	4K: 130Mbps FHD: 70Mbps
Photo Format	JPEG/DNG (RAW)
Video Format	MP4 (MPEG-4 AVC/H.264)
Supported File System	exFAT
Digital Zoom	8x
Multispectral Camera	
Sensor	1/2.8" CMOS; Effective pixels: 5 MP
Lens	FOV: 73.91° Format Equivalent: 25 mm Aperture: f/2.0 Focus: N/A
Narrow Band Filter	Green (G): 560±16 nm, Red (R): 650±16 nm, Red edge (RE): 730±16 nm, Near-infrared (NIR): 860±26 nm
Gain Range	1x-32x
Shutter Speed	Electronic shutter: 1/30-1/12800 s



Cámaras de drones comerciales

Max Image Size	2592×1944
Photo Shooting Mode	Single shot: 5 MP Timed: 5 MP TIFF: 2/3/5/7/10/15/20/30/60 s
Video Encoding and Resolution	H.264 FHD: 1920×1080@30fps Video content: NDVI/GNDVI/NDRE
Video Bitrate	Stream 60Mbps
Photo Format	TIFF
Video Format	MP4 (MPEG-4 AVC/H.264)
Sensing	
Type	Omnidirectional binocular vision system, supplemented with an infrared sensor at the bottom of the aircraft.
Forward	Measurement Range: 0.5-20 m Detection Range: 0.5-200 m Effective Sensing Speed: Flight Speed ≤15 m/s FOV: Horizontal 90°, Vertical 103°
Backward	Measurement Range: 0.5-16 m Effective Sensing Speed: Flight Speed ≤12 m/s FOV: Horizontal 90°, Vertical 103°
Lateral	Measurement Range: 0.5-25 m Effective Sensing Speed: Flight Speed ≤15 m/s FOV: Horizontal 90°, Vertical 85°
Upward	Measurement Range: 0.2-10 m Effective Sensing Speed: Flight Speed ≤6 m/s FOV: Front and Back 100°, Left and Right 90°
Downward	Measurement Range: 0.3-18 m Effective Sensing Speed: Flight Speed ≤6 m/s FOV: Front and Back 130°, Left and Right 160°
Operating Environment	Forward, Backward, Lateral, and Upward: surface with a clear pattern and adequate lighting (lux >15) Downward: diffuse reflective surface with diffuse reflectivity>20% (e.g. walls, trees, people) and adequate lighting (lux >15)
Video Transmission	
Video Transmission System	DJI O3 Enterprise Transmission
Live View Quality	Remote Controller: 1080p/30fps
Operating Frequency ^[2]	2.400-2.4835 GHz, 5.725-5.850 GHz
Transmitter Power (EIRP)	2.4 GHz: <33 dBm (FCC), <20 dBm (CE/SRRC/MIC) 5.8 GHz: <33 dBm (FCC), <14 dBm (CE), <30 dBm (SRRC)
Max Transmission Distance (unobstructed, free of interference) ^[3]	15 km (FCC), 8 km (CE/SRRC/MIC)

Cámara de DJI Mavic 3M

Cámara del Matrice – RedEdge de MICASENSE



Peso:	231.9 g
Dimensiones:	8.7cm x 5.9cm x 4.54cm
Poder externo:	4.2 V DC – 15.6 V DC
Bandas espectrales	Azul, verde, rojo, borde rojo, cerca de IR (obturador global, banda estrecha)
Salida de color RGB:	Obturador global, alineado con todas las bandas.
Distancia de muestra en el suelo (GSD):	8 cm por píxel (por banda) a 120 m (~ 400 pies) AGL
Velocidad de captura:	1 captura por segundo (todas las bandas), RAW de 12 bits
Interfaces:	Serial, Ethernet 10/100/1000, Wi-Fi extraíble, disparador externo, GPS, SDHC
Campo de visión:	47.2 ° HFOV
Opciones de activación:	Modo de temporizador, modo de superposición, modo de disparo externo (PWM, GPIO, serie y opciones de Ethernet), modo de captura manual

Peso:	231.9 g
Dimensiones:	8.7cm x 5.9cm x 4.54cm
Poder externo:	4.2 V DC – 15.6 V DC
Bandas espectrales	Azul, verde, rojo, borde rojo, cerca de IR (obturador global, banda estrecha)
Salida de color RGB:	Obturador global, alineado con todas las bandas.
Distancia de muestra en el suelo (GSD):	8 cm por píxel (por banda) a 120 m (~ 400 pies) AGL
Velocidad de captura:	1 captura por segundo (todas las bandas), RAW de 12 bits
Interfaces:	Serial, Ethernet 10/100/1000, Wi-Fi extraíble, disparador externo, GPS, SDHC
Campo de visión:	47.2 ° HFOV
Opciones de activación:	Modo de temporizador, modo de superposición, modo de disparo externo (PWM, GPIO, serie y opciones de Ethernet), modo de captura manual

Cámara del Matrice – RedEdge de MICASENSE

Preprocesamiento

Correcciones radiométricas, atmosféricas y geométricas





Correcciones radiométricas,
atmosféricas y geométricas

Las **correcciones radiométricas, atmosféricas y geométricas** son procesos fundamentales en **teledetección** que se aplican a las imágenes obtenidas por sensores remotos (drones, satélites, aviones) para asegurar que los datos reflejen **valores reales y comparables** de la superficie terrestre.

Corrección radiométrica

Ajusta las imágenes para eliminar **errores del sensor y condiciones de iluminación** (como variación solar), garantizando que los valores digitales (DN o reflectancia) sean consistentes.

¿Corrige?

- Ruido del sensor.
- Diferencias de ganancia entre bandas.
- Efectos de sombra o sobreexposición.

Resultado:

- Produce una imagen con **valores radiométricos corregidos** listos para conversión a **reflectancia a través de blancos de calibración**.

Corrección atmosférica

Elimina los efectos de la **atmósfera** (absorción, dispersión, humedad, aerosoles) sobre la radiación captada por el sensor. Sin esta corrección, los valores de reflectancia no representan la superficie real.

¿Corrige?

- Efecto de gases como vapor de agua, ozono.
- Dispersión de Rayleigh y Mie (nubes, polvo).
- Variación atmosférica entre fechas o lugares.

Resultado:

- Obtención de la **reflectancia de superficie real**
→ base para comparar imágenes en el tiempo o calcular índices como **NDVI, EVI, SAVI** de forma confiable.

Corrección atmosférica

Herramientas comunes:

- **SEN2COR** (Sentinel-2)
- **QUAC, FLAASH** (ENVI)
- **ACOLITE** (para aguas)
- **DOS (Dark Object Subtraction)** – método empírico

Corrección geométrica

Corrige errores de **posición espacial** y **distorsión geográfica**, asegurando que cada píxel esté alineado correctamente con su ubicación real en la Tierra.

¿Corrige?

- Movimiento del satélite o dron.
- Curvatura terrestre.
- Rotación, inclinación y ángulo del sensor.
- Variaciones topográficas (relieve).

Resultado:

- Imágenes **georreferenciadas y ortorrectificadas**, listas para análisis GIS, comparación multitemporal o fusión con otros datos (como mapas de suelo o clima).

Importancia de las correcciones

- Comparar imágenes en el tiempo (series temporales).
- Calcular índices espectrales (NDVI, etc.) con precisión.
- Integrar imágenes con datos de campo o de otras plataformas (drones, sensores espectrales).






Composición de bandas e índices espectrales


NDVI, NDWI, SAVI, etc.



¿De donde proviene el concepto físico de índice de vegetación?



¿De donde proviene el concepto físico de índice de vegetación?




Ejemplo de espectro típico de reflectancia mostrando el comportamiento de una planta vigorosa y otra en condiciones de estrés. *Fuente: CIMMYT.*

NDVI: Normalized Difference Vegetation Index.


NIR=Infrarrojo cercano (850 nm) y Red: Rojo (650 nm).

Índice de la salud de la planta




$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}}$$

(Fuente: <http://odis.ca/ndvi.html>)



NDVI

¿De donde proviene el concepto físico de índice de vegetación?



NDRE: Normalized Difference Red Edge. NIR=Infrarojo Lejano (850 nm) y RE: Red Edge (715 nm).



Medida de la cantidad de Clorofila

$$NDRE = \frac{(NIR - RE)}{(NIR + RE)}$$

Ejemplo de espectro típico de reflectancia mostrando el comportamiento de una planta vigorosa y otra en condiciones de estrés. *Fuente: CIMMYT.*



$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}}$$



Generación de imágenes de índices de vegetación




IMAGEN NIR (850 nm)





IMAGEN RED (650 nm)



NDVI(650 nm)

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

Generación de imágenes multispectrales en software libre Python a partir de imágenes de reflectancia calibradas con blanco de reflectancia

Indices de Vegetación

Nota: ρ son las bandas espectrales de las bandas de luz infrarroja cercana (NIR), roja, verde y azul, respectivamente; ρ_i denota reflectancia en la longitud de onda de la banda i en nanómetros.

Vegetation Index	Formulas
Three gradient difference vegetation index (TGDVI)	$TGDVI = \frac{\rho_{NIR} - \rho_R}{\lambda_{NIR} - \lambda_R} - \frac{\rho_R - \rho_G}{\lambda_R - \lambda_G}$
Triangular vegetation index (TVI)	$TVI = 60(\rho_{NIR} - \rho_G) - 100(\rho_R - \rho_G)$
Modified triangular vegetation index (MTVI2)	$MTVI2 = \frac{1.5[(1.2(\rho_{NIR} - \rho_G) - 2.5(\rho_R - \rho_G))]}{\sqrt{(2\rho_{NIR} + 1)^2 - (6\rho_{NIR} - 5\sqrt{\rho_R})} - 0.5}$
Red edge NDVI	$NDVI_{Red-edge} = \frac{\rho_{NIR} - \rho_{Red-edge}}{\rho_{NIR} + \rho_{Red-edge}}$
Red-edge chlorophyll index	$CI_{Red-edge} = \frac{\rho_{NIR}}{\rho_{Red-edge}} - 1$
MERIS Terrestrial Chlorophyll Index	$MTCI = \frac{\rho_{NIR} - \rho_{Red-edge}}{\rho_{Red-edge} - \rho_{Red}}$
Water Index (WI)	$WI = \rho_{900} / \rho_{970}$
Normalized difference water index (NDWI)	$NDWI = \frac{\rho_{860} - \rho_{1240}}{\rho_{860} + \rho_{1240}}$
Normalized difference infrared index (NDII)	$NDII = \frac{\rho_{819} - \rho_{1600}}{\rho_{819} + \rho_{1600}}$
Disease water stress index (DSWI)	$DSWI = \frac{\rho_{803} + \rho_{549}}{\rho_{1659} + \rho_{681}}$

Indices de Vegetación

Nota: ρ son las bandas espectrales de las bandas de luz infrarroja cercana (NIR), roja, verde y azul, respectivamente; ρ_i denota reflectancia en la longitud de onda de la banda i en nanómetros.

Vegetation Index	Formulas
Three gradient difference vegetation index (TGDVI)	$TGDVI = \frac{\rho_{NIR} - \rho_R}{\lambda_{NIR} - \lambda_R} - \frac{\rho_R - \rho_G}{\lambda_R - \lambda_G}$
Triangular vegetation index (TVI)	$TVI = 60(\rho_{NIR} - \rho_G) - 100(\rho_R - \rho_G)$
Modified triangular vegetation index (MTVI2)	$MTVI2 = \frac{1.5[(1.2(\rho_{NIR} - \rho_G) - 2.5(\rho_R - \rho_G))]}{\sqrt{(2\rho_{NIR} + 1)^2 - (6\rho_{NIR} - 5\sqrt{\rho_R}) - 0.5}}$
Red edge NDVI	$NDVI_{Red-edge} = \frac{\rho_{NIR} - \rho_{Red-edge}}{\rho_{NIR} + \rho_{Red-edge}}$
Red-edge chlorophyll index	$CI_{Red-edge} = \frac{\rho_{NIR}}{\rho_{Red-edge}} - 1$
MERIS Terrestrial Chlorophyll Index	$MTCI = \frac{\rho_{NIR} - \rho_{Red-edge}}{\rho_{Red-edge} - \rho_{Red}}$
Water Index (WI)	$WI = \rho_{900} / \rho_{970}$
Normalized difference water index (NDWI)	$NDWI = \frac{\rho_{860} - \rho_{1240}}{\rho_{860} + \rho_{1240}}$
Normalized difference infrared index (NDII)	$NDII = \frac{\rho_{819} - \rho_{1600}}{\rho_{819} + \rho_{1600}}$
Disease water stress index (DSWI)	$DSWI = \frac{\rho_{803} + \rho_{549}}{\rho_{1659} + \rho_{681}}$

Indices de Vegetación

Table 3. Vegetation indices compiled from the literature.

Vegetation Index	Formulas
Atmospherically-resistant vegetation index (ARVI)	$ARVI = \frac{\rho_{NIR} - RB}{\rho_{NIR} + RB}$ $RB = R - \gamma(B - R), \gamma = 1$
Difference vegetation index (DVI)	$DVI = \rho_{NIR} - \rho_R$
Enhanced vegetation index (EVI)	$EVI = 2.5 \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + 6\rho_R - 7.5\rho_B + 1}$
Green normalized difference vegetation index (GNDVI)	$GNDVI = \frac{\rho_{NIR} - \rho_G}{\rho_{NIR} + \rho_G}$
Modified nonlinear vegetation index (MNLI)	$MNLI = \frac{1.5(\rho_{NIR}^2 - \rho_R)}{\rho_{NIR}^2 + \rho_R + 0.5}$
The second modified SAVI (MSAVI2)	$MSAVI2 = \frac{2\rho_{NIR} + 1 - \sqrt{(2\rho_{NIR} + 1)^2 - 8(\rho_{NIR} - \rho_R)}}{2}$
Modified simple ratio (MSR)	$MSR = \frac{\rho_{NIR}/\rho_R - 1}{\sqrt{\rho_{NIR}/\rho_R + 1}}$
Normalized difference vegetation index (NDVI)	$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}$
Nonlinear vegetation index (NLI)	$NLI = \frac{\rho_{NIR}^2 - \rho_R}{\rho_{NIR}^2 + \rho_R}$

Optimization of soil-adjusted vegetation index (OSAVI)	$OSAVI = (1 + 0.16) \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R + 0.16}$
Renormalized difference vegetation index (RDVI)	$RDVI = \frac{\rho_{NIR} - \rho_R}{\sqrt{\rho_{NIR} + \rho_R}}$
Ratio vegetation index (RVI)	$RVI = \frac{\rho_{NIR}}{\rho_R}$
Soil-adjusted vegetation index (SAVI)	$SAVI = \frac{\rho_{NIR} - \rho_R}{(\rho_{NIR} + \rho_R + L)} (1 + L), L = 0.5$

IDB - List of available Indices

¿Cómo usar las imágenes del Sentinel 2 para que sean procesadas e interpretadas de manera rápida por personal no experto?



EQUIPO DE TRABAJO

THOMAS GOMEZ SERPA

Es un estudiante de matemáticas y física en la Universidad de los Andes en Colombia. También conocido en GitHub por su nombre de usuario Ratabart666 [Ratabart666](#) ([GitHub](#)). Programador de proyecto HYPERCORN adaptando algoritmos de procesamiento de imágenes multiespectrales y procesamiento de espectros en Python. Su interés es la física teórica, física matemática, modelación matemática y ciencias computacionales. Aspira a ser doctor en Física y empresario de proyectos digitales en Inteligencia Artificial para agricultura.

Autor de App HYPERSATELLITE y OPTIFORRAJE



EQUIPO DE TRABAJO


ANDRES FELIPE MENDOZA

Es un estudiante Ingeniería de Sistema en la Universidad de los Andes en Colombia. También conocido en GitHub por su nombre de usuario gordosaurio [gordosaurio \(github.com\)](https://github.com/gordosaurio); desarrollando proyectos Web y proyectos de transacciones financieras. Es programador de HYPERCORN creando backend, base de datos y frontend. Intereses en programación y arquitectura de software.

Autor de App HYPERSATELLITE



ARQUITECTURA



Versatilidad de la arquitectura



Modelos de machine learning para la estimación de parámetros relevantes en cultivos.



Análisis y procesamiento online de imágenes.



Detección de vegetación, seguimiento de deforestación y evolución de zonas verdes, detección de zonas con agua, seguimiento de emisiones.



Promoción de la conectividad para la gestión agrícola.

Espectroradiómetros (sensores proximales)

MODEL	PSR-1100f	RS-3500	PSR+	RS-8800	NaturaSpec	NaturaSpec Ultra
						
	· Smallest and lightest portable instrument · Spectral range is ideal for vegetation and water analysis · Internal memory – no need for external PC to operate · Tripod mountable · Compatible with all fore optics and accessories	· Tried and true full-range model · Standard spectral resolution · Lightweight and portable for field research · Compatible with all fore optics and accessories	· Lightest, most portable full-range instrument · Internal memory & onboard controls - no need for external PC to operate · Option for direct attach lens or fiber optic · Tripod mountable · Compatible with all fore optics and accessories	· Built-in computer with IoT operating system to control instrument with smartphone · See field of view in real-time & record GPS, distance to target, solar elevation angle, and capture picture of fov with exclusive accessory Sensaprobe™ · Compatible with all fore optics and accessories	· Best signal to noise compromise in a field instrument · High resolution & sensitivity · Better data quality of any field spectrometer · The new standard for remote sensing	· The highest spectral resolution of any field spectroradiometer · Enables field validation and calibration of even the highest resolution hyperspectral cameras and satellites by bringing lab quality hyperspectral data into the field. · The optimum instrument to build high-resolution libraries and to push the limits of spectral analysis
Spectral Range	320-1100nm	350-2500nm	350-2500nm	350-2500nm	350-2500nm	350-2500nm
Spectral Resolution	3.0nm@600nm	2.8nm@700nm 8nm@1500nm 6nm@2100nm	2.8nm@700nm 8nm@1500nm 6nm@2100nm	3nm@700nm 8nm@1500nm 6nm@2100nm	2.7nm@700nm 5.5nm@1500nm 5.8nm@2100nm	1.5nm@700nm 3nm@1500nm 3.8nm@2100nm
Detector(s)	512-element Si Array	512-element Si Array Two 256-element TE-cooled InGaAs Arrays	512-element Si Array Two 256-element TE-cooled InGaAs Arrays	512-element Si Array Two 256-element TE-cooled InGaAs Arrays	1024-element UV-enhanced Si Array 512-element TE-cooled InGaAs Array 512-element extended TE-cooled InGaAs Arrays	1024-element UV-enhanced Si Array 512-element TE-cooled InGaAs Array 512-element extended TE-cooled InGaAs Arrays

Espectrómetro OCEAN INSIGHT

Ocean Optics. Espectrómetro SR-4VN500-25. SR4 es altamente configurable, con modelos que cubren diferentes rangos de longitud de onda desde aproximadamente 190-1100 nm y opciones de ranura de entrada en anchos de 5 μm a 200 μm . SR4 demuestra resultados efectivos para aplicaciones que van desde la medición de picos espectrales distintos dentro de plasmas y fuentes de emisión hasta la detección de cambios sutiles en la absorbancia en ADN, proteínas y otras muestras biológicas.



- Rango de longitud de onda: 190nm - 1,04 μm
- Longitud de onda del resplandor: 500 nm
- Resolución óptica: 1,2 nm
- Píxeles: 3648
- Ranura de entrada: 25 μm . Ref:SR-4VN500-25

Ref: SR-4VN500-25

Espectrómetro OCEAN INSIGHT

Ocean Optics. Estándar de reflectancia difusa, PTFE. El WS-1 utiliza un difusor óptico de PTFE, un material lambertiano que se distingue por su acabado blanco mate y una reflectividad >98 % entre 250 y 1500 nm y >95 % entre 250 y 2200 nm. Ref: WS-1.



Espectrómetro OCEA INSIGHT

Ocean Optics. Fibra óptica resistente a la solarización. Nuestros ensambles de fibra óptica de primera calidad son latiguillos duraderos y de alta calidad que brindan resultados uniformes con una variación mínima de la señal. Los latiguillos de primera calidad actúan como fibras de iluminación y lectura y se conectan fácilmente a los espectrómetros, fuentes de luz y accesorios de muestreo Ocean Insight.



- Rango de longitud de onda: 200 nm - 1,1 μ m
- Tamaño del núcleo de fibra: 600 μ m
- Longitud: 2 m
- Recubrimiento: acero inoxidable BX

Ref: QP600-2-SR-BX


Espectrómetro OCEAN INSIGHT

Ocean Optics. Juego de tubos Gershun. El Gershun Tube Kit es un conjunto óptico que se conecta a un espectrómetro o fibra óptica con terminación SMA 905 para controlar el FOV de la configuración. Cada conjunto comprende una base cónica y cilindros central y externo que se enroscan entre sí. Se pueden instalar aperturas intercambiables por el usuario para ajustar el FOV en diferentes incrementos de 1° a 28°.



- Conector: espectrómetro o fibra óptica con terminación SMA 905
- Material: Aluminio anodizado negro

Ref:GER-KIT



Espectrómetro OCEAN
INSIGHT para
adquisición de firmas
espectrales – Espectro
de Reflectancia

An aerial photograph of a vast agricultural landscape. The foreground and middle ground are dominated by long, straight rows of crops, likely corn or a similar grain, planted in a grid-like pattern. A small, dark-colored building or shed is visible near the bottom center of the frame. In the background, a range of mountains stretches across the horizon under a sky with scattered white clouds. The entire image has a green color overlay.

Ejemplos

Teledetección práctica

Ejemplos de teledetección

Descarga de imágenes de Sentinel-2 con GEE: (Google Earth Engine): *vía web*

Generación de índices de vegetación con imágenes satelitales usando QGIS: *Programa gratuito de escritorio*

Descarga de imágenes de Sentinel-2 desde Copernicus: *vía web*

Usando EO Browser (web gratuita, visual e intuitiva) de Sentinel-2: *vía web.*

Generación de imágenes de índice de vegetación usando imágenes de Sentinel-2 + Python

Corrección atmosférica de Sentinel-2 con SEN2COR

Descarga de imágenes satelitales desde Sentinel-2 usando Python: *librería sentinelsat y GeoPandas*

Generación de shapefiles (.shp y otros) usando Python y desde GEE

MODIS

Google Earth Engine (GEE)

Descargando Imágenes de Sentinel - 2



Google Earth Engine (GEE) - MISIONES

1. NASA / USGS

- **Landsat 1-9:** Monitoreo terrestre desde 1972 hasta la actualidad (30 m resolución desde Landsat 4).
- **MODIS (Terra y Aqua):** Datos globales diarios desde 1999 (250 m - 1 km resolución).
- **ASTER:** Datos de elevación y multiespectrales (15 m - 90 m).

ESA (Agencia Espacial Europea)

- **Sentinel-1:** Radar de apertura sintética (SAR), activo, desde 2014.
- **Sentinel-2:** Imágenes multiespectrales ópticas (10-60 m), desde 2015.
- **Sentinel-3:** Datos oceánicos y atmosféricos.

Google Earth Engine (GEE)

- GEE no tiene un número fijo, pero integra datos de más de 40 sensores satelitales diferentes.
- Puedes acceder a más de 100 datasets satelitales en su catálogo oficial: <https://developers.google.com/earth-engine/datasets?hl=es-419>

Google Earth Engine (GEE)

Nombre	Agencia	Tipo de sensor	Resolución (m)	Frecuencia	Desde
Landsat 8/9	NASA/USGS	Óptico (OLI/TIRS)	30 (óptico), 100 (TIRS)	Cada 16 días	2013 / 2021
Landsat 7	NASA/USGS	Óptico (ETM+)	30	Cada 16 días	1999
MODIS (Terra/Aqua)	NASA	Óptico / Térmico	250 – 1000	Diaria	1999 / 2002
Sentinel-1	ESA	Radar SAR C-band	10 – 40	Cada 6 días (par)	2014
Sentinel-2	ESA	Óptico multiespectral (MSI)	10 – 60	Cada 5 días	2015
Sentinel-3	ESA	Óptico y térmico	300 – 1200	Diaria	2016
ASTER	NASA/JAXA	Óptico multiespectral	15 – 90	Variable	1999
ALOS-1/2	JAXA	Radar PALSAR L-band	10 – 100	Variable	2006 / 2014
VIIRS	NOAA/NASA	Óptico / Térmico	375 – 750	Diaria	2011
GOES	NOAA	Geoestacionario (óptico)	500 – 1000	Cada 15 min	2016
Himawari-8	JMA	Geoestacionario (óptico)	500 – 2000	Cada 10 min	2015

Descarga de imágenes de Sentinel-2

- Google Earth Engine (GEE) – Plataforma en la nube, sin necesidad de descargar imágenes.
- Ventajas: Gratuito
- Procesamiento en la nube
- Acceso a todas las imágenes de Sentinel-2 desde 2015
- Ideal para series temporales o análisis por zonas.
- Paso a paso para calcular NDVI:
 - Crea una cuenta: <https://signup.earthengine.google.com>
 - Abre el Code Editor: <https://code.earthengine.google.com>
 - Copia y pega este script básico (**B4 = Rojo, B8 = Infrarrojo cercano**)

Descarga de imágenes de Sentinel-2 (Código en JavaScript)

// 1. Define tu zona de estudio (puedes usar un shapefile o coordenadas)

```
var zona = ee.Geometry.Rectangle([-75.9, 8.9, -75.8, 9.0]); //
ejemplo: Cereté, Córdoba
```

// 2. Carga colección Sentinel-2

```
var coleccion = ee.ImageCollection('COPERNICUS/S2_SR')
  .filterBounds(zona)
  .filterDate('2023-01-01', '2023-12-31')
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
  .median();
```

// 3. Calcula NDVI = (NIR - Red) / (NIR + Red)

```
var ndvi = coleccion.normalizedDifference(['B8',
'B4']).rename('NDVI');
```

// 4. Visualización

```
Map.centerObject(zona, 12);
Map.addLayer(ndvi, {min: -1, max: 1, palette: ['red', 'yellow',
'green']}, 'NDVI');
```

// 5. Exportar (opcional)

```
Export.image.toDrive({
  image: ndvi,
  description: 'NDVI_Sentinel2',
  scale: 10,
  region: zona,
  maxPixels: 1e9
});
```

1-descargarNDVISentineltoDrive

Descarga de imágenes de Sentinel-2

- La imagen aparecerá en tu Google Drive 'NDVI_Sentinel2' en formato .tif.
- Si no la puedes visualizar puedes cargarla en Python.
- Puedes exportar también bandas individuales (B2, B3, B4, B8...) o mosaicos multibanda.

En Google Earth Engine “COPERNICUS/S2_SR” corresponde al Sentinel-2 L2A con corrección atmosférica aplicada.

Descarga de imágenes de Sentinel-2 (Serie mensual)

// 1. Definir el área de interés (puedes usar tus propias coordenadas o shapefile)

```
var aoi = ee.Geometry.Rectangle([-75.9, 8.8, -75.7, 9.0]); //  
Ejemplo en Córdoba, Colombia
```

// 2. Definir el rango de fechas (ejemplo: marzo 2024)

```
var start = '2024-03-01';
```

```
var end = '2024-03-31';
```

// 3. Cargar Sentinel-2 nivel 2A (con corrección atmosférica)

```
var s2 = ee.ImageCollection("COPERNICUS/S2_SR")
```

```
.filterDate(start, end)
```

```
.filterBounds(aoi)
```

```
.filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 20)); // Ajusta  
según tolerancia
```

// 4. Aplicar máscara de nubes usando SCL que hace reconstrucción de la escena

```
function maskClouds(image) {
```

```
  var qa = image.select('SLC');
```

```
  var cloudBitMask = 1 << 10;
```

```
  var cirrusBitMask = 1 << 11;
```

```
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
```

```
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));
```

```
  return image.updateMask(mask).copyProperties(image,  
    ["system:time_start"]);
```

```
}
```

```
var s2Masked = s2.map(maskClouds);
```

Descarga de imágenes de Sentinel-2 (Serie mensual)

// 5. Calcular NDVI y renombrar

```
var withNDVI = s2Masked.map(function(img) {
  var ndvi = img.normalizedDifference(['B8',
  'B4']).rename('NDVI');
  return img.addBands(ndvi);
});
```

// 6. Crear mosaico mensual (mediana)

```
var monthlyNDVI =
withNDVI.select('NDVI').median().clip(aoi);
```

// 7. Visualización en el mapa

```
Map.centerObject(aoi, 12);
Map.addLayer(monthlyNDVI, {min: 0, max: 1, palette:
['white', 'green']}, 'NDVI Marzo 2024');
```

// 8. Exportar a Google Drive

```
Export.image.toDrive({
  image: monthlyNDVI,
  description: 'NDVI_Marzo2024_Mombasa',
  folder: 'GEE_Exports',
  fileNamePrefix: 'NDVI_Marzo2024',
  region: aoi,
  scale: 10,
  crs: 'EPSG:4326',
  maxPixels: 1e13
});
```

2-descargarNDVISentineltoDriveSerieTemp

Como guardar NDVI en formato CSV, no valores nulos por nubosidad

// 1. Área funcional cerca de Cereté

```
var aoi = ee.Geometry.Polygon([
```

```
  [[-75.811, 8.914],
```

```
  [-75.811, 8.902],
```

```
  [-75.794, 8.902],
```

```
  [-75.794, 8.914]]
```

```
]);
```

```
Map.centerObject(aoi, 14);
```

```
Map.addLayer(aoi, {color: 'red'}, 'AOI Cereté');
```

// 2. Función para enmascarar nubes con SCL

```
function maskCloudsSCL(image) {
```

```
  var scl = image.select('SCL');
```

```
  var mask = scl.neq(3).and(scl.neq(8))
```

```
    .and(scl.neq(9)).and(scl.neq(10))
```

```
    .and(scl.neq(11));
```

```
  return image.updateMask(mask);
```

```
}
```

Como guardar NDVI en formato CSV, no valores nulos por nubosidad

// 3. Cargar Sentinel-2 SR y calcular NDVI

```
var s2 = ee.ImageCollection('COPERNICUS/S2_SR')  
  .filterBounds(aoi)  
  .filterDate('2023-01-01', '2023-12-31')  
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 30))  
  .map(maskCloudsSCL)  
  .map(function(img) {  
    var ndvi = img.normalizedDifference(['B8', 'B4']).rename('NDVI');  
    return img.addBands(ndvi);  
  });
```

// 4. Calcular NDVI mensual solo si hay imágenes

```
var months = ee.List.sequence(1, 12);  
  
var ndviByMonth = months.map(function(m) {  
  var monthly = s2.filter(ee.Filter.calendarRange(m, m, 'month'));  
  var count = monthly.size();
```

Como guardar NDVI en formato CSV, no valores nulos por nubosidad

```
// Solo continúa si hay imágenes en ese mes
```

```
return ee.Algorithms.If(
  count.gt(0),
  ee.Feature(null, {
    'mes': m,
    'NDVI': monthly.select('NDVI').mean()
      .reduceRegion({
        reducer: ee.Reducer.mean(),
        geometry: aoi,
        scale: 10,
        maxPixels: 1e13
      }).get('NDVI')
  }),
  null
);
```

```
// 5. Filtrar valores nulos
```

```
var ndviFeatures =
  ee.FeatureCollection(ndviByMonth).filter(ee.Filter.notNull(['NDVI']));
```

```
// 6. Exportar a CSV
```

```
Export.table.toDrive({
  collection: ndviFeatures,
  description: 'NDVI_Cerete_2023_OK',
  fileFormat: 'CSV'
});
```

3-DescargaejemploCSV2NoNulo

Generación Índices de Vegetación con QGIS

Programa gratuito de escritorio para análisis de imágenes satelitales



Generación de Índices de Vegetación con QGIS

Opción 2: QGIS con el plugin Semi-Automatic Classification (SCP)

Ventajas:

- No necesitas programación
- Puedes trabajar sin conexión
- Permite clasificaciones, índices e incluso análisis multitemporales

Paso a paso:

1. Instala QGIS (si no lo tienes):

<https://qgis.org>

2. Activa el plugin SCP:

1. Ve a *Complementos > Administrar e instalar complementos*
2. Busca **Semi-Automatic Classification Plugin** e instálalo

Generación de Índices de Vegetación con QGIS

1. Descarga imágenes Sentinel-2 desde el plugin o desde:

1. <https://dataspace.copernicus.eu>

2. Carga las bandas necesarias (B4 y B8)

3. Calcula el NDVI:

1. En SCP > *Preprocessing* > *Band set*
2. Define las bandas
3. Luego, ve a *Band calc* y usa la fórmula:
$$(B8 - B4) / (B8 + B4)$$

(OPCION 1: ¡Continuamos y volvemos para hacer este proceso!).

Descarga de imágenes satelitales desde Copernicus

Copernicus es una base de datos web desde donde se descargan imágenes del satélite Sentinel-2



¿Cómo descargar desde Copernicus?

1. Entra al portal

- Ve a: <https://dataspace.copernicus.eu/>
- Inicia sesión o crea una cuenta gratuita (necesario para descargar datos) (SENTINEL HUB → Copernicus Browser).

2. Buscar tu área de interés

- Usa el mapa para acercarte a **Cereté, Colombia** (o la zona que desees).
- Dibuja un polígono o cuadrado sobre el área de interés.

¿Cómo descargar desde Copernicus?

3. Filtrar la búsqueda

- En el panel izquierdo:
 - Producto: selecciona **Sentinel-2 L2A** (procesado al nivel de superficie con corrección atmosférica).
 - Fecha: selecciona el rango deseado (por ejemplo: 2023-06-01 a 2023-06-30).
 - Nubes: ajusta a **< 20%** o el umbral que prefieras.
 - Haz clic en "**Search**".

¿Cómo descargar desde Copernicus?

4. Seleccionar una imagen

- Revisa las imágenes encontradas.
- Haz clic en una con baja nubosidad y buena cobertura de tu zona.

5. Descargar el producto

- Haz clic en el botón de descarga:
 - Puedes elegir el producto completo (aprox. 1 GB) o sólo algunas bandas.

Como descargar las bandas B4 y B8 (imágenes satelitales) descargadas desde Copernicus

- Una vez descargado el producto ZIP completo:
- Opción A: Extraer manualmente
- Descomprime el archivo.
- Entra a la carpeta: GRANULE > L2A_Tile_Code > IMG_DATA
- Busca los archivos:
 - Txxxxyy_YYYYMMDDTxxxx_B04_10m.jp2 (B4)
 - Txxxxyy_YYYYMMDDTxxxx_B08_10m.jp2 (B8)
- Puedes abrirlos en QGIS, SNAP o Python (usa rasterio o gdal).
- Opción B: Usar SNAP (opcional! Se verá luego)
- Abre el archivo ZIP directamente en SNAP.
- Visualiza y exporta las bandas deseadas como GeoTIFF.

Generación Índices de Vegetación con QGIS usando archivos .jp2

Programa gratuito de escritorio para análisis de imágenes satelitales

CÓMO CALCULAR NDVI EN QGIS USANDO ARCHIVOS .jp2

1. Abrir QGIS

Asegúrate de tener instalada la versión más reciente de QGIS (preferiblemente 3.22 o superior).

2. Cargar las bandas B4 y B8

Ve a "Capa" > "Añadir capa" > "Añadir capa ráster".

Selecciona el archivo .jp2 correspondiente a la banda B4 (típicamente tiene B04_10m.jp2 en el nombre).

Repite para la banda B8 (B08_10m.jp2).

Verás dos capas separadas en el panel de capas.

3. Asegúrate de que tengan la misma resolución y alineación

Las bandas de Sentinel-2 a 10m suelen coincidir directamente, pero puedes verificarlo:

Haz clic derecho en cada banda > Propiedades > pestaña Información.

Asegúrate de que tengan la misma resolución espacial, sistema de coordenadas y tamaño.

CÓMO CALCULAR NDVI EN QGIS USANDO ARCHIVOS .jp2

4. Calcular NDVI con la Calculadora ráster

Ve a "Procesos" > "Calculadora ráster" o presiona Ctrl+R. (OPCION 2)

1. Asigna un nombre a la capa de salida, por ejemplo: ndvi.tif.

2. En la parte inferior, selecciona el lugar para guardar el archivo.

3. En la expresión, escribe en texto plano en "" los nombres de los archivos

$$("B8@1" - "B4@1") / ("B8@1" + "B4@1")$$

Donde:

"B8@1" es el nombre de la capa de la banda 8 (puede llamarse distinto, revisa el nombre exacto en el panel).

"B4@1" es el nombre de la banda 4.

Si los nombres son diferentes (por ejemplo: B08_10m@1), usa esos nombres exactos.

CÓMO CALCULAR NDVI EN QGIS USANDO ARCHIVOS .jp2

Haz clic en Aceptar.

5. Visualiza y colorea el NDVI

1. Una vez generado, carga el archivo ndvi.tif.
2. En el panel de capas, haz clic derecho > Propiedades > pestaña Simbología.
3. Cambia el tipo a "Renderizado en pseudocolor" y aplica una rampa de color (verde - amarillo - rojo, por ejemplo).
4. Ajusta los valores mínimo y máximo a los esperados (por ejemplo: -1 a 1).

EO Browser de Sentinel-2

(web gratuita (limitada), visual e intuitiva)

Usando EO Browser de Sentinel-2

Ingreso

- Ve a: <https://apps.sentinel-hub.com/eo-browser>

Pasos (EXPIRA EN 30 DIAS)

1. **Sentinel2 Dashboard → EO Browser. Selecciona tu zona de interés** (puedes buscar "Cereté, Colombia" si es tu caso).
2. Escoge el satélite: **Sentinel-2 L2A** (ya corregido atmosféricamente).
3. Define el **rango de fechas** (últimos días/semanas).
4. En "Visualizations", selecciona:
 1. **True Color** para ver imagen natural
 2. **NDVI** para salud vegetal
 3. Puedes crear visualizaciones personalizadas
5. Haz clic en "**Compare**" para ver diferencias entre fechas.
6. Puedes descargar las imágenes o datos NDVI como PNG, GeoTIFF o CSV.

Generación de imágenes de índice de vegetación usando imágenes de Sentinel-2 + Python

(con Google Earth Engine o descarga directa desde Copernicus)

Librerías de Python para procesamiento de imágenes satelitales

1.rasterio:

Propósito: Lectura, escritura y análisis de datos ráster (como imágenes satelitales).

Formatos comunes: GeoTIFF, JPEG2000, entre otros.

Usos típicos:

- Extraer valores de píxeles.
- Leer metadatos geoespaciales.
- Recortar, reproyectar y combinar bandas.

Que son los datos ráster

Los **datos raster** son un tipo de datos geospaciales representados en forma de **rejilla de celdas o píxeles**, donde cada celda tiene un **valor numérico** que representa información sobre una característica del territorio en esa ubicación específica.

- Color (en imágenes satelitales RGB)
- Temperatura
- Altura o elevación (DEM)
- Índice de vegetación (NDVI, SAVI, etc.)

Estructura de un dato ráster

Elemento	Descripción
Píxel	Unidad mínima, cuadrada. Tiene una dimensión espacial (por ejemplo, 10 m).
Resolución	Tamaño real que representa cada píxel en el terreno.
Bandas	Capas del ráster que contienen distintos tipos de información (ej. R, G, B, NIR u otra banda).
Valor	Número o categoría almacenada en cada píxel. Puede ser real, entero o clase. Se refiere al DN

¿Qué representan los datos ráster?

Tipo de ráster	¿Qué representa cada píxel?	Ejemplo
Imágenes satelitales	Intensidad de luz reflejada en diferentes bandas	Sentinel-2, Landsat
Modelos de elevación (DEM)	Altura del terreno sobre el nivel del mar	SRTM, ASTER
Índices de vegetación	Cálculo como NDVI, NDRE, etc.	NDVI generado a partir de bandas
Mapas de temperatura	Temperatura de la superficie o del aire	Datos térmicos
Clasificaciones de uso suelo	Categoría del uso o cobertura del suelo	Bosque, cultivo, agua, etc.

Características de los datos raster

- Resolución espacial: Tamaño del píxel en el terreno. Ej: 10 m (cada píxel representa un área de 10x10 m).
- Extensión: Área total que cubre la imagen.
- Sistema de referencia: Información geográfica como UTM o WGS84.
- Formato común: .tif (GeoTIFF), .img, .asc, etc.

Comparación de datos Raster y Datos Vectoriales

Atributo	Datos Raster	Datos Vectoriales
Forma de almacenamiento	Matriz de valores (rejilla)	Puntos, líneas y polígonos (geometrías)
Ejemplo	Imagen satelital NDVI	Shapefile de parcelas o caminos
Ideal para	Datos continuos (vegetación, elevación)	Datos discretos (parcelas, ríos, árboles)

¿Qué es un GeoTIFF?

- Un GeoTIFF es un archivo .tif o .tiff que no solo contiene una imagen raster, sino también metadatos que describen cómo esa imagen se ubica en el espacio geográfico.

Contenido de un archivo GeoTIFF

Elemento	Descripción
Imagen raster	Datos en píxeles (ej. valores de NDVI, elevación, reflectancia, etc.)
Sistema de coordenadas	Proyección y sistema geodésico (ej. WGS 84, UTM)
Referencia espacial	Coordenadas del borde superior izquierdo y resolución (tamaño del píxel)
Metadata adicional	Nombre del satélite, fecha, bandas, estadísticas, etiquetas, etc.

Formatos comparables con GeoTIFF para almacenar datos ráster georreferenciados

Formato	Descripción breve	Georreferencia	Multibanda	Compresión	Compatibilidad
GeoTIFF	TIFF con metadatos espaciales incrustados	✓ Sí	✓ Sí	✓ Opcional	✓ Muy alta
JPEG2000 (JP2)	Imagen comprimida con soporte de geolocalización	✓ Sí	✓ Sí	✓ Alta	⚠ Media
NetCDF (.nc)	Formato científico multidimensional (tiempo, espacio, altura, etc.)	✓ Sí	✓ Sí	✓ Alta	⚠ Técnica (más en ciencia climática)
HDF5 (.h5/.hdf)	Formato jerárquico para grandes volúmenes de datos científicos (ej. MODIS)	✓ Sí	✓ Sí	✓ Alta	⚠ Técnica
ENVI .hdr/.dat	Propio del software ENVI (metadatos separados en archivo .hdr)	✓ Sí	✓ Sí	✗ No	⚠ Parcial (mejor en ENVI/IDL)
IMG (ERDAS)	Formato raster usado por ERDAS Imagine	✓ Sí	✓ Sí	✓ Alta	⚠ Alta solo en software ESRI/ERDAS
Cloud Optimized GeoTIFF (COG)	Variante de GeoTIFF para la nube, accesible por partes	✓ Sí	✓ Sí	✓ Alta	✓ Muy alta (especialmente en GEE, Python)

Usos de los los formatos geoespaciales

Uso principal

Formato recomendado

Visualización + análisis GIS

GeoTIFF, COG

Grandes volúmenes en
clima/suelo

NetCDF, HDF5

Intercambio web / servicios WMS

JPEG2000, COG

Procesamiento remoto / cloud

COG, NetCDF

Análisis en ENVI

.hdr + .dat

WGS84 – Sistema de Coordenadas Geográficas

(*World Geodetic System 1984*)

Elemento	Descripción
Tipo de sistema	Geográfico (usa latitud y longitud)
Unidades	Grados decimales (°), minutos (′), segundos (″)
Cobertura	Global
Representación	(latitud, longitud) Ej: (8.755°, -75.881°)
Datum	Basado en un elipsoide global, con centro en el centro de la Tierra
Uso común	GPS, mapas web (Google Maps, GEE, Leaflet), sensores satelitales

Ejemplo de un WGS84

- Coordenadas de Montería:
Latitud: 8.75° N
Longitud: 75.88° W
Sistema: **EPSG:4326**

UTM – Universal Transverse Mercator: *Sistema Universal de Coordenadas Transversales de Mercator*

Elemento	Descripción
Tipo de sistema	Proyectado (plano/cartesiano)
Unidades	Metros
Cobertura	Divide el mundo en 60 zonas de 6° de ancho cada una
Representación	(Este, Norte, Zona) Ej: (795412, 968713, Zona 18N)
Datum común	Generalmente usa WGS84 , pero también puede usar otros
Uso común	Cartografía de precisión, topografía, teledetección, SIG locales

Ejemplo

- Coordenadas UTM de Montería (aprox.):
Este (Easting): 795412 m
Norte (Northing): 968713 m
Zona: 18N
Sistema: **EPSG:32618** (WGS84 + UTM zona 18N)

Comparación entre WGS84 Vs. UTM

Característica	WGS84	UTM
Tipo	Geográfico (esférico)	Proyectado (plano)
Coordenadas	Latitud, Longitud	Este (X), Norte (Y), Zona
Unidades	Grados	Metros
Sistema	EPSG:4326	EPSG:32618
Precisión local	Menor	Mayor (útil para distancias/áreas)
Aplicaciones	Navegación global, web	SIG de precisión, mapas impresos

¿Cómo usar uno u otro?

¿Qué estás haciendo?

Recomendado

Visualizar datos globales o usar GPS

WGS84

Calcular áreas, distancias en metros,
topografía

UTM

Trabajar en Google Earth Engine o mapas
web

WGS84

Hacer un análisis SIG local con precisión

UTM

Sistemas adoptados por países

País / Región	Sistema común	EPSG u observación
Colombia	MAGNA-SIRGAS	EPSG:4686 (geográfico), EPSG:9377–9382 (proyectados por zonas UTM)
España	ETRS89 + UTM	EPSG:25828–25831 según zona
Brasil	SIRGAS 2000	EPSG:4674 o proyectado EPSG:31981–31999
Chile	PSAD56 / SIRGAS-Chile	EPSG:24891 o EPSG:5361
México	ITRF92 o NAD27/NAD83 local	Varía por región
Argentina	POSGAR94 / POSGAR07	EPSG:5347–5356
Francia	Lambert 93	EPSG:2154

Cómo identificar un sistema de coordenadas



A través de su **EPSG** (European Petroleum Survey Group), un número único de referencia.



En QGIS o ArcGIS, puedes buscar estos sistemas por nombre o EPSG.



En Python puedes usar pyproj, rasterio, o geopandas para trabajar con sistemas de coordenadas.

Librerías de Python para procesamiento de imágenes satelitales

2. Shapely

- Propósito: Geometría y operaciones espaciales puras (sin datos)
- Usos típicos:
 - Crear puntos, líneas, polígonos.
 - Calcular distancias, áreas, intersecciones.

Librerías de Python para procesamiento de imágenes satelitales

3. *fiona*:

- Propósito: Entrada/salida de archivos vectoriales geográficos (como shapefiles).
- Usos típicos: Trabajar directamente con estructuras tipo diccionario para archivos **.shp**

Librerías de Python para procesamiento de imágenes satelitales

4. Sentinelsat

- Propósito: Búsqueda y descarga de imágenes Sentinel desde Copernicus Open Access Hub.
 - Útil para: Automatizar adquisición de datos satelitales.
- 

Librerías de Python para procesamiento de imágenes satelitales

5. scikit-image o opencv:

- Propósito: Procesamiento de imágenes (aplica también para imágenes satelitales).
 - Usos: Mejora de contraste, filtrado.
 - Clasificación por píxel, segmentación.
- 

Instalar en Visual Studio Code las siguientes librerías

```
pip install rasterio geopandas shapely fiona pyproj xarray rioxarray  
earthpy
```

Programas – Python

Conversores de sistemas geográficos, generación de índices de vegetación usando datos satelitales.

Ejemplo conversión WGS84 (lat/lon) a UTM zona 18N (EPSG:32618)- Python con pyproj

```
from pyproj import Transformer

# Define el transformador de WGS84 a UTM zona 18N
transformer = Transformer.from_crs("EPSG:4326",
    "EPSG:32618", always_xy=True)

# Coordenadas de ejemplo (longitud, latitud)
lon, lat = -75.88, 8.75

# Convertir a UTM
easting, northing = transformer.transform(lon, lat)
print(f"UTM: Este = {easting:.2f}, Norte = {northing:.2f}")
```

Ejemplo conversión inverso UTM a WGS84 con Python con pyproj

```
# Transformador inverso
transformer_inv = Transformer.from_crs("EPSG:32618",
"EPSG:4326", always_xy=True)

# Coordenadas UTM
e, n = 795412, 968713

# Convertir a lat/lon
lon, lat = transformer_inv.transform(e, n)
print(f"WGS84: Lat = {lat:.6f}, Lon = {lon:.6f}")
```

Usando geopandas y shapely – ejemplo de transformación de un punto

```
import geopandas as gpd
from shapely.geometry import Point

# Crear un GeoDataFrame con sistema WGS84
gdf = gpd.GeoDataFrame(geometry=[Point(-75.88,
8.75)], crs="EPSG:4326")

# Convertir a UTM zona 18N
gdf_utm = gdf.to_crs("EPSG:32618")

print(gdf_utm)
```

Generación de imágenes de índice de vegetación usando imágenes de Sentinel-2 + Python

```
import rasterio
import numpy as np
import matplotlib.pyplot as plt
# Carga de bandas NIR (B8) y RED (B4)
with rasterio.open('B08_10m.jp2') as nir:
    nir_band = nir.read(1).astype('float32')
with rasterio.open('B04_10m.jp2') as red:
    red_band = red.read(1).astype('float32')
```

Cálculo NDVI


```
ndvi = (nir_band - red_band) / (nir_band + red_band)
ndvi = np.clip(ndvi, -1, 1)
```

Visualización

```
plt.imshow(ndvi, cmap='RdYlGn')
plt.colorbar(label='NDVI')
plt.title('NDVI Sentinel-2')
plt.show()
```

2-NDVI_Satellite

Resultado de calculo de imagen de índice de vegetación NDVI



Programa 2 – Python

Generación de índices de vegetación usando datos satelitales



Análisis NDVI con Python y Sentinel-2 L2A

```
import rasterio
import numpy as np
import matplotlib.pyplot as plt
from glob import glob
```

```
# Ruta a las bandas de
una imagen Sentinel-2
L2A
```

```
ruta_b4 = 'B04_10m.jp2'
ruta_b8 = 'B08_10m.jp2'
```

```
# Abrir las bandas
with rasterio.open(ruta_b4) as
    src_red:
        red =
        src_red.read(1).astype('float32')
        perfil = src_red.profile
        nodata = src_red.nodata

with rasterio.open(ruta_b8) as
    src_nir:
        nir =
        src_nir.read(1).astype('float32')
```

Análisis NDVI con Python y Sentinel-2 L2A

Manejo de nodata y cálculo del NDVI

```
ndvi = np.where(
    (nir + red) == 0,
    np.nan,
    (nir - red) / (nir + red)
)
```

Actualizar el perfil para guardar el NDVI

```
perfil.update(dtype='float32',
    count=1, nodata=np.nan)
```

Guardar NDVI como GeoTIFF

```
ndvi_scaled = ((ndvi + 1) *
    10000).astype('uint16') # NDVI [-1,1] → [0, 20000]
perfil.update(dtype='uint16',
    count=1)
```


```
with rasterio.open('NDVI.jp2',
    'w', **perfil) as dst:
    dst.write(ndvi_scaled, 1)
```

Análisis NDVI con Python y Sentinel-2 L2A

```
# Visualización
plt.figure(figsize=(10, 6))
ndvi_plot = plt.imshow(ndvi, cmap='RdYlGn', vmin=-1, vmax=1)
plt.colorbar(ndvi_plot, label='NDVI')
plt.title('NDVI Sentinel-2 L2A')
plt.axis('off')
plt.show()
```

3-NDVI_SatelliteV2

Resultado de la ejecución del código



Corrección atmosférica

Con Sen2Cor y SNAP



¿Qué es SEN2Cor?

- La corrección atmosférica con **Sen2Cor** es un proceso que elimina los efectos de la atmósfera (como vapor de agua, aerosoles, gases) en imágenes del satélite Sentinel-2, para obtener reflectancia de superficie (BOA – Bottom of Atmosphere) en lugar de reflectancia en la parte superior de la atmósfera (TOA).
- Sen2Cor es un software oficial de ESA (Agencia Espacial Europea) que convierte productos Sentinel-2 L1C (TOA) en L2A (BOA)
- Google Earth Engine ^(COPERNICUS/S2_SR), OpenEO, EO Browser y MAAP ya incluyen productos L2A generados con Sen2Cor.
- Mejora la precisión radiométrica para cálculos como NDVI (basados en reflectancia), clasificación de cobertura, o modelos de regresión espectral.
- Es esencial cuando necesitas comparabilidad entre fechas, sensores o zonas geográficas.

Las imágenes de Sentinel 2 (L2A) corregidas atmosféricamente

Producto	Tipo de imagen	Corrección atmosférica
L1C	Reflectancia TOA	 No
L2A (con Sen2Cor)	Reflectancia BOA	 Sí (con Sen2Cor)

Corrección atmosférica de Sentinel-2 con SEN2COR

Requisitos previos

1. **Imagen Sentinel-2 nivel 1C** (formato .SAFE) descargada de Copernicus Open Access Hub.

2. Instalación de **SNAP Toolbox** (gratuito) en la web:

https://download.esa.int/step/snap/12.0/installers/esa-snap_all_windows-12.0.0.exe

4. Descargar el plugin en (OPCIÓN 1):

<https://step.esa.int/main/snap-supported-plugins/sen2cor/>

3. Instalación del **plugin Sen2Cor** desde SNAP directamente.



Paso a paso para modulo de corrección atmosférica de imágenes de Sentinel

1. Instala **SNAP** y **Sen2Cor**

- Abre SNAP.
- Ve a: Tools > Plugins.
- En la pestaña **Available Plugins**, busca y selecciona **Sen2Cor**.
- Instálalo y reinicia SNAP.

2. Abre la imagen Sentinel-2

- Ve a File > Open Product y selecciona el archivo .xml dentro de la carpeta .SAFE de tu producto nivel 1C.

Paso a paso para modulo de corrección atmosférica de imágenes de Sentinel

3. Ejecuta Sen2Cor

- Una vez cargada la imagen, ve a: Optical > Thematic Land Processing > Sen2Cor.
- En el cuadro de diálogo:
 - Selecciona el producto.
 - Configura la altura del terreno si es conocida (~50 m para regiones planas, ~200 m si hay colinas o árboles altos).
 - Verifica las opciones de salida (Reflectancia de superficie, mapas de nubes, etc.).

4. Procesamiento

- Sen2Cor generará un producto **nivel**
- 

¿Qué obtienes con el producto L2A?

- **Reflectancia de superficie** por banda (corregida atmosféricamente).
- Máscaras de **nubes, sombras, niebla y clasificación del terreno**.
- Preparado para cálculo de índices como **NDVI, NDRE, SAVI**, y comparación multitemporal.

Estructura de un producto L2A

- S2A_MSIL2A_20240514T151651_N0500_R125_T18NUC_20240514T202321.SAFE/
 - |
 - └─ GRANULE/
 - └─ HTML/
 - └─ AUX_DATA/
 - └─ DATASTRIP/
 - └─ IMG_DATA/ (reflectancia) ← Aquí están los archivos JP2 por banda

Cálculo de NDVI en SNAP (interfaz gráfica)

Requisitos:

- Tener instalada SNAP.
- Haber realizado la **corrección atmosférica** con Sen2Cor.

Pasos:

1. **Abre el producto L2A** (reflectancia de superficie).
2. Ve a Raster > Band Maths.
3. Crea una nueva banda llamada NDVI.
4. En la expresión, escribe:

Cálculo de NDVI en SNAP (interfaz gráfica)

B8 = Banda NIR (842 nm)

B4 = Banda Roja (665 nm)

Asegúrate de marcar:

- Virtual Band = No
- Save to Product = Sí

Da clic en **OK** → SNAP genera el NDVI como una nueva banda.

Puedes visualizarlo, exportarlo a GeoTIFF, o recortarlo por polígonos

Descarga de imágenes satelitales desde Sentinel-2 usando Python

Usando las librerías sentinelsat, geopandas



Descarga de Imágenes satelitales usando la librería *sentinel*sat

```
from sentinelat import SentinelAPI, geojson_to_wkt
from datetime import date
import geopandas as gpd

# --- CREDENCIALES DE ACCESO AL PORTAL COPERNICUS ---
# Puedes registrarte gratis en:
# 'https://scihub.copernicus.eu/dhus
api = SentinelAPI('usuario', 'contraseña',
https://apihub.copernicus.eu/apihub')

# --- LEER SHAPEFILE DE TU ÁREA DE INTERÉS (AOI) ---
gdf = gpd.read_file('parcelas.shp')
aoi = geojson_to_wkt(gdf.__geo_interface__)
```

```
# --- BÚSQUEDA DE PRODUCTOS SENTINEL-2 ---
products = api.query(
    area=aoi,
    date=('20240101', '20240531'), # Rango de fechas: enero a mayo de 2024
    platformname='Sentinel-2',
    producttype='S2MSI2A',      # L2A: corrección atmosférica incluida
    cloudcoverpercentage=(0, 20) # Máximo 20% de nubes
)

# --- IMPRIMIR RESULTADOS ---
print(f"{len(products)} productos encontrados.")
```

Creación de archivos shapefile

```
# Opcional: mostrar info básica de
los productos
for product_id, product_info in
products.items():
    print(f"{product_info['title']} -
{product_info['beginposition']} -
{product_info['cloudcoverpercentage
']}% nubes")

los criterios.")
```

```
# --- DESCARGA DEL PRIMER PRODUCTO ---
# Descargará un archivo .zip en el directorio
actual
if products:
    first_product_id = list(products.keys())[0]
    api.download(first_product_id)
else:
    print("No se encontraron imágenes que
cumplan
```

20-SentinelSaT_Descarga

Creación de shapefiles

Usando las librerías sentinelsat, geopandas, Python y GEE



Creación de archivos shapefile

```
import geopandas as gpd
from shapely.geometry import Polygon

# Coordenadas de ejemplo (LONGITUD,
# LATITUD) - ordenadas en sentido horario
coords = [
    (-75.883, 8.883), # Esquina inferior izquierda
    (-75.870, 8.883), # Esquina inferior derecha
    (-75.870, 8.890), # Esquina superior derecha
    (-75.883, 8.890), # Esquina superior izquierda
    (-75.883, 8.883) # Cerrar el polígono (igual al
    primer punto)
]
```

```
# Crear el polígono
polygon = Polygon(coords)

# Crear GeoDataFrame con el polígono
gdf = gpd.GeoDataFrame({'id': [1]},
    geometry=[polygon], crs='EPSG:4326')

# Guardar como shapefile
gdf.to_file('aoi_parcela.shp')

print("Shapefile 'aoi_parcela.shp' generado con
    éxito.")
```

¿Qué archivos se generan?

aoi_parcela.shp

aoi_parcela.shx

aoi_parcela.dbf

aoi_parcela.cpg

Puedes abrirlo en **QGIS**, **ArcGIS** o usarlo directamente en Python, aunque el mas común es el .shp.

Como generar shapefiles:

- Desde Google Earth o Google Maps: haz clic derecho sobre la zona → "¿Qué hay aquí?".
- Desde QGIS: dibuja el polígono con la herramienta de edición y expórtalo como .shp.
- Desde Sentinel Hub EO Browser: exporta un polígono en formato GeoJSON o KML y conviértelo.

Generar polígonos en GGE

```
// Tu polígono dibujado llamado 'aoi'  
print('Coordenadas del polígono:', aoi.coordinates());  
  
// Exportar el polígono como shapefile (Table)  
Export.table.toDrive({  
  collection: ee.FeatureCollection([ee.Feature(aoi)]),  
  description: 'exportar_aoi',  
  fileFormat: 'SHP'  
});
```

Conversión de GeoJSON a shapefile

```
import geopandas as gpd

# Leer archivo GeoJSON
gdf = gpd.read_file("mi_area.geojson")

# Exportar como Shapefile
gdf.to_file("mi_area_convertido.shp")

print("Conversión GeoJSON → Shapefile completada.")
```

Convertir de KML a Shapefile

- `import geopandas as gpd`
- `# Leer archivo KML (requiere habilitar el driver)`
- `gdf = gpd.read_file("mi_area.kml", driver='KML')`
- `# Exportar como Shapefile`
- `gdf.to_file("mi_area_convertido.shp")`
- `print("Conversión KML → Shapefile completada.")`

Convertir de GPX a Shapefile

```
import geopandas as gpd

# Leer tracks del GPX
gdf = gpd.read_file("mi_ruta.gpx", layer='tracks') # Puedes cambiar a
'waypoints', 'routes'

# Exportar como Shapefile
gdf.to_file("mi_ruta_convertido.shp")

print(" Conversión GPX → Shapefile completada.")
```

¿Cómo se consiguen estos archivos?

- **GeoJSON:** Puedes exportarlos desde <https://apps.sentinel-hub.com/eo-browser> o geojson.io.
- **KML/GPX:** Puedes obtenerlos desde Google Earth o aplicaciones de GPS como Garmin o Strava.

En Google Earth Engine (GEE) código de Java

```
// Tu polígono dibujado llamado 'aoi'  
print('Coordenadas del polígono:', aoi.coordinates());
```

```
// Exportar el polígono como shapefile (Table)  
Export.table.toDrive({  
  collection: ee.FeatureCollection([ee.Feature(aoi)]),  
  description: 'exportar_aoi',  
  fileFormat: 'SHP'  
});
```

En Google Earth Engine (GEE)

- Exporta el área que dibujaste (Hacer click en Task que esta en amarillo)
- Recuerda que los archivos se exportan a tu Drive de Google
- Descarga un .zip con archivos shapefile (.shp, .shx, .dbf, etc.).
- Puedes usarlo directamente con geopandas, sentinelsat, o en QGIS.
- Recuerda que estos archivos se generan en GEE:
<https://code.earthengine.google.com>

MODIS

Imágenes satelitales de alta resolución espectral



MODIS

**MODerate Resolution
Imaging
Spectroradiometer**
(Espectrorradiómetro de
Imágenes de Resolución
Moderada)

Es un sensor a bordo de
dos satélites de la NASA:

- **Terra** (lanzado en 1999)
- **Aqua** (lanzado en 2002)

MODIS

MODIS captura imágenes de **la superficie terrestre, océanos y atmósfera** todos los días, en **36 bandas espectrales** (desde visible hasta infrarrojo térmico).

Mide cosas como:

- Índices de vegetación: **NDVI, EVI**, etc.
 - Temperatura de la superficie.
 - Cobertura de nubes.
 - Uso y cambio del suelo.
 - Fuego y quemas.
 - Biomasa, productividad primaria, etc.
- 

MODIS

Parámetro

Valor

Resolución espacial

250 m, 500 m o 1 km (según banda)

Resolución temporal

1 a 2 días

Cobertura global


Sí (visita toda la Tierra a diario)

Productos de MODIS

Producto	Descripción	Resolución
MOD13Q1	NDVI y EVI (cada 16 días)	250 m
MOD11A2	Temperatura de superficie (8 días)	1 km
MCD12Q1	Clasificación de cobertura del suelo	500 m
MOD15A2H	Índice de área foliar (LAI)	500 m

Donde se obtienen imágenes con MODIS

- Google Earth Engine (muy práctico para procesamiento en la nube).
- NASA LP DAAC (<https://lpdaac.usgs.gov>)
- App MODIS Subsets para descargas por coordenadas.
- Librerías en Python como MODIS, pyModis, o vía earthengine-api.



Cómo obtener con GEE (JavaScript)

```
var aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);
```

```
var modis = ee.ImageCollection("MODIS/006/MOD13Q1")  
  .filterDate('2023-12-01', '2024-03-01')  
  .filterBounds(aoi)  
  .select('NDVI');
```

```
// Mostrar cuántas imágenes hay  
print("Número de imágenes encontradas:", modis.size());
```

```
// Verifica si hay imágenes antes de hacer operaciones  
var imageCount = modis.size();
```

```
var ndvi_mean = ee.Image(ee.Algorithms.If(  
  imageCount.gt(0),  
  modis.mean().clip(aoi),  
  ee.Image(0).rename('NDVI').clip(aoi)  
));
```

```
// Visualizar
```

```
Map.centerObject(aoi, 13);
```

```
Map.addLayer(ndvi_mean, {min: 0, max: 9000, palette: ['white', 'green']},  
'NDVI');
```

```
// Exportar
```

```
Export.image.toDrive({  
  image: ndvi_mean,  
  description: 'NDVI_Export',  
  folder: 'GEE_Exports',  
  region: aoi,  
  scale: 250,  
  fileFormat: 'GeoTIFF'  
});
```

Usando earthengine-api (Google Earth Engine con Python)

Digitar en terminal

```
pip install earthengine-api
```

Se abre

```
earthengine authenticate
```


Usando earthengine-api (Google Earth Engine con Python) en Python

```
import ee

ee.Initialize()

# Área de interés (Turipaná, Córdoba)
aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90])

# Fechas de análisis
start_date = '2024-01-01'
end_date = '2024-03-01'

# Colección MODIS NDVI
modis_ndvi = ee.ImageCollection('MODIS/006/MOD13Q1') \
    .filterDate(start_date, end_date) \
    .filterBounds(aoi) \
    .select('NDVI')

# Validar si hay imágenes disponibles
image_count = modis_ndvi.size().getInfo()

print(f" Número de imágenes encontradas: {image_count}")
```

```
if image_count > 0:

    # Calcular NDVI promedio
    ndvi_composite = modis_ndvi.mean().clip(aoi)

    # Exportar imagen a Google Drive
    task = ee.batch.Export.image.toDrive(
        image=ndvi_composite,
        description='MODIS_NDVI_EneMar2024',
        folder='GEE_Exports',
        fileNamePrefix='NDVI_MODIS_Turipana_2024',
        region=aoi,
        scale=250,
        crs='EPSG:4326',
        maxPixels=1e13
    )
    task.start()
    print("Exportación iniciada a Google Drive.")
else:
    print("No se encontraron imágenes MODIS NDVI para el área y fechas especificadas.")
```

¿Por qué usar MODIS?

- Alta frecuencia temporal (útil para seguimiento).
- Larga serie histórica (desde 2000).
- Cobertura global y gratuita.

Clasificación de imágenes: supervisada y no supervisada

Algoritmos de clasificación de imágenes



¿En qué consiste la clasificación?

La clasificación consiste en la asignación de etiquetas (clases) a cada píxel según sus características espectrales, espaciales y radiométricas. Esta puede hacerse de dos maneras principales:

1. Clasificación Supervisada
2. Clasificación No Supervisada



Clasificación Supervisada

El usuario **entrena** el algoritmo con ejemplos de clases conocidas, como:

- **Bosque**
- **Agua**
- **Cultivos**
- **Urbano**

El algoritmo aprende los patrones espectrales o radiométricos y luego clasifica el resto de la imagen.

Algoritmos comunes

- Random Forest (RF)
- Support Vector Machine (SVM)
- Decisión Tree (Árboles de decisión)
- Redes neuronales (MLP)

Clasificación Supervisada

Ventajas

- Alta precisión si las muestras están bien tomadas
- Control sobre las clases

Desventajas

- Requiere muestras etiquetadas (datos de entrenamiento)
- Sensible a errores en los datos de entrada

Clasificación No Supervisada

El algoritmo **agrupa píxeles sin conocimiento previo** de las clases, basándose solo en similitudes espectrales o radiométricas (clustering).

Algoritmos comunes

- K-means
- ISODATA

Clasificación No Supervisada

Ventajas

- No requiere datos de entrenamiento
- Útil para exploración inicial

Desventajas

- El usuario debe interpretar los grupos resultantes
- Menor precisión
- No garantiza que cada grupo corresponda a una clase real

Comparación entre ambos métodos de clasificación

Característica

¿Requiere muestras?

Supervisada



Sí

No Supervisada



No

¿Precisión?



Alta con buen
entrenamiento



Menor, depende del
agrupamiento

¿Interpretación?

Directa

Necesita análisis posterior

¿Ideal para...?

Clasificación temática
precisa

Exploración preliminar

Clasificación Supervisada con Random Forest y en GEE

1. Carga imágenes Sentinel-2.
2. Aplica enmascarado de nubes.
3. Crea muestras de entrenamiento para 3 clases (bosque, pasto y suelo)
4. Entrena un clasificador (Random Forest).
5. Aplica y visualiza la clasificación.

CLASIFICACIÓN CON RANDOM FOREST

// 1. Área de interés (Turipaná, Córdoba)

```
var aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);
```

```
Map.centerObject(aoi, 14);
```

// 2. Enmascarar nubes y seleccionar solo bandas necesarias

```
function maskS2clouds(image) {
```

```
  var qa = image.select('SCL');
```

```
  var cloudBitMask = 1 << 10;
```

```
  var cirrusBitMask = 1 << 11;
```

```
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
```

```
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));
```

```
  return image.updateMask(mask)
```

```
    .select(['B2', 'B3', 'B4', 'B8']) // Solo las bandas útiles
```

```
    .copyProperties(image, ['system:time_start']);
```

```
}
```

// 3. Cargar imágenes Sentinel-2 SR

```
var s2 = ee.ImageCollection('COPERNICUS/S2_SR')
```

```
  .filterDate('2024-01-01', '2024-03-31')
```

```
  .filterBounds(aoi)
```

```
  .map(maskS2clouds);
```

CLASIFICACIÓN CON RANDOM FOREST

// 4. Crear imagen compuesta (mediana)

```
var composite = s2.median().clip(aoi);
```

// 5. Visualización RGB

```
Map.addLayer(composite, {bands: ['B4', 'B3', 'B2'],  
min: 0, max: 0.3}, 'Sentinel-2 RGB');
```

// 6. Crear muestras de entrenamiento (puedes modificarlas o cargarlas)

```
var bosque = ee.FeatureCollection([  
  ee.Feature(ee.Geometry.Point([-75.88, 8.89]),  
    {'class': 0}),  
  ee.Feature(ee.Geometry.Point([-75.879, 8.891]),  
    {'class': 0})  
]);
```

```
var pasto = ee.FeatureCollection([  
  ee.Feature(ee.Geometry.Point([-75.87, 8.89]),  
    {'class': 1}),  
  ee.Feature(ee.Geometry.Point([-75.871, 8.891]),  
    {'class': 1})  
]);
```

```
var suelo = ee.FeatureCollection([  
  ee.Feature(ee.Geometry.Point([-75.86, 8.89]),  
    {'class': 2}),  
  ee.Feature(ee.Geometry.Point([-75.861, 8.891]),  
    {'class': 2})  
]);
```


CLASIFICACIÓN CON RANDOM FOREST

```
var muestras =  
bosque.merge(pasto).merge(suelo);
```

```
// 7. Tomar muestras de la imagen  
compuesta
```

```
var training =  
composite.sampleRegions({  
  collection: muestras,  
  properties: ['class'],  
  scale: 10  
});
```

```
// 8. Entrenar clasificador Random  
Forest
```

```
var classifier =  
ee.Classifier.smileRandomForest(50).  
train({  
  features: training,  
  classProperty: 'class',  
  inputProperties:  
    composite.bandNames()  
});
```

CLASIFICACIÓN CON RANDOM FOREST

// 9. Clasificar la imagen

```
var classified = composite.classify(classifier);
```

// 10. Visualizar clasificación

```
Map.addLayer(classified,  
  {min: 0, max: 2, palette: ['006400', '7FFF00',  
    'DAA520']},  
  'Clasificación Random Forest');
```

// 11. Exportar la imagen clasificada a Google Drive

```
Export.image.toDrive({  
  image: classified,  
  description: 'Clasificacion_RF_Turipana',  
  folder: 'GEE_Exports', // Cambia si deseas otra  
  carpeta en tu Drive  
  fileNamePrefix: 'clasificacion_turipana_rf_2024',  
  region: aoi,  
  scale: 10,  
  crs: 'EPSG:4326',  
  maxPixels: 1e13  
});
```

Clasificación no Supervisada con k-means

1. Carga imágenes Sentinel-2.
2. Aplica enmascarado de nubes.
3. Clasificación para para 3 clases (bosque, pasto y suelo) según características radiométricas o espectrales
4. Aplica y visualiza la clasificación.



Clasificación no Supervisada con k-means

// 1. Definir el área de interés

```
var aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);  
Map.centerObject(aoi, 14);
```

// 2. Enmascarar nubes y seleccionar bandas útiles

```
function maskS2clouds(image) {  
  var qa = image.select('SCL');  
  var cloudBitMask = 1 << 10;  
  var cirrusBitMask = 1 << 11;  
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)  
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));  
  return image.updateMask(mask)  
    .select(['B2', 'B3', 'B4', 'B8']) // Solo bandas espectrales  
    .copyProperties(image, ['system:time_start']);  
}
```

// 3. Cargar colección Sentinel-2 SR

```
var s2 = ee.ImageCollection('COPERNICUS/S2_SR')  
  .filterDate('2024-01-01', '2024-03-31')  
  .filterBounds(aoi)  
  .map(maskS2clouds);
```

// 4. Crear imagen compuesta

```
var composite = s2.median().clip(aoi);
```

Clasificación no Supervisada con k-means

// 5. Visualización RGB

```
Map.addLayer(composite, {bands: ['B4', 'B3', 'B2'], min: 0, max: 0.3},  
'Sentinel-2 RGB');
```

// 6. Clasificación no supervisada: muestreo y KMeans

```
var training = composite.sample({  
  region: aoi,  
  scale: 10,  
  numPixels: 5000,  
  geometries: true  
});
```

// 7. Entrenar el modelo KMeans con 3 clusters

```
var clusterer = ee.Clusterer.wekaKMeans(3).train(training);
```

// 8. Clasificar la imagen

```
var result = composite.cluster(clusterer);
```

// 9. Visualizar clasificación

```
Map.addLayer(result.randomVisualizer(), {}, 'KMeans - Clusters');
```

Técnicas de Segmentación y Detección de Cambios

Algoritmos de Segmentación



Importancia de la segmentación y detección de cambios

Las **técnicas de segmentación y detección de cambios** son herramientas clave en el análisis de imágenes satelitales, sobre todo para **monitoreo de coberturas, agricultura, gestión forestal y seguimiento de fenómenos ambientales** como la deforestación o sequías

Qué es la segmentación

La **segmentación** consiste en dividir una imagen en regiones homogéneas en función de sus características espectrales, espaciales o temporales. Aquí algunas técnicas comunes:

a) Segmentación por Umbral (Thresholding)

- Se basa en definir un valor límite (por ejemplo, $NDVI > 0.4$) para separar vegetación de no vegetación.
- Muy útil en imágenes NDVI, NDWI, etc.

Qué es la segmentación

b) Crecimiento de Regiones (Region Growing)

Parte de "semillas" que se expanden a píxeles vecinos similares. Más complejo y generalmente aplicado en software como eCognition o Python (OpenCV, scikit-image).

c) Segmentación basada en Objetos (OBIA)

Divide la imagen en objetos geográficos, no solo píxeles. Se usa en plataformas como: eCognition Orfeo Toolbox GEE (limitado con connectedComponents) Python (skimage.segmentation.slic)

d) k-Means y clustering espectral:

Técnicas no supervisadas (útiles como segmentadores de clases espectralmente o radiométricamente homogéneas).

Técnicas de Detección de Cambios

c) Clasificación Post-Clasificación

- Clasificas ambas fechas con Random Forest, luego comparas píxel a píxel los resultados para generar un **mapa de transición**.

d) Cambio basado en aprendizaje automático

- Se usa un modelo supervisado para clasificar tipos de cambio directamente.
- También existen métodos no supervisados como **Change Vector Analysis (CVA)** o **PCA multitemporal**.

Ejemplo de segmentación en GEE

Pasos

- Extrae NDVI desde Sentinel-2.
- Aplica un umbral $\text{NDVI} > 0.5$ para seleccionar vegetación densa.
- Agrupa los píxeles contiguos (4-conectividad) en objetos etiquetados.
- Usa `randomVisualizer()` para visualizar cada parche con color diferente.

¿Qué se puede hacer después?

Exportar cada parche como shapefile. Calcular área, perímetro, NDVI medio por segmento. Usarlo como base para clasificación supervisada basada en objetos.

Ejemplo de segmentación (Umbralización o Thresholding)

```
// 1. Área de interés: Turipaná
var aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);
Map.centerObject(aoi, 15);

// 2. Imagen Sentinel-2, sin nubes
var s2 = ee.ImageCollection('COPERNICUS/S2_SR')
  .filterBounds(aoi)
  .filterDate('2024-01-01', '2024-01-31')
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 10))
  .median()
  .clip(aoi);

// 3. Calcular NDVI
var ndvi = s2.normalizedDifference(['B8', 'B4']).rename('NDVI');
Map.addLayer(ndvi, {min: 0, max: 1, palette: ['white', 'green']}, 'NDVI');

// 4. Umbral para vegetación densa
var vegetacion = ndvi.gt(0.5).selfMask();
```

```
// 4. Umbral para vegetación densa
var vegetacion = ndvi.gt(0.5).selfMask();

// 5. Preparar imagen binaria (necesaria para segmentar)
var binaria = vegetacion.rename('binary');

// 6. Segmentar usando connectedComponents
var segmentos = binaria.connectedComponents({
  connectedness: ee.Kernel.plus(1), // conectividad 4
  maxSize: 128
});

// 7. Visualizar etiquetas de segmentos
var etiquetas = segmentos.select('labels');
var visual = etiquetas.randomVisualizer();
Map.addLayer(visual, {}, 'Segmentos de vegetación');
```


Detección de cambios y mapas de post-clasificación

- Un ejemplo en GEE con **detección de cambio NDVI** entre dos fechas.
- O cómo hacer un **mapa de transición post-clasificación**.



Código de detección de cambios

```
// 1. Área de interés: Turipaná  
var aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);  
Map.centerObject(aoi, 14);
```

```
// 2. Función para enmascarar nubes en Sentinel-2  
function maskS2clouds(image) {  
  var qa = image.select('QA60');  
  var cloudBitMask = 1 << 10;  
  var cirrusBitMask = 1 << 11;  
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)  
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));  
  return image.updateMask(mask)  
    .select(['B8', 'B4']); // B8 = NIR, B4 = Red  
}
```

```
// 3. Colecciones multitemporales  
var s2_2023 = ee.ImageCollection('COPERNICUS/S2_SR')  
  .filterDate('2023-01-01', '2023-01-31')  
  .filterBounds(aoi)  
  .map(maskS2clouds)  
  .median()  
  .clip(aoi);  
  
var s2_2024 = ee.ImageCollection('COPERNICUS/S2_SR')  
  .filterDate('2024-01-01', '2024-01-31')  
  .filterBounds(aoi)  
  .map(maskS2clouds)  
  .median()  
  .clip(aoi);
```

Código de detección de cambios

// 4. Calcular NDVI

```
function calcNDVI(image) {  
  return image.normalizedDifference(['B8',  
  'B4']).rename('NDVI');  
}
```

```
var ndvi_2023 = calcNDVI(s2_2023);
```

```
var ndvi_2024 = calcNDVI(s2_2024);
```

// 5. Calcular cambio de NDVI

```
var cambioNDVI =  
ndvi_2024.subtract(ndvi_2023).rename('C  
ambioNDVI');
```

// 6. Visualización

```
Map.addLayer(ndvi_2023, {min: 0, max: 1, palette:  
['white', 'green']}, 'NDVI 2023');
```

```
Map.addLayer(ndvi_2024, {min: 0, max: 1, palette:  
['white', 'darkgreen']}, 'NDVI 2024');
```

```
Map.addLayer(cambioNDVI, {min: -0.5, max: 0.5,  
palette: ['red', 'white', 'blue']}, 'Cambio NDVI');
```

// 7. Umbralizar pérdida y ganancia

```
var perdida = cambioNDVI.lt(-0.1);
```

```
var ganancia = cambioNDVI.gt(0.1);
```

```
Map.addLayer(perdida.updateMask(perdida),  
{palette: ['red']}, 'Pérdida Vegetación');
```

```
Map.addLayer(ganancia.updateMask(ganancia),  
{palette: ['blue']}, 'Ganancia Vegetación');
```

Código de detección de cambios

```
Export.image.toDrive({  
  image: cambioNDVI,  
  description: 'Cambio_NDVI_Ene2023_2024',  
  folder: 'GEE_Exports',  
  scale: 10,  
  region: aoi,  
  fileFormat: 'GeoTIFF'  
});
```

Ejemplo de detección de cambios con MODIS para cambios mas grandes

```
// 1. Área de interés en EPSG:4326 (lat/lon)
```

```
var aoi4326 = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);
```

```
Map.centerObject(aoi4326, 13);
```

```
// 2. Cargar NDVI MODIS
```

```
var modis = ee.ImageCollection('MODIS/006/MOD13Q1')
```

```
.filterDate('2023-01-01', '2024-01-01')
```

```
.filterBounds(aoi4326)
```

```
.select('NDVI');
```

```
// 3. Escalar NDVI
```

```
var modisNDVI = modis.map(function(img) {
```

```
  return img.multiply(0.0001).copyProperties(img,  
    ['system:time_start']);
```

```
});
```

```
// 4. Obtener proyección MODIS y transformar AOI con tolerancia
```

```
var sampleImage = modis.first();
```

```
var modisProjection = sampleImage.projection();
```

```
var aoiReprojected = aoi4326.transform(modisProjection, 100); //  
Tolerancia de 100 m
```

Ejemplo de detección de cambios con MODIS para cambios mas grandes

```
// 5. Gráfico serie temporal
var chart = ui.Chart.image.series({
  imageCollection: modisNDVI,
  region: aoiReprojected,
  reducer: ee.Reducer.mean(),
  scale: 250,
  xProperty: 'system:time_start'
}).setOptions({
  title: 'Serie Temporal de NDVI MODIS (2023)',
  hAxis: {title: 'Fecha'},
  vAxis: {title: 'NDVI (0 - 1)'},
  lineWidth: 2,
  pointSize: 4
});
```

```
print(chart);

// 6. Visualizar última imagen
var ultima = modisNDVI.sort('system:time_start', false).first();
Map.addLayer(ultima, {min: 0, max: 1, palette: ['white', 'green']}, 'NDVI última imagen');
```


Fusión de Imágenes y Multitemporalidad

Mejorando la interpretación, clasificación y monitoreo de fenómenos a lo largo del tiempo.



Fusión de imágenes

La **fusión de imágenes (image fusion)** es el proceso de **combinar información de múltiples imágenes** (pueden ser de diferentes sensores, resoluciones o fechas) para generar una nueva imagen **más informativa o útil**.

Tipos de fusiones



Fusión espacial:

Combina imágenes de baja resolución espacial (e.g., MODIS) con imágenes de alta resolución (e.g., Sentinel-2).



Fusión espectral:

Integra bandas de diferentes sensores o longitudes de onda (e.g., visible + infrarrojo térmico).

Ejemplo: *Pan-sharpening*, que mejora la resolución espacial de una imagen multiespectral usando una banda pancromática



Fusión temporal:

Une imágenes tomadas en diferentes fechas para mejorar la continuidad de observación (útil cuando hay nubes).



Fusión de sensores:

MODIS + Sentinel + Landsat, por ejemplo, para tener mejor frecuencia temporal o espectral.

Característica de una banda pancromática

- Alta resolución espacial: detecta detalles más finos del terreno. Por ejemplo, la banda pancromática del satélite Landsat 8 tiene una resolución de 15 metros, mientras que sus bandas multispectrales tienen 30 metros.
 - Amplio espectro: integra varias longitudes de onda visibles (como azul, verde y rojo) y a veces parte del infrarrojo cercano, pero no permite distinguir colores.
 - Imagen en escala de grises: registra variaciones en la reflectancia total como intensidades de gris.
- 

Banda pancromática (*Pan-sharpening*)

La banda pancromática es una banda espectral que captura imágenes en blanco y negro (escala de grises), combinando un amplio rango de longitudes de onda del espectro visible (y a veces parte del infrarrojo cercano). Su principal característica es que ofrece una resolución espacial más alta que las bandas multispectrales del mismo satélite.

Aplicaciones



Fusión de imágenes (pan-sharpening): se combina la banda pancromática con las bandas multiespectrales para mejorar la resolución espacial de las imágenes a color.



Detección de detalles urbanos o agrícolas finos: caminos, techos, surcos, etc.



Análisis temporal con alta resolución cuando no se requiere información espectral precisa.

Bandas pancromáticas en Satélites

Ejemplo:

- **Satélite Landsat 8**
 - Banda Pancromática (Banda 8)
 - Resolución: 15 m
 - Rango espectral: 0.50 – 0.68 μm

Bandas pancromáticas en Satélites

En la banda pancromática, no se combinan directamente las bandas multispectrales existentes, sino que el sensor captura directamente una sola imagen en blanco y negro (escala de grises), usando una banda ancha del espectro electromagnético.

Sin embargo, la intensidad (nivel de gris) de cada píxel en la banda pancromática depende de la cantidad total de radiación reflejada dentro del rango espectral específico de la banda pancromática.

¿Cómo se calcula el nivel de energía captado por la banda pancromática?

No se calcula como suma de otras bandas como el rojo, verde y azul, sino que el sensor mide la energía total reflejada en un rango amplio (por ejemplo, de 0.5 a 0.68 μm en Landsat 8).

Cada píxel representa la cantidad de energía que llega al sensor dentro de ese rango.

Esa energía se convierte en un valor digital (Digital Number, DN) proporcional a la reflectancia.

Multitemporalidad

- La multitemporalidad en imágenes satelitales se refiere al uso de imágenes adquiridas en diferentes momentos del tiempo para observar y analizar cambios, patrones o dinámicas.
- Aplicaciones: Detección de cambios (deforestación, expansión urbana, sequías). Monitoreo agrícola (NDVI a lo largo del ciclo fenológico). Análisis estacional (variaciones entre épocas húmedas y secas). Evaluación de recuperación ambiental tras incendios o inundaciones.

Uso de GEE y Python

- En Google Earth Engine, usas `.filterDate()` y `.map()` para construir colecciones multitemporales.
- En Python, puedes usar librerías como rasterio, xarray, geopandas o PyModis para manejar datos multitemporales y combinarlos.

Ejemplo de fusión y multitemporalidad

1. Análisis multitemporal mensual de NDVI con MODIS.
2. Fusión MODIS (temporal) + Sentinel-2 (espacial).

Código GEE en JavaScript- Paso 1 para generar serie multitemporal con MODIS

```
// Área de interés: Turipaná, Córdoba
var aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);
Map.centerObject(aoi, 13);

// Cargar colección MODIS NDVI
var modis = ee.ImageCollection('MODIS/006/MOD13Q1')
  .filterBounds(aoi)
  .filterDate('2023-01-01', '2023-12-31')
  .select('NDVI');

// Crear lista de imágenes mensuales, ignorando meses sin datos
var listaMensual = ee.List.sequence(1, 12).map(function(mes) {
  var mensual = modis.filter(ee.Filter.calendarRange(mes, mes, 'month'));
  var count = mensual.size();
```

```
// Si hay imágenes, promediarlas y
devolver imagen NDVI escalada
return ee.Algorithms.If(
  count.gt(0),
  mensual.mean()
    .multiply(0.0001)
    .set('month', mes)
    .set('system:time_start',
      ee.Date.fromYMD(2023, mes, 1).millis()),
  null // Ignorar si no hay imágenes
);
});
```

Código GEE en JavaScript- Paso 1 para generar serie multitemporal con MODIS

```
// Eliminar elementos nulos y convertir a ImageCollection  
var mensual =  
ee.ImageCollection(ee.List(listaMensual).removeAll([null]));
```

```
// Gráfico NDVI mensual  
var chart = ui.Chart.image.series({  
  imageCollection: mensual,  
  region: aoi,  
  reducer: ee.Reducer.mean(),  
  scale: 250  
}).setOptions({  
  title: 'NDVI Mensual MODIS 2023 (Turipaná)',  
  hAxis: {title: 'Mes'},  
  vAxis: {title: 'NDVI (0 - 1)'}  
});  
print(chart);
```

Código completo de fusión y multitemporalidad en JavaScript para GEE

```
// =====  
// 1. Definir área de interés  
// =====  
var aoi = ee.Geometry.Rectangle([-75.89, 8.88, -75.86, 8.90]);  
Map.centerObject(aoi, 13);  
  
// =====  
// 2. Serie mensual MODIS NDVI 2023  
// =====  
  
var modis = ee.ImageCollection('MODIS/006/MOD13Q1')  
  .filterBounds(aoi)  
  .filterDate('2023-01-01', '2023-12-31')  
  .select('NDVI');
```

```
// Generar colección mensual (con control de errores)  
var listaMensual = ee.List.sequence(1, 12).map(function(mes) {  
  var mensual = modis.filter(ee.Filter.calendarRange(mes, mes, 'month'));  
  var count = mensual.size();  
  return ee.Algorithms.If(  
    count.gt(0),  
    mensual.mean()  
      .multiply(0.0001)  
      .set('month', mes)  
      .set('system:time_start', ee.Date.fromYMD(2023, mes, 1).millis()),  
    null  
  );  
});  
  
var mensual = ee.ImageCollection(ee.List(listaMensual).removeAll([null]));
```

Código completo de fusión y multitemporalidad en JavaScript para GEE

```
// =====  
// 3. Gráfico de NDVI mensual MODIS  
// =====
```

```
var chart = ui.Chart.image.series({  
  imageCollection: mensual,  
  region: aoi,  
  reducer: ee.Reducer.mean(),  
  scale: 250  
}).setOptions({  
  title: 'NDVI Mensual MODIS 2023 (Turipaná)',  
  hAxis: {title: 'Mes'},  
  vAxis: {title: 'NDVI (0 - 1)'}  
});  
print(chart);
```

```
// =====  
// 4. NDVI junio 2023 - MODIS  
// =====
```

```
var modis_jun = ee.Image(ee.Algorithms.If(  
  modis.filterDate('2023-06-01', '2023-06-30').size().gt(0),  
  modis.filterDate('2023-06-01', '2023-06-30')  
    .mean()  
    .multiply(0.0001)  
    .rename('NDVI_MODIS'),  
  ee.Image(0).rename('NDVI_MODIS').updateMask(ee.Image(0))  
));
```

Código completo de fusión y multitemporalidad en JavaScript para GEE

```
// =====
// 5. NDVI junio 2023 - Sentinel-2
// =====
var s2 = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
  .filterBounds(aoi)
  .filterDate('2023-06-01', '2023-06-30')
  .filter(ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', 20))
  .select(['B4', 'B8']); // rojo e infrarrojo cercano

var sentinel_jun = ee.Image(ee.Algorithms.If(
  s2.size().gt(0),
  s2.median(),
  ee.Image().select() // imagen vacía
));
```

```
var ndvi_s2 = ee.Algorithms.If(
  sentinel_jun.bandNames().size().gt(0),
  sentinel_jun.normalizedDifference(['B8', 'B4']).rename('NDVI_S2'),
  ee.Image().select()
);

ndvi_s2 = ee.Image(ndvi_s2);

// 6. Fusión visual: Reproyectar MODIS a 10 m
var reproj = ee.Algorithms.If(
  ndvi_s2.bandNames().size().gt(0),
  ndvi_s2.projection(),
  ee.Projection('EPSG:4326').atScale(10)
);

var modis_resampled = modis_jun
  .resample('bilinear')
  .reproject({
    crs: ee.Projection(reproj).crs(),
    scale: 10
  });
```

Código completo de fusión y multitemporalidad en JavaScript para GEE

```
// =====  
// 7. Mostrar capas en el mapa  
// =====
```

```
if (modis_jun.bandNames().size().getInfo() > 0) {  
  Map.addLayer(modis_resampled.clip(aoi), {  
    min: 0, max: 1,  
    palette: ['white', 'green']  
  }, 'MODIS NDVI (jun 2023)');  
} else {  
  print('⚠ No hay datos MODIS NDVI en junio 2023.');
```

```
} if (ndvi_s2.bandNames().size().getInfo() > 0) {  
  Map.addLayer(ndvi_s2.clip(aoi), {  
    min: 0, max: 1,  
    palette: ['white', 'darkgreen']  
  }, 'Sentinel-2 NDVI (jun 2023)');  
} else {  
  print('⚠ No hay datos Sentinel-2 NDVI en junio 2023.');
```


Ejercicio práctico de clasificación supervisada y no supervisada de firmas espectrales

Usando SVM y covarianza para clasificación



Procesamiento de espectros de reflectancia

firma espectral



Código: 7-SPECTRUM_PROCESSING_GROUP.ipynb

Características:

- Lectura de archivos .txt de registros de firmas espectrales con OCEAN OPTICS
- Promedio de 4 espectros
- Visualización de espectro promedio.
- Cálculo de covarianza en bandas R, G, B y NIR
- Cálculo de 21 índices de vegetación (NDVI, NDRE, GNDVI, etc), calculada a través de la longitud de onda aproximada.

Procesamiento de espectros de reflectancia – firma espectral

Spectrums per sample



Ejemplo de etiquetados

- **Etiquetado**

Asociar cada espectro con una **clase conocida**, por ejemplo:

- **Tipo de cobertura:** pasto Mombasa, suelo desnudo, sombra, árbol.
- **Estado:** estrés hídrico, sano, seco.

Asociar a la covarianza del NIR una clase conocida, por ejemplo

- **Uniformidad de macollas de Mombasa:** Dependiendo del valor
- **Usar algoritmos como Máquinas de Soporte Vectorial (SVM) para clasificación de biomasa de Mombasa** si se asocia una propiedad del espectro (reflectancia NIR, NDVI u otro índice) con la biomasa en términos de etiquetas (ALTA, BAJA). Véase ejemplo ilustrativo en clase de una clasificación de biomasa con No. de hojas totales de la planta (macolla).

Código de clasificación usando sklearn de Python

```
espectros = [  
    {'reflectancia': [0.12, 0.18, 0.25, 0.32, 0.04], 'clase': 'Mombasa'},  
    {'reflectancia': [0.03, 0.05, 0.08, 0.12, 0.02], 'clase': 'Suelo'},  
]
```

```
from sklearn.ensemble import RandomForestClassifier  
from sklearn.model_selection import train_test_split  
from sklearn.metrics import classification_report  
import numpy as np
```

```
# Datos de ejemplo: X = espectros (reflectancias por banda),  
y = etiquetas  
X = np.array([  
    [0.12, 0.18, 0.25, 0.32, 0.04],  
    [0.10, 0.16, 0.22, 0.30, 0.03],  
    [0.03, 0.05, 0.08, 0.12, 0.02],  
    [0.02, 0.04, 0.07, 0.11, 0.01]  
])
```

Código de clasificación usando sklearn de Python

```
y = ['Mombasa', 'Mombasa', 'Suelo', 'Suelo']
```

```
# Dividir y entrenar
```

```
X_train, X_test, y_train, y_test = train_test_split(X, y,  
test_size=0.25, random_state=42)
```

```
clf = RandomForestClassifier(n_estimators=100,  
random_state=42)
```

```
clf.fit(X_train, y_train)
```

```
# Evaluar
```

```
y_pred = clf.predict(X_test)
```

```
print(classification_report(y_test, y_pred))
```

8-ClasificadorRFMombasaReflectancia.ipynb

Aplicaciones del modelo

Aplica el modelo a:

- Imágenes multiespectrales completas (por píxel).
- Nuevas muestras de espectro de campo.

Si tienes imágenes de **Sentinel-2** o dron:

- Extrae las bandas por píxel.
- Aplica el modelo a cada vector de bandas.
- Reconstruye un mapa de clases.

Véase ejemplo de clasificación de imágenes multibandas (5 bandas) usando Random Forest

9-ClasificadorSupMombasaImagen5bandas.ipynb

9-GeneradorAleatorioImagen5Bandas

Comparación de técnicas de clasificación supervisadas y no supervisadas

Técnica	Descripción
Random Forest	Robusto y fácil de interpretar. Ideal para espectros.
SVM	Funciona bien con espectros si normalizas.
PCA	Reduce bandas redundantes antes de clasificar.
K-means + supervisado	Usa <i>k-means</i> para agrupar y etiquetar manualmente.
CNNs	Para clasificación de imágenes completas con espectros espaciales.

Librerías de Python



scikit-learn: modelos clásicos.



xgboost: muy preciso para clasificación.



spectral: para trabajar con imágenes hiperespectrales.



geemap/ee: si trabajas con imágenes de Earth Engine.



numpy, pandas, matplotlib: manipulación y visualización.

Generalidades y componentes de los vehículos aéreos no tripulados

Drones, características técnicas y altura de vuelo



Tipos de drones según plataforma

Tipo	Descripción	Ejemplo de uso
Multirrotor	Vuela verticalmente, maniobrable y fácil de operar	Agricultura, topografía, inspecciones
Ala fija	Vuela como un avión, mayor autonomía y cobertura	Cartografía, monitoreo de cultivos
Híbrido VTOL	Despega como multirrotor, vuela como ala fija	Coberturas amplias con precisión

Características técnicas claves

Característica	Descripción
Sensor / Cámara	RGB, multispectral, térmica, hiperespectral, LiDAR
Resolución	En megapíxeles (RGB) o resolución espacial (cm/píxel para multispectral)
Estabilización / Gimbal	Mejora la calidad de imágenes en vuelo
Precisión GPS	RTK/PPK para precisión centimétrica (ideal para ortomosaicos y mapeo)
Autonomía de vuelo	Entre 20 y 60 minutos típicamente
Alcance de comunicación	Generalmente entre 2–7 km (depende del dron y regulaciones locales)
Capacidad de carga útil	Peso que puede llevar: importante si deseas añadir sensores específicos

Altura de vuelo recomendada (AGL = sobre el nivel del suelo)

Aplicación	Altura típica (AGL)	Resolución esperada (cm/píxel)	Notas
Agricultura RGB general	60–120 m	2–5 cm/píxel	Balance entre resolución y cobertura
Agricultura multiespectral	80–120 m	5–10 cm/píxel	Según sensor (e.g., RedEdge, Altum)
Clasificación de cobertura (NDVI)	100–120 m	5–10 cm/píxel	Cobertura amplia, resolución útil
Detección fina (plagas, estrés)	30–60 m	<2 cm/píxel	Requiere baja altura y alta resolución
Levantamiento topográfico (LiDAR)	100–150 m	Depende del sensor	Generalmente con RTK/PPK
Silvopasturas	80–100 m	4–8 cm/píxel	Permite NDVI, altura y biomasa

Drones usados en Agricultura y Monitoreo Ambiental

Modelo	Sensor incluido	Notas clave
DJI Phantom 4 RTK	RGB + RTK	Muy usado para cartografía y ortomosaicos
DJI Mavic 3 Multispectral	RGB + Multiespectral (4 bandas)	Ideal para NDVI y agricultura de precisión
Parrot Anafi USA	RGB + térmica	Inspección y monitoreo
eBee X + RedEdge-MX	Multiespectral	Alta cobertura para parcelas grandes
DJI Matrice 300 + Zenmuse P1 / L1	RGB / LiDAR	Profesional, adaptable, alta carga útil

Recomendaciones para uso de drones



 **Calibración radiométrica:**
Usa paneles de calibración si
trabajas con sensores
multiespectrales.



 **Planifica con software:**
Pix4D, DroneDeploy, DJI Terra o
QGIS con plugins.



 **Vuelo automático:** Usa
misiones preprogramadas para
asegurar solapamiento y calidad.



 **Baterías extras:** Planifica con
baterías de respaldo si el terreno
es grande.

Programa que relaciona el FOV, la altura de Vuelo y tipo de cámara

- 10-CALCULADORA_CAMARA_DRONES.ipynb

PASOS PARA GENERACIÓN DE IMÁGENES NDVI DE DRONES

- Cargar las bandas (NIR y RED)
- Calcular el NDVI
- Visualizar el NDVI
- Guardar el NDVI como imagen GeoTIFF o JPG

El rango del NDVI va de **-1 a 1**:

- $\text{NDVI} > 0.5$: vegetación vigorosa
- NDVI entre 0.2 y 0.5: vegetación escasa o en estrés
- $\text{NDVI} < 0.2$: suelo, agua, o materiales inertes

PASOS PARA GENERACIÓN DE IMÁGENES NDVI DE DRONES



- 11-CARGAR_IMAGENES_DRONES.ipynb
- 12-GENERACION_NDVI_FROM_R_NIR -DRONES

SEGMENTACIÓN DE IMÁGENES DE DRONES USANDO k-means

- 13-Segmentación_Kmeans (Carpeta con archivos Python)



IMÁGENES ORIGINALES



IMAGENES SEGMENTADAS

App de escritorio y Android: OPTIFORRAJE

- Presentación de la App Optiforraje.
 - Algoritmos de procesamiento de espectros integrados en plataforma digital OPTIFORRAJE
 - Algoritmos de procesamiento de imágenes: k-means y Mahalanobis.
- 

Sensores remotos (Teledetección) Vs. Sensores proximales (Espectroradiómetros y smartphones)

Los **SENSORES REMOTOS** capturan información de la superficie terrestre desde una **gran distancia**, normalmente desde **satélites o drones**.

Características:

- **Cobertura espacial amplia** (decenas a miles de km²).
- Resoluciones espacial, espectral, temporal y radiométrica variables.
- Pueden ser **sensores pasivos** (como Sentinel-2, Landsat) o **activos** (como Sentinel-1, LIDAR).

Usos comunes:

- Monitoreo multitemporal de NDVI, humedad del suelo, temperatura.
- Seguimiento de cambios en grandes extensiones (cultivos, pasturas, bosques).
- Detección de patrones regionales.

Ejemplos:

- Satélites: Sentinel-2, Landsat, MODIS.
- Drones con cámaras multispectrales o térmicas.

Sensores remotos (Teledetección) Vs. Sensores proximales (Espectroradiómetros y smartphones)

Los SENSORES PROXIMALES operan **muy cerca del objetivo** (centímetros a metros), y son empleados directamente en campo.

Características:

- **Alta resolución espacial y espectral.**
- Permiten mediciones inmediatas y específicas por planta o parcela.
- Ideales para **calibrar y validar** datos satelitales.

Usos comunes:

- Medición directa del NDVI, PRI, clorofila, contenido de agua.
- Evaluación de calidad forrajera o estrés hídrico.
- Calibración de modelos predictivos y aprendizaje automático.

Ejemplos:

- **Espectroradiómetros** portátiles (como ASD FieldSpec, OCEAN OPTICS).
- **Smartphones** con apps especializadas o adaptadores de lentes multispectrales.
- **Sensores ópticos en tractor o bastón.**

Sensores remotos Vs. Proximales

Característica	Sensores Remotos	Sensores Proximales
Distancia de medición	Decenas a miles de kilómetros	Centímetros a pocos metros
Resolución espacial	Baja a media (10–1000 m/píxel)	Muy alta (milímetros – centímetros)
Cobertura	Regional a global	Hoja, planta, parcela
Frecuencia de medición	Determinada por plataforma	Según necesidad (manual o continua)
Costo	Bajo por área, alto por unidad	Medio a alto por unidad
Requiere calibración	Sí, preferiblemente con datos de campo	No siempre
Ejemplos	Sentinel-2, MODIS, drones	ASD FieldSpec, smartphone, SVC

Aplicaciones y estado de arte

Open Access Article

In-Field Forage Biomass and Quality Prediction Using Image and VIS-NIR Proximal Sensing with Machine Learning and Covariance-Based Strategies for Livestock Management in Silvopastoral Systems

by Claudia M. Serpa-Imbett ^{1,2,*} , Erika L. Gómez-Palencia ¹ , Diego A. Medina-Herrera ¹ ,
Jorge A. Mejía-Luquez ¹ , Remberto R. Martínez ¹ , William O. Burgos-Paz ¹  and
Lorena A. Aguayo-Ulloa ^{1,*} 

¹ Corporación Colombiana de Investigación Agropecuaria AGROSAVIA, Centro de Investigación Turipaná, km 13
vía Montería Cereté, Cereté 230550, Córdoba, Colombia

² Departamento de Ingeniería Eléctrica, Universidad del Sinú Elías Bechara Zainum, Montería 230001, Córdoba,
Colombia

* Authors to whom correspondence should be addressed.

AgriEngineering **2025**, *7*(4), 111; <https://doi.org/10.3390/agriengineering7040111>

Submission received: 14 February 2025 / Revised: 18 March 2025 / Accepted: 2 April 2025 /

Published: 8 April 2025

(This article belongs to the Collection Exploring the Application of Artificial Intelligence and Image Processing
in Agriculture)

Remotos para analizar patrones y
evolución en el tiempo.

Proximales para validar datos,
mejorar modelos de predicción y
tomar decisiones inmediatas de
manejo.

[In-Field Forage Biomass and
Quality Prediction Using Image and
VIS-NIR Proximal Sensing with
Machine Learning and Covariance-
Based Strategies for Livestock
Management in Silvopastoral
Systems](#)

[illegible]

CONTENIDO

1. Fundamentos de teledetección

2. Imágenes pasivas

3. Imágenes activas



An aerial photograph of a coastal region. A large, light-colored bay or estuary is the central feature, surrounded by dark, forested hills. The coastline is irregular with several small inlets and peninsulas. The text 'MODULO 3' is overlaid in the center-right of the image.

MODULO 3

IMÁGENES ACTIVAS

CONTENIDO

1. Fundamentos de teledetección

2. Imágenes pasivas

3. Imágenes activas



¿Qué es un sensor activo?

Un **sensor activo** es un tipo de sensor de teledetección (sensor remoto) que **emite su propia energía electromagnética** hacia la superficie terrestre y **mide la energía reflejada o dispersada** por los objetos en esa superficie.



¿Qué es un sensor activo?

Los sensores activos generan una **imagen activa** capturada por una plataforma de teledetección que **emite su propia señal electromagnética** y registra su retorno tras interactuar con el objetivo.

Ejemplos más comunes:

- **Radar (Radio Detection and Ranging)** — microondas.
- **LIDAR (Light Detection and Ranging)** — láser (infrarrojo o verde).



¿Cómo funciona un sensor activo?

- **Emisión:** El sensor genera una señal (como un pulso de microondas o láser) dirigida hacia el terreno.
 - **Interacción:** Esta señal interactúa con la superficie u objetos (suelo, vegetación, agua, construcciones).
 - **Recepción:** El sensor detecta la señal que retorna después de la interacción.
 - **Procesamiento:** A partir del tiempo, intensidad y forma de la señal reflejada, se infiere información sobre el objeto observado.
- 

Tipos de sensores activos

- **RADAR (Radio Detection and Ranging)**
 - Emite microondas.
 - Usado en satélites como **Sentinel-1, RADARSAT**.
 - Capaz de operar bajo cualquier condición climática.
- **LIDAR (Light Detection and Ranging)**
 - Emite pulsos de luz láser.
 - Usado en drones y aviones para generar **modelos 3D** del terreno o vegetación.
 - Alta resolución y precisión vertical.

Tipos de sensores ópticos y de radiofrecuencia

Sensor	Energía emitida	Longitud de onda	Usos comunes
SAR (Radar de apertura sintética)	Microondas (GHz)	~1–100 cm	Vegetación, humedad del suelo, estructuras, topografía, agricultura
LIDAR	Láser (infrarrojo o visible)	~0.5–1.5 μm	Modelos digitales de terreno, biomasa, estructuras forestales

Diferencias entre sensor activo y pasivo

Característica	Sensor Activo	Sensor Pasivo
Fuente de energía	Propia (emitida)	Externa (como el Sol)
Operación nocturna	 Sí	 No (depende de la luz solar)
Capacidad de penetrar nubes o vegetación	Alta (especialmente radar)	Limitada
Ejemplos	RADAR, LIDAR, Echo Sounder	Cámaras ópticas, termales, multiespectrales

Ventajas de los sensores activos



Funcionan de **día o noche**
(independientes de la luz
solar).



Pueden **penetrar nubes,
humo y vegetación**
(especialmente SAR).



Capturan información
estructural y geométrica
(relieve, textura, rugosidad).



LIDAR proporciona datos en
3D de alta precisión.

Interacción de la señal con la superficie

Radar/SAR:

- Interacción dominada por **rugosidad del terreno, contenido de humedad y geometría del objeto**.
- Produce imágenes en **tonos de gris (backscatter)**.
- Polarización (HH, HV, VV) afecta la sensibilidad del sensor.

LIDAR:

- Mide el **tiempo de retorno del pulso láser** para obtener:
 - Altura de objetos
 - Altura del terreno
 - Nubes de puntos 3D
- Puede distinguir entre **copa vegetal, tronco y suelo**.

¿Qué es la polarización?



Cuando una antena emite una onda de radar, esa onda tiene una orientación eléctrica (polarización). El sensor puede cambiar o mantener esa orientación al enviar y recibir la señal.




Esto afecta **cómo interactúa la onda con la superficie**, dependiendo del tipo de cobertura (agua, vegetación, suelo, estructuras).

Codificación

Código	Significado	Sensibilidad principal
HH	Horizontal emitida y recibida	Superficies planas como suelo desnudo o agua.
VV	Vertical emitida y recibida	Superficies verticales como tallos o edificios.
HV	Horizontal emitida, vertical recibida	Estructuras complejas como vegetación densa.
VH	Vertical emitida, horizontal recibida	Similar a HV (son recíprocos).

Polarización V y H (Lineal)



Aplicaciones en vegetación y agricultura

- **HH o VV:** Útiles para monitorear humedad del suelo o estructuras verticales.
- **HV o VH (cross-polarization):** Muy útiles para evaluar **biomasa, estructura de vegetación o interacciones volumétricas** (e.g., ramas, hojas).

Ejemplo el Sentinel-1 proporciona:

- **VV + VH** para modo IW (Interferometric Wide swath).
- Datos en **polarización dual** (dual-pol) o **polarización completa** (quad-pol) dependiendo del sensor.

¿Cómo afecta a la interpretación?

- Un campo cubierto de pasto denso reflejará más señal HV que VV.
- Un lago reflejará más en VV o HH y casi nada en HV.
- Combinando varias polarizaciones, se pueden hacer clasificaciones supervisadas, detección de cambios, o estimación de biomasa.



Procesamiento de imágenes activas

- **Corrección geométrica y radiométrica**

- SAR: corrección speckle, calibración radiométrica.
- LIDAR: corrección de trayectoria y calibración láser.

- **Extracción de características**

- Textura, retrodispersión (SAR).
- Altura, densidad, perfil vertical (LIDAR).

- **Clasificación supervisada/no supervisada**

- Basada en patrones de backscatter o altura.

- **Fusión multifuente**

- Integración con imágenes ópticas o NDVI para mejores resultados.

Aplicaciones de sensores activos

- Altura de cultivos o pastos (LIDAR).
- Densidad de vegetación o cobertura arbórea (LIDAR, RADAR).
- Humedad del suelo (RADAR).
- Mapeo de estructuras en suelos complejos o bajo sombra.

Ejemplos de Aplicaciones

Aplicación

Sensor

Estimación de biomasa y altura de pastos

LIDAR (UAV o satelital)

Evaluación de humedad del suelo

SAR (Sentinel-1, RADARSAT)

Análisis de deforestación y cambio de uso de suelo

SAR + óptico

Detección de estructuras agrícolas o canales

LIDAR topográfico

Monitoreo de pasturas bajo cobertura arbórea (silvopastoriles)

LIDAR + NDVI

Integración con Python

Librerías clave:

- rasterio, geopandas: manipulación de datos geoespaciales.
- lidar, laspy: manejo de nubes de puntos LIDAR.
- sentinelsat, pyroSAR: descarga y análisis de datos SAR.
- scikit-learn, xgboost: clasificación supervisada.

Procesamiento de Imágenes Sentinel-1 VV y VH con Python

1. Descarga de Datos

Puedes obtener imágenes de Sentinel-1 desde el Copernicus Open Access Hub o utilizar plataformas como [Google Earth Engine](#) para acceder a datos preprocesados.

2. Preprocesamiento

Es recomendable realizar los siguientes pasos:

- Calibración radiométrica:** para convertir los valores de retrodispersión a unidades físicas.
- Corrección geométrica:** para alinear las imágenes con coordenadas geográficas precisas.
- Conversión a decibelios (dB):** utilizando la fórmula $10 * \log_{10}(\text{valor})$.

Nota: Si utilizas datos de Google Earth Engine, muchos de estos pasos ya están aplicados.

3. Cálculo de Índices

Puedes calcular el índice de retrodispersión cruzada (Cross Ratio Index) para resaltar diferencias entre las polarizaciones:

Unidades de retrodispersión

En el caso de imágenes satelitales activas como las de Sentinel-1, que utiliza radar de apertura sintética (SAR), la retrodispersión (backscatter) es la medida principal, y sus unidades se relacionan con la potencia de la señal reflejada por la superficie hacia el sensor.

- La retrodispersión se mide como un **coeficiente adimensional**, generalmente representado como:
- **σ^0 (sigma-cero)**: Coeficiente de retrodispersión normalizada.
- Aunque σ^0 es adimensional, **se expresa comúnmente en decibelios (dB)** para facilitar la interpretación y comparación:

$$\sigma^0(\text{dB}) = 10 \cdot \log_{10}(\sigma^0)$$

Comparación con el dominio óptico

Mientras que en sensores pasivos (como Sentinel-2 o Landsat) se trabaja con:

- **Radiancia** ($\text{W} \cdot \text{m}^{-2} \cdot \text{sr}^{-1} \cdot \mu\text{m}^{-1}$)
- **Reflectancia** (valor entre 0 y 1, o en %)

En sensores **activos** como Sentinel-1, el radar emite su propia señal y mide la fracción que regresa (retrodispersión), por eso:

- No se mide **radiancia reflejada del Sol**, sino la **potencia reflejada del pulso de radar**.
- No se usa reflectancia espectral, sino **coeficientes de dispersión** (σ^0 , β^0 o γ^0).

Coeficientes de retrodispersión

Coeficiente	Significado	Relación	Comentario
σ^0 (sigma nought)	Retrodispersión en dirección normal al radar	Base	Común en productos GRD (Ground Range Detected)
β^0 (beta nought)	Potencia de retrodispersión por unidad de ángulo sólido	Relacionado con σ^0 por el ángulo de incidencia	Útil en análisis topográficos
γ^0 (gamma nought)	Retrodispersión referida al plano local del terreno	$\gamma^0 = \sigma^0 / \cos(\theta)$	Común en productos corregidos topográficamente (RTC)

Unidades para los SAR

- Unidad base: σ^0 , adimensional, expresada en decibelios (dB).
- dB es una escala logarítmica: cada +10 dB representa un aumento de 10 veces en potencia.
- No hay unidades como W/m^2 en SAR, ya que no se mide radiancia solar, sino potencia de eco del radar.
- La interpretación física del valor depende de la rugosidad, humedad y geometría del terreno.

Ejemplo en GEE (Conversión de unidades)

```
// Definir el polígono de interés
```

```
var geometry = ee.Geometry.Polygon(
```

```
  [[[-75.9, 8.8],
```

```
    [-75.9, 8.6],
```

```
    [-75.5, 8.6],
```

```
    [-75.5, 8.8]]]);
```

```
// Cargar imagen Sentinel-1 VV
```

```
var image = ee.ImageCollection('COPERNICUS/S1_GRD')
```

```
  .filterBounds(geometry)
```

```
  .filterDate('2024-01-01', '2024-01-31')
```

```
  .filter(ee.Filter.eq('instrumentMode', 'IW'))
```

```
  .filter(ee.Filter.eq('orbitProperties_pass', 'DESCENDING'))
```

```
  .filter(ee.Filter.eq('resolution_meters', 10))
```

```
  .filter(ee.Filter.listContains('transmitterReceiverPolarisation', 'VV'))
```

```
  .select('VV')
```

```
  .first();
```

```
// Convertir a dB
```

```
var sigma0_dB = image.log10().multiply(10).rename('VV_dB');
```

```
// Parámetros de visualización
```

```
var visParams = {
```

```
  min: -25,
```

```
  max: 0,
```

```
  palette: [
```

```
    '#440154', '#3b528b', '#21918c', '#5ec962', '#fde725'
```

```
  ]
```

```
};
```


Ejemplo en GEE (Conversion de unidades)

```
// Mostrar la imagen y el polígono en el  
mapa  
Map.centerObject(geometry, 10);  
Map.addLayer(sigma0_dB, visParams,  
'VV en dB (resaltado)');  
Map.addLayer(ee.FeatureCollection(geo  
metry),  
              {color: 'red'},  
              'Área de interés', false); // El  
"false" permite activar/desactivar la  
capa
```

```
// Exportar imagen a Google Drive  
Export.image.toDrive({  
  image: sigma0_dB.clip(geometry),  
  description: 'Sentinel1_VV_dB_Export',  
  folder: 'GEE_Export',  
  fileNamePrefix: 'sentinel1_vv_dB',  
  region: geometry,  
  scale: 10,  
  crs: 'EPSG:4326',  
  maxPixels: 1e13  
});
```

Conversión de unidades en Python

21-Sentinel1-ConversiondBRetros.ipynb

Calculo con bandas VV y VH

```
import rasterio
import numpy as np
import matplotlib.pyplot as plt

# Cargar las bandas VV y VH
with rasterio.open('sentinel1_VV.tif') as vv_src:
    vv = vv_src.read(1)
    profile = vv_src.profile

with rasterio.open('sentinel1_VH.tif') as vh_src:
    vh = vh_src.read(1)

# Evitar divisiones por cero
epsilon = 1e-10
cross_ratio = np.log10((vv + epsilon) / (vh + epsilon))
```

```
# Guardar el índice como un nuevo raster
profile.update(dtype=rasterio.float32, count=1)
with rasterio.open('cross_ratio.tif', 'w', **profile) as dst:
    dst.write(cross_ratio.astype(rasterio.float32), 1)

# Visualizar el resultado
plt.imshow(cross_ratio, cmap='viridis')
plt.colorbar(label='Cross Ratio Index')
plt.title('Índice de Retrodispersión Cruzada (VV/VH)')
plt.axis('off')
plt.show()
```

22-Generacion_Imagenes_VV_VH.ipynb

Aplicaciones de las bandas VV y VH

1. Estimación de Humedad Superficial

La retrodispersión en la polarización **VV** es sensible a la humedad del suelo. Puedes aplicar modelos empíricos o de aprendizaje automático para estimar la humedad superficial a partir de los valores de retrodispersión. Por ejemplo, utilizando regresión lineal o Random Forest, entrenados con datos de campo.

2. Clasificación de Cobertura Vegetal

Combinando las polarizaciones **VV** y **VH**, puedes realizar una clasificación supervisada para diferenciar tipos de cobertura vegetal. Esto se puede lograr utilizando algoritmos como Random Forest o Support Vector Machines, entrenados con muestras de referencia.

Comparación de diferentes satélites

Característica	Sentinel-1A/B	Sentinel-1C	RISAT (1,2,2B,1A)	RADARSAT-2	RADARSAT Constellation (RCM)
Agencia Espacial	ESA	ESA	ISRO (India)	CSA / MDA (Canadá)	CSA (Canadá)
País	Unión Europea	Unión Europea	India	Canadá	Canadá
Sensor SAR	Banda C (5.405 GHz)	Banda C (idéntica a A/B)	Banda C (1/1A) y Banda X (2/2B)	Banda C	Banda C
Resolución espacial	5 – 40 m	5 – 40 m (misma que A/B)	1 – 50 m	3 – 100 m	3 – 100 m
Cobertura de escena	20 – 400 km	20 – 400 km	10 – 240 km	20 – 500 km	20 – 500 km
Revisita temporal	~6 días (con 1A+1B)	Ayudaría a retomar ciclo de 6 días	2 – 5 días	~24 días	4 días (con 3 satélites)
Altura de órbita	~693 km	~693 km	~536 – 576 km	~798 km	~600 km
Órbita	Heliosíncrona	Heliosíncrona	Heliosíncrona	Heliosíncrona	Heliosíncrona
Polarizaciones	VV, VH, HH, HV (dual)	Igual que A/B	VV, HH, HV, VH (según versión)	HH, VV, HV, VH, quad-pol	HH, VV, HV, VH, quad-pol
Lanzamiento inicial	1A: 2014; 1B: 2016	1C: 2024 (lanzamiento previsto)	2: 2009; 1: 2012; 2B: 2019; 1A: 2022	2007	2019
Objetivo principal	Agricultura, monitoreo terrestre	Reforzar continuidad del programa	Defensa, monitoreo agrícola	Hielo, agricultura, vigilancia	Agricultura, clima, vigilancia marítima
Acceso a datos	Gratuito y abierto (Copernicus Hub)	Gratuito (mismo sistema)	Parcial o restringido	Comercial (licencia MDA)	Gratuito para Canadá / comercial limitado

Tipos de adquisición del SAR

Satélite	Modos SAR	Detalles
Sentinel-1A/B/C	- IW (Interferometric Wide Swath)- EW (Extra Wide Swath)- SM (Stripmap)- WV (Wave Mode)	- IW: modo estándar para tierra (res. ~10m, 250km ancho)- EW: emergencias costeras- SM: alta resolución
RISAT	- Fine Resolution Stripmap (FRS)- Coarse Resolution ScanSAR- Spotlight (en RISAT-2B)	- Múltiples modos según misión: defensa, agricultura, vigilancia
RADARSAT-2	- Spotlight (3m)- Fine Quad-pol (8m)- Wide (100m)- ScanSAR Wide	- Capacidad multi-polarización y modos flexibles
RCM (Constelación)	- Spotlight- Ultra-Fine- Wide ScanSAR- Maritime Surveillance	- Óptimo para cobertura frecuente, monitoreo rápido y vigilancia marítima

Modo Strip Map (SM) – Sentinel 1

Es un **modo SAR de resolución alta** que adquiere imágenes **de una franja continua del terreno** al mover la antena del radar con una dirección fija respecto al nadir (sin barrido lateral).



Para que se usa el Strip Map (SM)

- Usado cuando se requiere **alta resolución espacial** sobre áreas más pequeñas, como:
- **Monitoreo de infraestructura crítica**
- **Aplicaciones militares o de seguridad**
- **Detección de objetos pequeños**
- **Estudios de detalle sobre zonas urbanas, fallas geológicas o glaciares**



Modo Strip Map (SM) de Sentinel 1

Parámetro	Valor típico (Sentinel-1)
Resolución espacial	~5 m (azimut) x 5 m (range)
Ancho de franja	~80 km
Polarizaciones	HH, VV, HV, VH (dual disponibles)
Frecuencia de uso	Poco frecuente en Sentinel-1 (se prioriza IW)

Comparación con modos IW y EW

Modo	Resolución (m)	Cobertura (km)	Uso principal
SM	5 x 5	80	Alta resolución en áreas pequeñas
IW	10 x 10	250	Estándar para monitoreo terrestre
EW	40 x 40	400	Grandes áreas, emergencias
WV	~20 x 20	Puntual	Estudios oceánicos (olas)

¿Que es el nadir?

El **nadir** es el **punto directamente debajo del satélite**, es decir, el punto de la superficie terrestre que se encuentra **en línea recta vertical con respecto al sensor**.

Imagina una línea recta que va del satélite hacia el centro de la Tierra:
→ El punto donde esta línea **toca la superficie** se llama **nadir**.

- **Ángulo de nadir = 0°** (mirada completamente vertical).
- Los sensores que miran hacia el nadir se llaman **nadiraes** o de **visión nadiral**.

Importancia de nadir

Aspecto

Relación con el nadir

Resolución espacial

Es máxima en el nadir (menor distorsión geométrica).

Órbitas satelitales

Muchos satélites de observación pasan justo sobre el nadir.

Modo SAR StripMap


Se orienta cerca del nadir pero ligeramente inclinado.

Correcciones geométricas

Se utilizan para compensar el ángulo respecto al nadir.

Wave mode (WM)

Es un **modo puntual (no continuo)** en el que el radar **captura pequeñas “ventanas” de imagen SAR** llamadas *imagettes* o *vignettes*.



Parámetros del wave mode (WM)

Parámetro	Valor típico en Sentinel-1
Tamaño de imágette	~20 km × 20 km
Frecuencia de adquisición	Cada ~100 km sobre el océano
Resolución espacial	~10 m
Cobertura	No es continua; solo pequeñas zonas
Polarización	VV (frecuente) o dual (VV + VH)

Uso de wave mode (WM)



Este modo está optimizado para generar productos como:



Espectros de olas oceánicas



Altura significativa de oleaje



Dirección y longitud de onda



Vigilancia marítima puntual (de forma secundaria)

Como funciona WM

El satélite **toma una serie de imágenes pequeñas** sobre el océano abiertas cada ciertos kilómetros, sin formar una imagen continua. Estas se procesan para estimar parámetros físicos del mar mediante análisis de Fourier del patrón SAR.

Diferencia con otros modos

Modo	Resolución	Cobertura	Uso principal
WV	10 m	20x20 km	Olas y dinámica marina puntual
IW	10 m	250 km	Monitoreo terrestre general
EW	40 m	400 km	Costas, emergencias, mar abierto
SM	5 m	80 km	Alta resolución sobre tierra

Pasos para procesar imágenes satelitales de Sentinel 1 (RADAR) con GEE

1. Configuración del Entorno
2. Definir el Área de Interés (AOI) y el Rango de Fechas
3. Cargar y Filtrar la Colección de Imágenes Sentinel-1
4. Calcular la Media Temporal de las Polarizaciones VV y VH
5. Calcular el Índice de Retrodispersión Cruzada (CR)
6. Visualizar los Resultados
7. Exportar los Resultados

Ejecutar código en COLAB: 13-Procesamiento de Imagenes ActivasCOLAB.ipynb

Clasificación supervisada usando datos de polarización VV y VH de Sentinel-1, empleando Google Earth Engine (GEE) y Random Forest.

- Usa Google Earth Engine para obtener datos VV y VH de Sentinel-1.
- Crea puntos de entrenamiento etiquetados para tres clases.
- Entrena un clasificador Random Forest.
- Crea puntos de entrenamiento etiquetados para dos clases.
- Entrena un clasificador SVC (Maquina de vectores de soporte)
- Aplica la clasificación y visualiza en un mapa interactivo con geemap.
- Exporta la imagen clasificada como .tif a tu Google Drive.

Ejecutar códigos RF

14-ClasificaciónImágenesActivasCOLAB.ipynb

15-ClasificaciónImágenesActivas2ImágenesCOLAB.ipynb

Ejecutar código SVC:

16-GeneradorImágenesActivasVVyVH

16-ClasificaciónImágenesActivasSVCCyRFCOLAB.ipynb

Clasificación de imágenes activas usando XGBoost

- Soporta valores faltantes
- Alta precisión
- Control de overfitting
- Buena interpretación (importancia de variables)
- Se puede combinar con espectros, índices (NDVI, NDWI) y variables auxiliares (e.g., altura, textura)
- Consulta el siguiente recurso: [Saeideh-Maleki/XGBoost Classification algorithm: Using this code, the NPZ files containing remote sensing data can be classified.](#)

Potencialidades del uso de XGBoost

Con XGBoost puedes realizar distintos tipos de clasificación en imágenes satelitales o de dron, incluyendo:

1. **Clasificación de cobertura del suelo** (uso del suelo, vegetación, agua, urbano, suelo desnudo, etc.).
2. **Clasificación de tipos de vegetación** (por ejemplo, distinguir cultivos, especies forrajeras como Mombasa, o pastos vs arbustos).
3. **Clasificación de humedad del suelo** (utilizando combinaciones de bandas e índices).
4. **Detección de cambios** (comparando épocas y clasificando zonas con cambio o sin cambio).
5. **Clasificación por salud de la vegetación** (alta, media, baja, o vegetación estresada).
6. **Clasificación de áreas quemadas** (usando NBR, NDVI y otros índices).
7. **Zonificación agrícola o ganadera** (por productividad, biomasa, calidad del forraje, etc.).
8. Puedes combinar las bandas originales (por ejemplo, Sentinel-2 B2–B8) con índices espectrales (NDVI, EVI, SAVI, etc.) y luego aplicar XGBoost con entrenamiento supervisado usando datos etiquetados (por ejemplo, puntos de muestreo en campo)

Potencialidades
del uso de
XGBoost


Ejecutar:

- 17-
GeneradorImágenesActivasMUESTRASV
VyVH.ipynb
17-XGBoostCLASIFICADORVVyVH.ipynb
- 18-
XGBoostCLASIFICADORVVyVH_2clases

Recursos recomendados



<https://youtu.be/eSLuGvnsorM?si=HBZEGYseAWfWq7xi> (SAR
– Curso de la Nasa)



<https://youtu.be/NPiXuN9kInI?si=Ks1yMkuGASdtGD79>
(Inteligencia Artificial y Teledetección).

Aplicaciones IA y teledetección en Colombia

Aplicación	Descripción	Ejemplos de uso
Clasificación automática de coberturas	Uso de algoritmos supervisados (e.g., Random Forest, SVM, CNN) para mapear cultivos, bosques, cuerpos de agua	Agricultura de precisión, ordenamiento territorial
Segmentación y detección de objetos	Deep learning con imágenes de drones o satélites para identificar parcelas, vías, techos, deforestación	Catastro, infraestructura, monitoreo ambiental
Detección de anomalías	IA para detectar cambios súbitos (e.g., incendios, inundaciones, invasiones urbanas)	Gestión de riesgos y desastres
Estimación de variables biofísicas	Modelos de ML para predecir biomasa, humedad del suelo, rendimiento de cultivos	Agricultura y silvicultura
Fusión de datos multifuente	Redes neuronales o modelos híbridos para combinar datos ópticos, radar, climáticos, etc.	Sistemas de alerta temprana y monitoreo multitemporal

Aplicaciones de Teledetección en el mundo

Aplicación	Descripción	País / Proyecto destacado
 Agricultura de precisión	Monitoreo de cultivos, estrés hídrico, predicción de rendimientos	US EE.UU. – John Deere, Climate FieldView
 Gestión de recursos hídricos	Seguimiento de cuerpos de agua, humedad del suelo, calidad y caudal	IN India – Cuenca del Ganges
 Monitoreo ambiental y cambio climático	Evaluación de deforestación, emisiones, desertificación	 Global – Global Forest Watch (Brasil, Congo, Indonesia)
 Gestión de desastres	Prevención y respuesta ante incendios, inundaciones, terremotos	AU Australia – Alerta de incendios forestales
 Planeación urbana y expansión	Análisis de crecimiento urbano, uso del suelo, zonificación	CN China – Ciudades inteligentes en Pekín y Shenzhen
 Minería y geología	Exploración de minerales y control ambiental	CL Chile – Exploración de cobre con imágenes satelitales
 Seguridad alimentaria	Anticipación de sequías, apoyo a programas humanitarios	 África – FAO/WFP usando NDVI y CHIRPS
 Oceanografía y monitoreo costero	Seguimiento de temperatura, floraciones algales, erosión y derrames	PE Perú – Monitoreo del fenómeno El Niño con Sentinel-3
 Arqueología y patrimonio	Descubrimiento de ruinas ocultas y monitoreo de sitios culturales	GT Guatemala – Ciudades mayas con LiDAR
 Defensa y vigilancia	Observación de fronteras, movimientos, embarcaciones y cambios territoriales	UA Ucrania – Monitoreo de infraestructura y conflicto

CONCLUSIÓN

- Este fue un curso de Teledetección, enfocado a la comprensión profunda de las Imágenes Pasivas y Activas, Fundamentos y Machine Learning.
- Durante este curso se consolidaron los conocimientos teóricos y prácticos necesarios para comprender y aplicar técnicas de teledetección basadas en sensores pasivos (plataformas satelitales como Sentinel-2, MODIS) y activos (como Sentinel-1 o radares SAR). Se analizaron sus principios físicos, ventajas comparativas, limitaciones y aplicaciones en el monitoreo de la superficie terrestre.
- Se abordaron las características técnicas de las plataformas satelitales y de drones
- En la teledetección pasiva, se abordaron conceptos como la reflectancia espectral, índices de vegetación (NDVI, EVI, etc.), y el uso de espectros multispectrales e hiperespectrales para la caracterización biofísica de coberturas. Por su parte, la teledetección activa permitió explorar la utilidad de la polarización (HH, HV, VV, VH) y el coeficiente CR para el análisis de estructuras, humedad del suelo y cobertura vegetal, incluso en condiciones de nubosidad.

CONCLUSIÓN



Complementariamente, se introdujeron técnicas de **aprendizaje automático supervisado**, como Random Forest, SVM y XGBoost, para realizar clasificaciones temáticas, segmentaciones y predicciones basadas en información espectral y polarimétrica. Estas herramientas permitieron automatizar la interpretación de imágenes, mejorar la precisión de los análisis y generar productos útiles para agricultura, monitoreo ambiental, gestión del territorio y cambio climático.



Se abordó el manejo de Google Earth Engine, plataforma de descarga de imágenes Copernicus, Sentinel Hub y directamente desde Python en Google Colab



Se presentó el manejo de plataformas de procesamiento de imágenes multiespectrales como QGIS y SNAP.



Este enfoque integral capacita al estudiante para abordar desafíos reales con un criterio científico-técnico, integrar fuentes de datos complementarias, y diseñar flujos de trabajo reproducibles que conectan la adquisición de imágenes satelitales y de dron con el análisis avanzado basado en inteligencia artificial.

CONCLUSIÓN

- Este fue un curso de Teledetección, enfocado a la comprensión profunda de las Imágenes Pasivas y Activas, Fundamentos y Machine Learning.
- Durante este curso se consolidaron los conocimientos teóricos y prácticos necesarios para comprender y aplicar técnicas de teledetección basadas en sensores pasivos (plataformas satelitales como Sentinel-2, MODIS) y activos (como Sentinel-1 o radares SAR). Se analizaron sus principios físicos, ventajas comparativas, limitaciones y aplicaciones en el monitoreo de la superficie terrestre.
- Se abordaron las características técnicas de las plataformas satelitales y de drones
- En la teledetección pasiva, se abordaron conceptos como la reflectancia espectral, índices de vegetación (NDVI, EVI, etc.), y el uso de espectros multispectrales e hiperespectrales para la caracterización biofísica de coberturas. Por su parte, la teledetección activa permitió explorar la utilidad de la polarización (HH, HV, VV, VH) y el coeficiente CR para el análisis de estructuras, humedad del suelo y cobertura vegetal, incluso en condiciones de nubosidad.

CONCLUSIÓN

- Complementariamente, se introdujeron técnicas de **aprendizaje automático supervisado**, como Random Forest, SVM y XGBoost, para realizar clasificaciones temáticas, segmentaciones y predicciones basadas en información espectral y polarimétrica. Estas herramientas permitieron automatizar la interpretación de imágenes, mejorar la precisión de los análisis y generar productos útiles para agricultura, monitoreo ambiental, gestión del territorio y cambio climático.
- Se abordó el manejo de Google Earth Engine, plataforma de descarga de imágenes Copernicus, Sentinel Hub y directamente desde Python en Google Colab
- Se presentó el manejo de plataformas de procesamiento de imágenes multiespectrales como QGIS y SNAP.
- Este enfoque integral capacita al estudiante para abordar desafíos reales con un criterio científico-técnico, integrar fuentes de datos complementarias, y diseñar flujos de trabajo reproducibles que conectan la adquisición de imágenes satelitales y de dron con el análisis avanzado basado en inteligencia artificial.

[illegible]