



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,
Cartográfica y Topográfica

Desarrollo de una app en Google Earth Engine para
identificación de cultivos en parcelas agrícolas

Trabajo Fin de Máster

Máster Universitario en Ingeniería Geomática y Geoinformación

AUTOR/A: Blázquez Tercero, Raquel

Tutor/a: Recio Recio, Jorge Abel

CURSO ACADÉMICO: 2024/2025



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA

UNIVERSITAT POLITÈCNICA DE VALÈNCIA
Escuela Técnica Superior de Ingeniería Geodésica,
Cartográfica y Topográfica

Desarrollo de una app en Google Earth Engine para identificación de cultivos en parcelas agrícolas

Trabajo Fin de Máster

Máster Universitario en Ingeniería Geomática y Geoinformación

AUTOR/A: Blázquez Tercero, Raquel

Tutor/a: Recio Recio, Jorge Abel

CURSO ACADÉMICO: 2024/2025

AGRADECIMIENTOS

" A la Escuela Técnica Superior de Ingeniería Geodésica, Cartográfica y Topográfica, por proporcionarme las bases del conocimiento que hoy poseo, en concreto agradecer a mi tutor Jorge Abel Recio Recio por su orientación durante este proyecto y su paciencia.

A mi empresa Idrica y a todos mis compañeros del equipo Implantación y del Equipo de GIS, que han sido un pilar fundamental para mi desarrollo profesional, superando día a día nuevos retos y aprendiendo nuevos conocimientos, a la vez que me ha aportado grandes experiencias.

Agradecer a mi familia, que siempre está apoyándome en todos los pasos que doy y siempre confiando en mis capacidades de superación.

Agradecer también, a todo aquel que dedique su tiempo a leer este trabajo

Y, sobre todo, agradecer y dedicar este trabajo a aquellas personas que me inspiraron y apoyaron y no han podido llegar a ver el resultado final."

"El presente documento ha sido realizado completamente por el firmante; no ha sido entregado como otro trabajo académico previo y todo el material tomado de otras fuentes ha sido convenientemente entrecomillado y citado su origen en el texto, así como referenciado en la bibliografía"

26/08/2025

X



Raquel Blázquez Tercero
Estudiante

Firmado por: f7294896-6a4d-4607-97e3-6506338d153f

RESUMEN

En el panorama actual, donde la tecnología y el acceso a la información geoespacial avanzan de forma exponencial, la teledetección y el aprendizaje automático (ML) han emergido como herramientas transformadoras en la agricultura. Ante la necesidad de obtener datos precisos y a gran escala para afrontar desafíos globales como el cambio climático o la seguridad alimentaria, este trabajo presenta el desarrollo de una herramienta de código abierto en Google Earth Engine (GEE). El objetivo principal de esta herramienta es la detección automática de cultivos mediante un aprendizaje supervisado de entrenamiento de modelos y su posterior evaluación, todo ello mediante una interfaz accesible para los usuarios.

La metodología empleada, integra datos de acceso libre de Sentinel-1, Sentinel-2 y Landsat procedentes de GEE, dándolos un enfoque en el procesamiento de series temporales para identificar la firma fenológica de los cultivos. Para ello, se corregirán dichas imágenes temporales con diferentes técnicas de corrección de ruido en imágenes satelitales, se calcularán índices representativos para la identificación de cultivos (NDVI, EVI, SAVI...), tras esto se entrenará al modelo mediante algoritmos clasificadores para que hagan la detección del tipo de cultivo y tras esto analizaremos mediante diferentes evaluadores, la calidad y precisión del modelo que hemos entrenado.

Como resultado, la aplicación demostró ser capaz de identificar diferentes tipos de cultivos con una gran facilidad y consiguió proporcionar una evaluación objetiva de la precisión con la que el modelo realizó la clasificación. Además, se pudo comprobar el correcto funcionamiento de todos los pasos que llevaban a el análisis completo, tanto de corrección como obtención de series temporales e índices como la parte de clasificación y evaluación del modelo generado.

La aplicación ofrece una solución para los desafíos de la agricultura moderna, tal como la clasificación automática de diferentes cultivos, a la vez que se adapta a las nuevas tecnologías de ML implantando diferentes algoritmos que se emplean actualmente en multitud de ámbitos. Esta aplicación sirve como base para futuros desarrollos, ya que se presenta como una aplicación modular permitiendo que los componentes puedan reutilizarse e integrarse en otros proyectos desde la plataforma de GEE y haciendo que el análisis geoespacial sea accesible a un público mucho más amplio.

Palabras clave: Teledetección, Google Earth Engine, Machine Learning, Clasificación de Cultivos, Series Temporales

ABSTRACT

In today's world, where technology and access to geospatial information are advancing exponentially, remote sensing and machine learning (ML) have emerged as transformative tools in agriculture. Given the need to obtain accurate, large-scale data to address global challenges such as food security and climate change, this paper presents the development of an open-source tool on the Google Earth Engine (GEE). The main objective of this tool is the automatic detection of crops through supervised model training and subsequent evaluation, all through an accessible user interface.

The methodology used integrates open access data from Sentinel-1, Sentinel-2 and Landsat from GEE, focusing on the processing of time series to identify the phenological signature of crops. To do this, these temporal images will be corrected using different satellite image noise correction techniques, representative indices for crop identification (NDVI, EVI, SAVI, etc.) will be calculated, and then the model will be trained using classification algorithms to detect the type of crop. After this, we will analyse the quality and accuracy of the model we have trained using different evaluators.

As a result, the application proved capable of identifying different types of crops with great ease and provided an objective assessment of the accuracy with which the model performed the classification. In addition, it was possible to verify the correct functioning of all the steps leading to the complete analysis, both in terms of correction and obtaining time series and indices, as well as the classification and evaluation of the generated model.

The application offers a solution to the challenges of modern agriculture, such as the automatic classification of different crops, while adapting to new ML technologies by implementing different algorithms that are currently used in a multitude of fields. This application serves as a basis for future developments, as it is presented as a modular application allowing components to be reused and integrated into other projects from the GEE platform, making geospatial analysis accessible to a much wider audience.

Keywords: Remote Sensing, Google Earth Engine, Machine Learning, Crop Classification, Time Series

INDICE DE FIGURAS

Figura 1: Fotografía aérea Sentinel-1 enero 2020(Fuente: GEE)

Figura 2: Fotografía aérea Sentinel-2 enero 2020(Fuente: GEE)

Figura 3: Imagen de Landsat 8 cortesía del Servicio Geológico de EE. UU. Enero a marzo de 2020 (Fuente: Mediante GEE)

Figura 4: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

Figura 5: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

Figura 6: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

Figura 7: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

Figura 8: Muestra de parcela preparada para evaluación (Fuente: Elaboración propia)

Figura 9: Muestra de interfaz de GEE (Fuente: Elaboración propia)

Figura 10: Muestra de interfaz de GEE con la aplicación (Fuente: Elaboración propia)

Figura 11: Muestra de interfaz de GEE con el paso 0 (Fuente: Elaboración propia)

Figura 12: Muestra de interfaz de GEE con el paso 1 (Fuente: Elaboración propia)

Figura 13: Muestra de interfaz de GEE con el paso 2 (Fuente: Elaboración propia)

Figura 14: Muestra de interfaz de GEE con el paso 3 (Fuente: Elaboración propia)

Figura 15: Muestra de interfaz de GEE con el paso 4 (Fuente: Elaboración propia)

Figura 16: Muestra de visualización tras el cálculo de una banda (Fuente: Elaboración propia)

Figura 17: Comportamiento de la reflectancia sobre diferentes superficies (Fuente: Presentación de Amber McCullum (BAERI), Britnay Beaudry (BAERI), Juan Torres-Pérez (NASA ARC), Sativa Cruz (BAERI), Índices Espectrales para Aplicaciones Terrestres y Acuáticas, Sesión 1: Resumen General de los Índices Espectrales)

Figura 18: Suavizado de una serie temporal (Fuente: documentación de ArcGIS Pro-3.4)

Figura 19: Grafica de suavizado (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/29938f5fcf023a281d71f98323cb0281>)

Figura 20: Grafica de relleno de huecos temporales (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/9477d1c8738d9a879e9f0d86c5e11cb0>)

Figura 21: Grafica del proceso de interpolación (Fuente: Presentación de Time-Series Processing using Google Earth Engine Ujaval Gandhi Spatial Thoughts October 2022)

Figura 22: Grafica de interpolación (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/fe4e9c27f262efc5bdbc7610fa03b146>)

Figura 23: Grafica del filtro Savitzky-Golay (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/ffd0b9b3c372d5e21181a6144acb0ae3>)

Figura 24: Muestra de interfaz para seleccionar índices y tecnicas de corrección de ruido de GEE en el paso 4 (Fuente: Elaboración propia)

Figura 25: Muestra de mapeo de bandas en el código de GEE en el paso 4 (Fuente: Elaboración propia)

Figura 26: Muestra de interfaz de GEE con el paso 5 (Fuente: Elaboración propia)

Figura 27: Muestra de interfaz para seleccionar índices, composición y periodo temporal de GEE en el paso 4 (Fuente: Elaboración propia)

Figura 28: Muestra de interfaz de GEE con el paso 6 (Fuente: Elaboración propia)

Figura 29: Muestra de interfaz de GEE con el paso 7 (Fuente: Elaboración propia)

Figura 30: Flujo de trabajo de una clasificación supervisada para el paso 7 (Fuente: Técnicas de clasificación de imágenes de satélite en ciencias forestales, Rafael M^a NAVARRO CERRILLO, M^a Ángeles VARO MARTÍNEZ, Antonio J. ARIZA SALAMANCA. Víctor RODRÍGUEZ GALIANO)

Figura 31: Muestra de interfaz de GEE con el paso 8 (Fuente: Elaboración propia)

Figura 32: Formato de una matriz de confusión para el paso 8 (Fuente: Comprensión de la Matriz de Confusión y Cómo Implementarla en Python, Admond Lee)

Figura 33: Muestra de la guía de usuario del paso 0 (Fuente: Elaboración propia)

Figura 34: Muestra del resultado del paso 1 (Fuente: Elaboración propia)

Figura 35: Muestra del resultado del paso 2 (Fuente: Elaboración propia)

Figura 36: Muestra del resultado del paso 3 para mascara de nubes (Fuente: Elaboración propia)

Figura 37: Muestra del resultado del paso 4 para cálculo de bandas (Fuente: Elaboración propia)

Figura 38: Muestra del resultado del paso 4 para graficas de tecnicas de corrección de ruido (Fuente: Elaboración propia)

Figura 39: Muestra del resultado del paso 4 error de límite de memoria excedido (Fuente: Elaboración propia)

Figura 40: Muestra del resultado del paso 5 (Fuente: Elaboración propia)

Figura 41: Muestra del resultado del paso 6 (Fuente: Elaboración propia)

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE
CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

Figura 42: Muestra del resultado del paso 7 (Fuente: Elaboración propia)

Figura 43: Muestra del resultado de la clasificación del paso 8 (Fuente: Elaboración propia)

Figura 44: Muestra del resultado de las recomendaciones del paso 8 (Fuente: Elaboración propia)

Figura 45: Muestra del resultado de la interpretación de índices del paso 8 (Fuente: Elaboración propia)

Figura 46: Muestra de limitaciones de GEE (Fuente: GEE)

INDICE DE TABLAS

Tabla 1: Bandas para Sentinel-1(Fuente: GEE)

Tabla 2: Bandas para Sentinel-2(Fuente: GEE)

Tabla 3: Bandas para Landsat 8(Fuente: GEE)

Tabla 4: Presupuesto (Fuente: Elaboración propia)

Esquema 1: Flujo general de trabajo de la aplicación (Fuente: Elaboración propia)

Esquema 2: Flujo de trabajo del paso 0 (Fuente: Elaboración propia)

Esquema 3: Flujo de trabajo del paso 1 (Fuente: Elaboración propia)

Esquema 4: Flujo de trabajo del paso 2 (Fuente: Elaboración propia)

Esquema 5: Flujo de trabajo del paso 3 (Fuente: Elaboración propia)

Esquema 6: Flujo de trabajo del paso 4 (Fuente: Elaboración propia)

Esquema 7: Flujo de trabajo del paso 5 (Fuente: Elaboración propia)

Esquema 8: Flujo de trabajo del paso 6 (Fuente: Elaboración propia)

Esquema 9: Flujo de trabajo del paso 7 (Fuente: Elaboración propia)

Esquema 10: Flujo de trabajo del paso 8 (Fuente: Elaboración propia)

Índice

RESUMEN	1
ABSTRACT	2
INDICE DE FIGURAS	3
INDICE DE TABLAS	6
INTRODUCCIÓN	8
OBJETIVOS.....	9
DATOS	11
METODOLOGÍA	18
RESULTADOS.....	58
PRESUPUESTO	68
CONCLUSIONES	70
BIBLIOGRAFÍA.....	72
ANEXOS.....	74

INTRODUCCIÓN

En la actualidad, la agricultura se ha ido encontrando con diferentes problemáticas globales, así encontramos la seguridad alimentaria, la presión sobre recursos naturales o el impacto del cambio climático entre otras. Ante esta necesidad, se ha vuelto una tarea fundamental obtener información precisa y a gran escala sobre el estado del suelo, vegetación y de cultivos.

En este contexto, la teledetección ha emergido como una herramienta indispensable para el monitoreo y la gestión agrícola a gran escala (Weiss et al., 2020). Paralelamente, también emerge la clasificación de cultivos, que surge como un pilar fundamental para abordar los nuevos desafíos y problemáticas.

Históricamente, la clasificación de usos del suelo, concretamente de los cultivos, dependía de software costosos o métodos demasiado manuales que solo podían realizarlos determinados expertos, pero ante el desproporcionado crecimiento de las tecnologías, los avances en la teledetección como la mejora en la resolución espacial, espectral y temporal de los satélites y la mayor disponibilidad de datos satelitales abiertos casi a tiempo real desde cualquier parte del mundo han transformado el panorama donde se enmarca, convirtiendo la teledetección en una herramienta fundamental para el monitoreo ambiental, la planificación territorial y la gestión de recursos naturales (EOS Data Analytics, 2024).

La clasificación de cultivos ha evolucionado drásticamente, beneficiándose de la capacidad de la teledetección para capturar series temporales de datos y de la potencia del aprendizaje automático para procesar esta información con alta precisión (Lary et al., 2016). Para enfrentar estos problemas, se han ido implantando una gran variedad de métodos y tecnologías avanzadas que han convertido lo que antes era un problema costoso y manual en una solución eficiente, accesible y escalable, pasando de una gestión de pequeña escala a una visión global y detallada de los cultivos.

El aprendizaje automático (ML), tiene un papel fundamental en diferentes ámbitos, no solo porque permite la clasificación de los datos con una elevada precisión, sino que también sirve como un método automático para tomar decisiones. En nuestro ámbito, el aprendizaje automático, entrena modelos para reconocer patrones sobre grandes volúmenes de datos satelitales, esto reduce significativamente la necesidad de intervención manual y se acelera el proceso de análisis (Repuestos Fuster, 2024). La gran capacidad de los algoritmos para aprender de los datos, e ir mejorando con el tiempo, es lo que permite que el monitoreo agrícola sea dinámico.

Actualmente, existen diferentes metodologías e investigaciones que se aplican para la clasificación de los cultivos. El punto común es el uso de series temporales multispectrales que aprovechan el ciclo fenológico de las plantas para diferenciar los diferentes tipos de cultivos, basándose en los cultivos estacionales. Para el cálculo de

estos valores, se utilizan una gran variedad de índices espectrales que, mediante cálculos matemáticos, combinan las diferentes bandas de satélite que realzan diferentes propiedades específicas del agua, suelo y vegetación. Algunos de los índices más utilizados, y que aparecen en nuestra aplicación, so: NDVI (Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index) o SAVI (Soil Adjusted Vegetation Index).

Estas metodologías, combinadas con algoritmos de aprendizaje automático como Random Forest, Support Vector Machines o redes neuronales, han demostrado una gran eficacia en la clasificación precisa de cultivos a nivel regional y global (NASA Applied Sciences, 2021).

Es aquí, dentro del campo de la geomática, donde surge la idea de la creación de la aplicación que se ha desarrollado y documentado en este trabajo. La aplicación busca el acceso libre a tecnologías de teledetección avanzadas, ya que desarrolla una herramienta de código abierto en la plataforma Google Earth Engine (GEE). Como propósito principal, la aplicación busca la automatización completa de un flujo de trabajo de teledetección para la detección automática de cultivos, desde la importación de datos satelitales y el preprocesamiento de estos datos, hasta la clasificación con algoritmos de ML y la evaluación de los resultados. Esta aplicación busca transformar datos brutos en información útil, visual y accesible, permitiendo a usuarios sin habilidades avanzadas en programación ejecutar análisis complejos de forma automática.

OBJETIVOS

El objetivo principal de este proyecto es crear una herramienta dentro del ámbito de la teledetección que sea funcional y de código abierto en la plataforma de Google Earth Engine (GEE).

La función principal de esta aplicación será la automatización de un proceso completo de detección automática de cultivos, desde la importación de datos, pasando por el preprocesamiento de los datos satelitales seleccionados, hasta la clasificación y evaluación de estos mediante algoritmos de aprendizaje automático (Machine learning).

Esta aplicación está diseñada para facilitar el acceso a los usuarios a recursos de teledetección sin necesidad de un software costoso y para que el usuario pueda llevar a cabo cálculos complejos sin necesidad de tener habilidades avanzadas en programación.

La aplicación está orientada a dar a los usuarios con experiencia en el campo de la teledetección, o experiencia en otros campos afines como agricultura, gestión ambiental o planificación territorial, una solución efectiva y rápida para grandes conjuntos de datos geoespaciales.

Con el desarrollo de esta aplicación se busca tener una interfaz intuitiva, con parámetros fácilmente seleccionables por el usuario, y también que sea interactiva, mediante la muestra de resultados en un mapa y los resultados en pantalla. También permite la exportación de resultados en varios apartados del proceso, evaluar la presión del modelo seleccionado y poder visualizar diferentes resultados en la interfaz

La arquitectura de la aplicación permite la integración de nuevas funcionalidades, permite a todo aquel que lo necesite hacer nuevos desarrollos sin tener que empezar la aplicación desde cero. Así, esta aplicación se convierte en un modelo flexible, escalable y dinámica.

Aparte de estos objetivos, la aplicación tiene la posibilidad de hacer estudios personalizables al poder seleccionar varios catálogos de imágenes, rangos de fechas diferentes, diferentes maneras de corregir las imágenes satélites y la selección de diferentes índices y formas de clasificación. Para alcanzar dicha funcionalidad, se han definido varios objetivos específicos que se han implementado a lo largo del desarrollo de la aplicación:

- Diseñar toda la aplicación en base a un flujo de trabajo completo de detección automática de cultivos con ML y su posterior evaluación de resultados, este diseño de flujo debe ser claro y organizado y se debe mostrar sobre una interfaz de usuario.
- Identificar las fuentes de datos más adecuadas para la clasificación de cultivos. Se han definido las colecciones de Sentinel-2, Sentinel-1 y Landsat, con sus periodos temporales correspondientes.
- Implementar las correcciones a las imágenes satelitales, aquí se incluye la reducción de ruido y las correcciones atmosféricas.
- Incluir el cálculo de bandas e índices espectrales con gran precisión. Hay que incluir índices espectrales clave para la identificación de cultivos
- Entrenar el modelo basándose en los algoritmos de ML de clasificación supervisada
- Validar la precisión de la clasificación mediante métricas estándar de evaluación como la matriz de confusión, el coeficiente Kappa y la precisión general.

DATOS

En este apartado estudiaremos dos tipos de datos, las colecciones que utilizamos para basar el análisis y la construcción de unos correctos datos de entrada (para este proyecto un shapefile).

La base de este proyecto está en el uso de datos satelitales de acceso abierto, disponibles a través de la plataforma de análisis geoespacial Google Earth Engine (GEE). Se han seleccionado tres misiones clave por su alta resolución espacial, espectral, y temporal, la combinación de datos ópticos (Sentinel-2 y Landsat 8) y datos de radar (Sentinel-1), nos proporcionan un estudio agrícola bastante completo, aprovechando estas diferencias en tipos de toma de imágenes podemos hacer el mismo análisis de forma más robusta, especialmente en zonas que son propensas a la nubosidad.

Colecciones y Variables de Datos utilizadas para la aplicación.

Las colecciones de imágenes en GEE se identifican con un ID único. Para este proyecto, se utilizarán las siguientes:

Sentinel-1: Se usará la colección de imágenes del Radar de Apertura Sintética (SAR) de banda C con doble polarización a 5.405 GHz, procesadas a coeficiente de retrodispersión Ground Range Detected (GRD). Este sensor activo emite y recibe microondas, lo que le permite obtener imágenes de la superficie terrestre de forma independiente de las condiciones lumínicas y meteorológicas.

El id de la colección es: COPENNICUS/S1_GRD

Los datos proporcionados, proceden del programa Copernicus de la ESA (Agencia Espacial Europea). La colección se actualiza todos los días y los datos se transfieren con un lapso de 2 días después de estar disponibles. El tamaño del píxel cambia dependiendo de la banda. El intervalo de revisión es de 6 días y tenemos datos desde el 03-10-2014

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero



Figura 1: Fotografía aérea Sentinel-1 enero 2020(Fuente: GEE)

VARIABLES (BANDAS):

Nombre	Unidades	Mín.	Máx.	Tamaño de los píxeles	Descripción
HH	dB	-50*	1*	10 metros	Polarización única, transmisión horizontal/recepción horizontal
HV	dB	-50*	1*	10 metros	Polarización cruzada de doble banda, transmisión horizontal y recepción vertical
VV	dB	-50*	1*	10 metros	Polarización única, transmisión vertical/recepción vertical
VH	dB	-50*	1*	10 metros	Polarización cruzada de doble banda, transmisión vertical y recepción horizontal
angle	°	0*	90*	20,000 metros	Aproximación del ángulo de incidencia desde el elipsoide

* Valor mínimo o máximo estimado

Tabla 1: Bandas para Sentinel-1(Fuente: GEE)

Sentinel-2: Se usará la colección de imágenes corregidas atmosféricamente, lo que se conoce como Reflectancia de la Superficie (Level-2A). Esta colección tiene el id: COPERNICUS/S2_SR_HARMONIZED

Los datos proporcionados, proceden del programa Copernicus de la ESA (Agencia Espacial Europea) mediante dos satélites (2A y 2). Contienen las imágenes multiespectrales de alta resolución y ancho de franja que respalda los estudios de monitoreo terrestre de Copernicus. Los datos se calcularon ejecutando sen2cor. El tamaño del pixel, es variable según la banda utilizada.

El intervalo de revisión es de 5 días y tenemos datos desde el 28-03-2017

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero



Figura 2: Fotografía aérea Sentinel-2 enero 2020(Fuente: GEE)

Variables (bandas espectrales):

Nombre	Unidades	Mín.	Máx.	Escala	Tamaño de los píxeles	Longitud de onda	Descripción
B1				0.0001	60 metros	443.9 nm (S2A) y 442.3 nm (S2B)	Aerosoles
B2				0.0001	10 metros	496.6 nm (S2A) / 492.1 nm (S2B)	Azul
B3				0.0001	10 metros	560 nm (S2A) / 559 nm (S2B)	Verde
B4				0.0001	10 metros	664.5 nm (S2A) / 665 nm (S2B)	Rojo
B5				0.0001	20 metros	703.9 nm (S2A) / 703.8 nm (S2B)	Borde rojo 1
B6				0.0001	20 metros	740.2 nm (S2A) / 739.1 nm (S2B)	Borde rojo 2
B7				0.0001	20 metros	782.5 nm (S2A) y 779.7 nm (S2B)	Borde rojo 3
B8				0.0001	10 metros	835.1 nm (S2A) y 833 nm (S2B)	NIR
B8A				0.0001	20 metros	864.8 nm (S2A) y 864 nm (S2B)	Borde rojo 4
B9				0.0001	60 metros	945 nm (S2A) / 943.2 nm (S2B)	Vapor de agua
B11				0.0001	20 metros	1613.7 nm (S2A) / 1610.4 nm (S2B)	SWIR 1
B12				0.0001	20 metros	2202.4 nm (S2A) / 2185.7 nm (S2B)	SWIR 2
AOT				0.001	10 metros	Ninguna	Grosor óptico del aerosol
WVP	cm			0.001	10 metros	Ninguna	Presión de vapor de agua Altura que ocuparía el agua si el vapor se condensara en líquido y se extendiera de manera uniforme por la columna.
SCL		1	11		20 metros	Ninguna	Mapa de clasificación de escenas (se enmascara el valor "Sin datos" de 0)
TCE_R					10 metros	Ninguna	Imagen en color verdadero, canal rojo
TCE_G					10 metros	Ninguna	Imagen en color verdadero, canal verde
TCE_B					10 metros	Ninguna	Imagen en color verdadero, canal azul
MSK_CLOUDPB		0	100		20 metros	Ninguna	Mapa de probabilidad de nubes (falta en algunos productos)
MSK_SNOWPB		0	100		10 metros	Ninguna	Mapa de probabilidad de nieve (falta en algunos productos)
QA1B					10 metros	Ninguna	Siempre vacío
QA2B					20 metros	Ninguna	Siempre vacío
QA6B					60 metros	Ninguna	Máscara de nubes. Se enmascara entre el 25 de enero de 2022 y el 28 de febrero de 2024, inclusive.

Tabla 2: Bandas para Sentinel-2(Fuente: GEE)

Lanpíxel8: Se utilizará la colección de Reflectancia de la Superficie de la Colección 2, Nivel 2. Esta colección tiene el id: LANDSAT/LC08/C02/T1_L2.

Los datos que proporciona la colección 2, que produce la USGS (U.S. Geological Survey) contiene la reflectancia de la superficie corregida atmosféricamente y la temperatura de la superficie de los datos producidos de los sensores OLI/TIRS. Este conjunto de datos, tiene un tamaño del píxel de 30 metros. El intervalo de revisión es de 16 días y tenemos datos desde 18-03-2013.

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero




Figura 3: Imagen de Landsat 8 cortesía del Servicio Geológico de EE. UU. Enero a marzo de 2020 (Fuente: Mediante GEE)

Variables (bandas espectrales):

Nombre	Unidades	Mín.	Máx.	Escala	Desplazamiento	Tamaño de los píxeles	Longitud de onda	Descripción
SR_B1		1	65455	2.75e-05	-0.2	metros	0.435-0.451 μm	Reflectancia de la superficie de la banda 1 (azul ultra, aerosol costero)
SR_B2		1	65455	2.75e-05	-0.2	metros	0.452-0.512 μm	Reflectancia de la superficie de la banda 2 (azul)
SR_B3		1	65455	2.75e-05	-0.2	metros	0.533-0.590 μm	Reflectancia de la superficie de la banda 3 (verde)
SR_B4		1	65455	2.75e-05	-0.2	metros	0.636 a 0.673 μm	Reflectancia de la superficie de la banda 4 (rojo)
SR_B5		1	65455	2.75e-05	-0.2	metros	0.851 a 0.879 μm	Reflectancia de la superficie de la banda 5 (infrarrojo cercano)
SR_B6		1	65455	2.75e-05	-0.2	metros	1.566 a 1.651 μm	Reflectancia de la superficie de la banda 6 (infrarrojo de onda corta 1)
SR_B7		1	65455	2.75e-05	-0.2	metros	2.107 a 2.294 μm	Reflectancia de la superficie de la banda 7 (infrarrojo de onda corta 2)
SR_QA_AEROSOL						metros	Ninguno	Atributos de aerosol

Tabla 3: Bandas para Landsat 8 (Fuente: GEE)

Preparación del shapefile para el entrenamiento

Para realizar una buena clasificación, nos hemos basado en un sistema de aprendizaje intuitivo y que pasa por hacer una buena muestra de entrenamiento.

Para este proceso, hemos seguido los siguientes pasos:

Creación de la capa shapefile

Lo primero que se ha realizado, es crear una nueva capa shapefile con las características que necesitamos para nuestro estudio, la aplicación utilizará 3 parámetros:

- Id de la parcela: id, es el identificador de la parcela
- Campo de entrenamiento: trsample, es la que se usa para realizar la clasificación, nosotros decimos al clasificador que parcelas usar. Esas parcelas las usa para aprender.
- Campo de evaluación: evsample, este campo contiene los valores para la evaluación.

A modo de resumen, el clasificador usará los campos trsample y el evaluador el campo evsample, por tanto, en la columna trsample añadiremos los valores que vamos a clasificar y en la columna evsample añadiremos los valores que vamos a evaluar y que tengan el valor de 99 en trsample (que es el campo que no usamos), ya que lo que queremos evaluar es lo que no hemos clasificado de forma manual.

Una vez tenemos el shapefile con parcelas delimitadas, tendremos que elegir cuantas clases de cultivos vamos a clasificar, hay que tener en cuenta que cultivos similares pueden llevar a error a no ser que especifiquemos muchos índices o atributos en la clasificación, por ejemplo, suelo desnudo y suelo temporalmente desarbolado, para ciertos periodos o años, puede llevar a error. Para estos casos, es mejor tener información complementaria.

La muestra que hemos realizado para este trabajo, contine 3 clases: arroz, cítricos, suelo y parcelas para no usar.

0: Suelo

1: Arroz

2: Cítricos

99: No Usar

Lo siguiente que hay que hacer es **clasificar nuestras parcelas** con información de referencia, ya sea alguna infraestructura de datos espaciales (IDE), CORINE Land Cover (CLC) o Catastro. En nuestro ejemplo usamos SIOSE (Sistema de Información sobre Ocupación del Suelo de España).

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

Mostraremos a continuación un ejemplo de lo asignado en cada campo:

Campo de entrenamiento 1:

Le agregamos el campo 1 ya que queremos asignarle la clase Arroz y corresponde a Combinación de cultivos con vegetación.

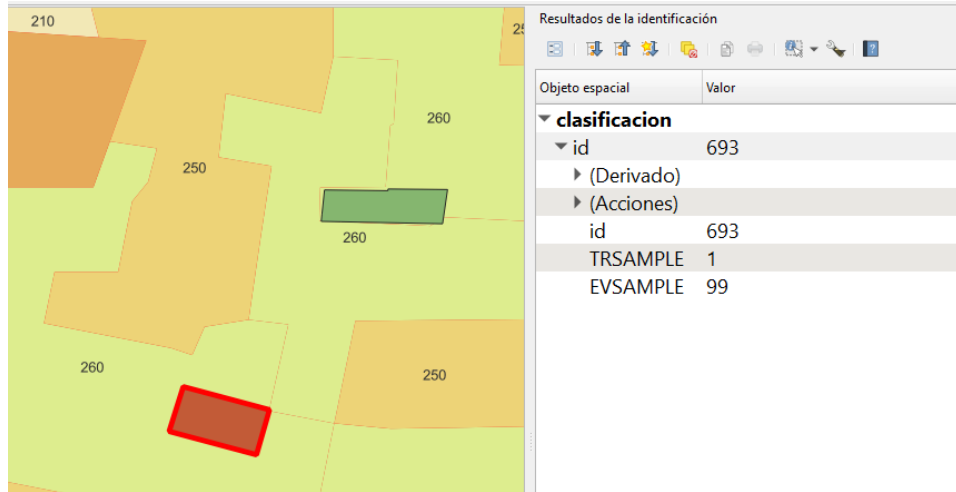


Figura 4: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

Campo de entrenamiento 2:

Le agregamos la clase 2 y evaluación 99 ya que queremos asignarle cítrico y corresponde a frutal cítrico en el SIOSE

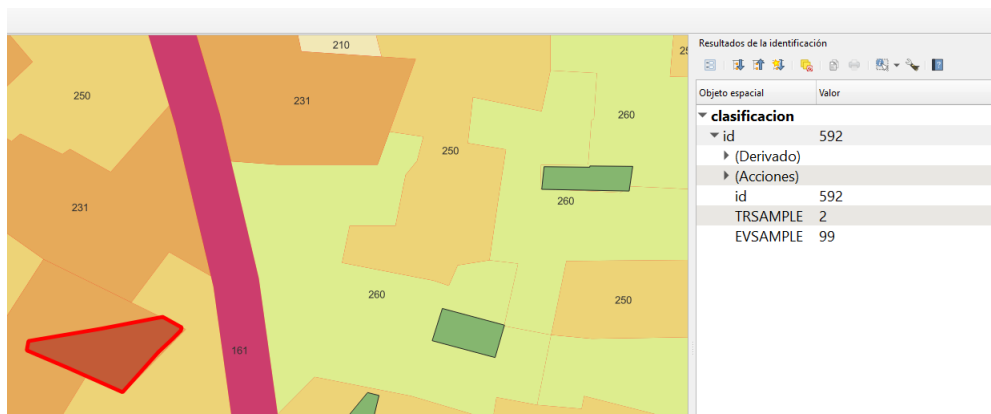


Figura 5: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

Campo de entrenamiento 3:

Corresponde con cultivo herbáceo y le asignaremos un 0 para suelo

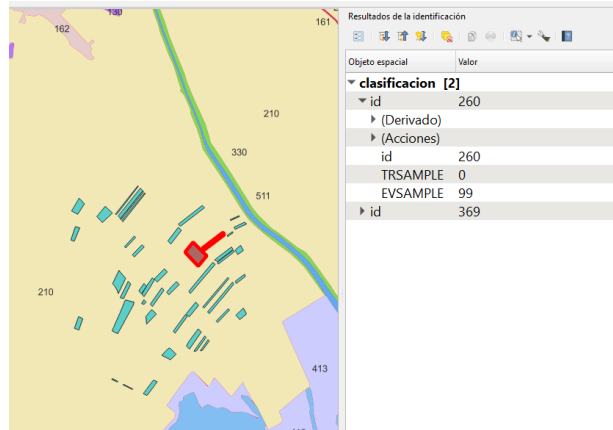


Figura 6: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

Campo de entrenamiento 99:

Este campo no está entrenado, correspondería a combinación de cultivos

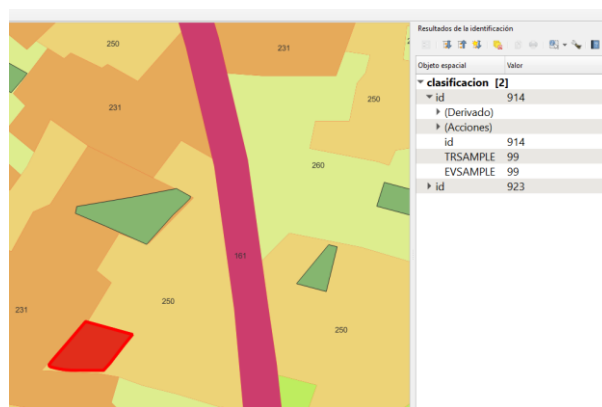


Figura 7: Muestra de parcela entrenada en shapefile (Fuente: Elaboración propia)

Para añadir los **valores de evaluación**, nos fijamos en que parcelas no tenemos clasificadas, tienen un valor 99 y las agregamos unos valores reales a las que queremos evaluar.

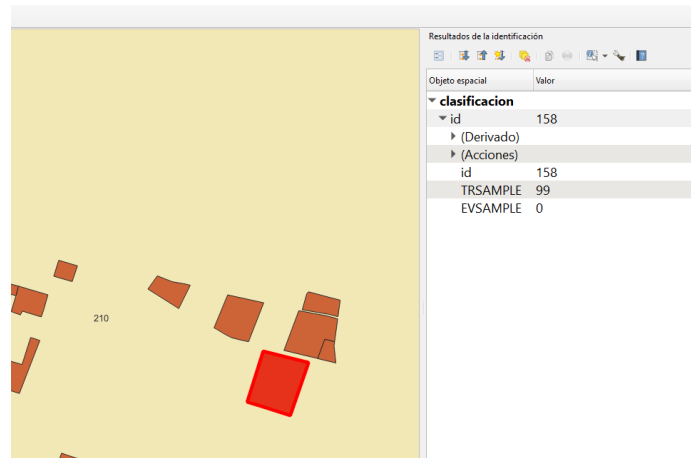


Figura 8: Muestra de parcela preparada para evaluación (Fuente: Elaboración propia)

METODOLOGÍA

La aplicación se basa en un flujo de trabajo estructurado que engloba los diferentes procesos en grupos, tenemos 5 grupos principales y 9 pasos individuales, todo ello a su vez se puede englobar en dos grandes apartados.

Inicialmente, haré una aproximación del flujo de trabajo completo, tras esto, se hará una explicación de cada uno de los pasos separados por bloques. Cada uno de los pasos incluirá:

- a) Explicación general del paso
- b) Información que empleamos en este paso
- c) Flujo de trabajo interno del paso
- d) Variables de entrada y salida del paso
- e) Diseño de la interfaz del paso
- f) Explicación del funcionamiento interno del código para el paso
- g) Resultados tras ejecución del paso

Para el apartado f, hemos utilizado funciones disponibles en las librerías de GEE.

En el apartado g, mencionaremos las salidas que encontramos tras la ejecución del paso, pero resaltaremos los resultados en el siguiente apartado.

Para cada uno de los pasos, se ha grabado un video explicativo sobre el funcionamiento de dicho paso, también se encuentran disponibles en la guía de usuario de la aplicación

Explicación general de la aplicación

Explicación general

La aplicación se ejecuta mediante la interfaz de código abierto de GEE, se puede acceder a la aplicación mediante el enlace que encontramos en los anexos. Para apoyar aún más los procedimientos, cada uno de los pasos también muestra información en consola y en los paneles principales.

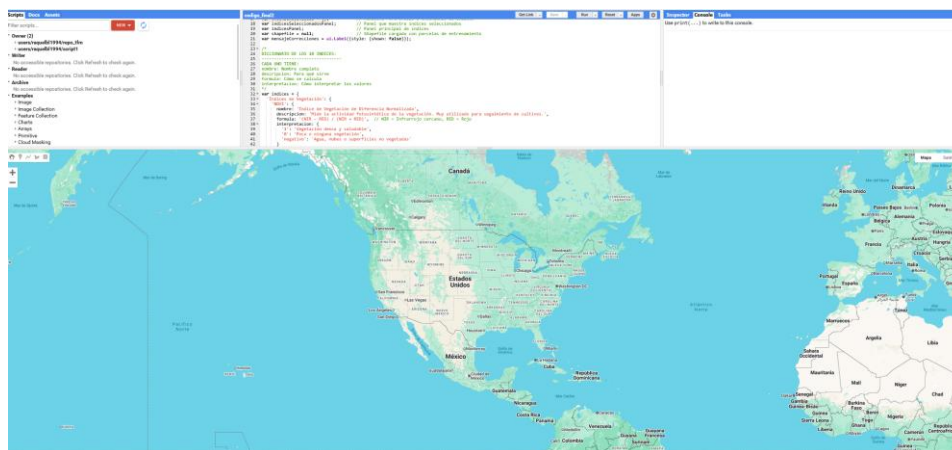


Figura 9: Muestra de interfaz de GEE (Fuente: Elaboración propia)

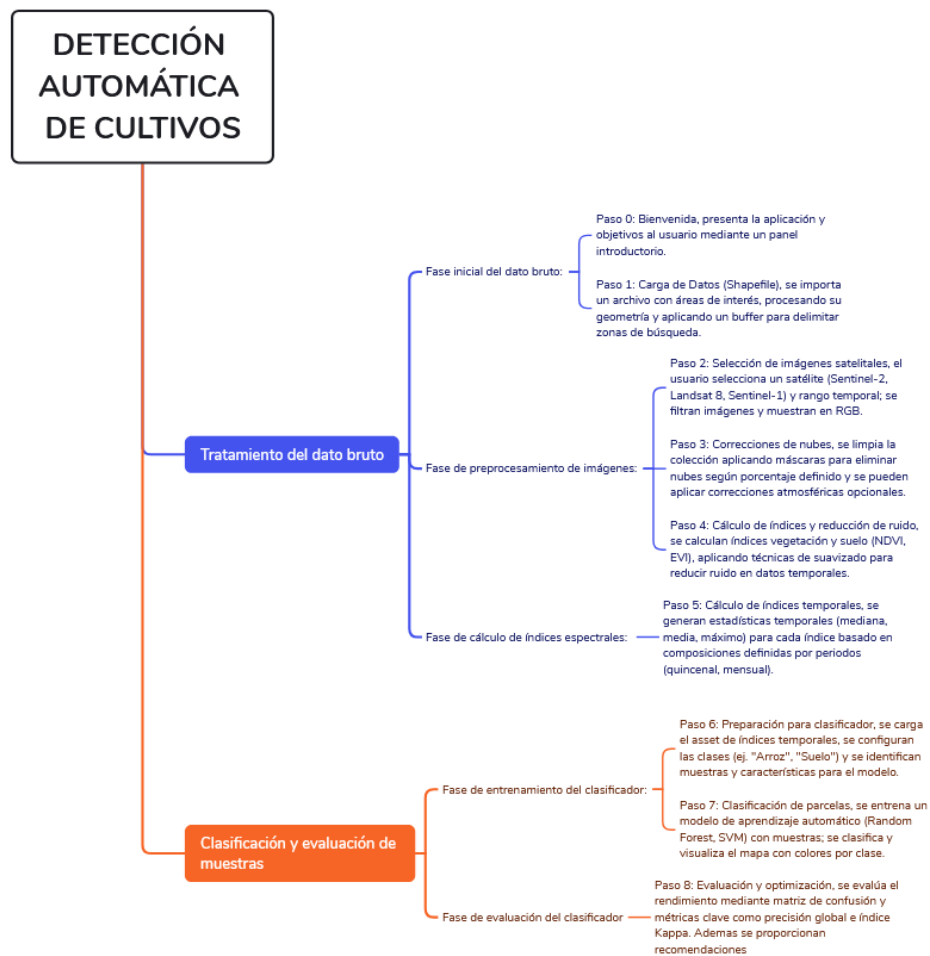
Flujo de trabajo

Para el flujo principal tenemos 5 apartados generales donde se engloban todos los pasos que vamos a ejecutar

- TRATAMIENTO DEL DATO BRUTO
 - FASE INICIAL DEL DATO BRUTO: PASO 0 Y 1
 - FASE DE PREPROCESAMIENTO DE IMÁGENES: PASO 2,3,4
 - FASE DE CALCULO DE INDICES ESPECTRALES PASO 5
- CLASIFICACION Y EVALUACIÓN DE MUESTRAS
 - FASE DE ENTRENAMIENTO DEL CLASIFICADOR PASO 6 Y 7
 - FASE DE EVALUACION DEL CLASIFICADOR PASO 8

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero



Esquema 1: Flujo general de trabajo de la aplicación (Fuente: Elaboración propia)

Relación entre pasos:

El primer apartado “Tratamiento del dato bruto” y el segundo “Clasificación y evaluación de muestras” son independientes entre sí, es decir los pasos que engloban, se pueden ejecutar de forma independiente. Los pasos dentro de cada uno de los apartados son dependientes entre sí.

Además de esto, tenemos una serie de dependencias obligatorias entre pasos que deben ejecutarse en orden, esto garantiza que la aplicación funcione correctamente siguiendo el flujo secuencial de los pasos, donde cada paso posterior depende de los datos generados en los pasos anteriores:

Paso 1 → Paso 2: `shapefileGeometria` para filtrar imágenes

Paso 2 → Paso 3: `coleccionImagenes` para aplicar correcciones

Paso 3 → Paso 4: `coleccionImagenesCorregidas` para calcular índices

Paso 4 → Paso 5: `coleccionImagenesCorregidas` para índices temporales

Paso 5 → Paso 6: Asset exportado para cargar estadísticas

Paso 6 → Paso 7: `muestrasEntrenamiento` y `listaCaracteristicas`

Paso 7 → Paso 8: `parcelasClasificadas` para evaluación

Si no se ejecuta o guardan estos valores, los siguientes pasos no se ejecutarán.

Diseño de la interfaz del paso

Al ejecutar la aplicación (clicar “Run”), se crea la interfaz y se prepara todo para que el usuario pueda trabajar paso a paso:

- Mapa:

Se crea automáticamente un mapa de GEE, se centra automáticamente en las coordenadas -3.7, 40.4 (España) y tiene un zoom inicial de nivel 6

- Interfaz entera:

Se limpia la interfaz de GEE y se añade el panel principal completo con todos los pasos

Además, se muestra automáticamente el panel de bienvenida y todos los demás paneles se ocultan inicialmente

También podremos ver en consola como se inicializan todos los componentes: Selectores de fecha y satélite, checkboxes de índices (NDVI, EVI, SAVI, etc.), los paneles de configuración para cada paso y los botones de navegación entre pasos

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

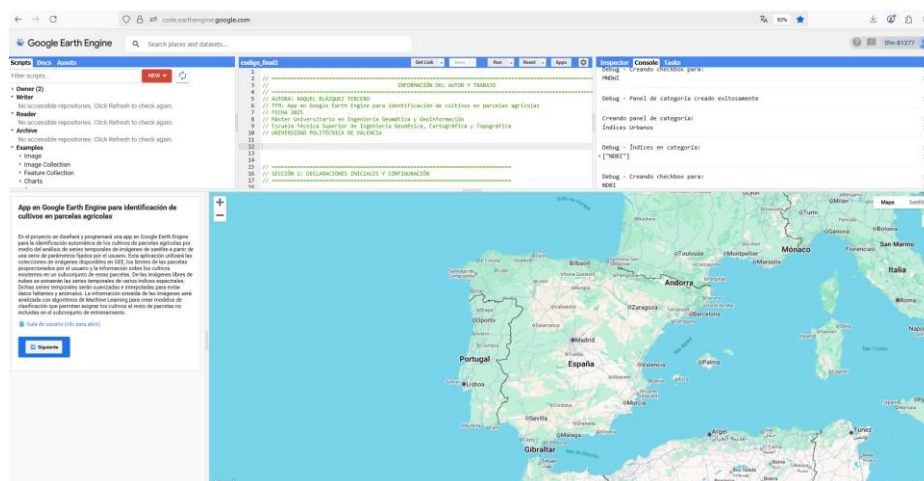


Figura 10: Muestra de interfaz de GEE con la aplicación (Fuente: Elaboración propia)

Explicación del funcionamiento interno del código

Para todos los pasos, tenemos una serie de funciones comunes para todos los pasos:

- Para la UI:

crearSeparador(), crearBotonesNavegacion(), crearPanelAyuda(),
crearTitulo(), mostrarMensaje(), mostrarCargando(), ocultarCargando()

Estas funciones se encargan de:

crearSeparador(): Crea una línea divisoria visual azul de 2px de grosor para separar diferentes secciones de la interfaz

crearBotonesNavegacion(): Crea un panel horizontal con botones de navegación para permitir al usuario moverse entre pasos de la aplicación, tenemos los botones anterior y siguiente.

crearPanelAyuda(): Crea un panel informativo con icono de ayuda, para dar mas información del paso al usuario, esto se mete dentro de un panel azul

crearTitulo(): Crea un título con separador integrado para añadir los encabezados de cada paso

mostrarMensaje(): Muestra mensajes de estado (éxito, error o advertencia) en el panel para ayudar al usuario a interpretar los resultados, también el mensaje sale coloreado según el tipo de estado (verde=éxito, rojo=error, naranja=advertencia)

mostrarCargando(): Muestra un indicador de carga con mensaje personalizado durante la carga que se esté realizando en el panel, para señalar al usuario que se está haciendo

ocultarCargando(panel): Oculta el indicador de carga del panel especificado, el mensaje de carga desaparece del panel

- Procesamiento de fechas:

`generarAños()`, `generarDias()`, `obtenerFechaFormateada()`, `validarFecha()`, `actualizarDiaInicio()`, `actualizarDiasFin()`

Estas funciones se encargan de:

`generarAños()`: Genera un array con años desde un año inicial hasta el año actual para crear opciones de años para los selectores de fecha

`generarDias()`: Genera un array con los días disponibles para un mes específico para tener días según el mes seleccionado

`obtenerFechaFormateada()` Convierte año, mes y día en formato de fecha estándar YYYY-MM-DD para formatear fechas para uso en Google Earth Engine

`validarFecha()`: Valida si una fecha tiene formato correcto y es válida devuelve true o false

`actualizarDiasInicio()`: Actualiza los días disponibles en el selector de fecha de inicio para sincronizar días disponibles cuando cambia el mes de inicio

`actualizarDiasFin()`: Actualiza los días disponibles en el selector de fecha de fin para sincronizar días disponibles cuando cambia el mes de fin.

- Validaciones:

`validarParametrosImagen()`, `validarTabla()`

Estas funciones se encargan de:

`validarParametrosImagen()`: Verifica configuración de imágenes, si es válido permite continuar con la carga de imágenes y sin no lo es muestra el error y bloquea el procesamiento.

`validarTabla()`: Verifica la estructura del shapefile, si no es correcto, muestra el error y bloquea el siguiente paso.

- Exportación:

`Export.table.toDrive()`, `Export.table.toAsset()`

Estas funciones se encargan de:

`Export.table.toDrive()`: Exporta una colección de datos a Google Drive del usuario, crea una tarea en la pestaña task para que el usuario la ejecute de forma manual.

`Export.table.toAsset()`: Exporta una colección de datos como un Asset en GEE, crea una tarea en la pestaña task para que el usuario la ejecute de forma manual.

- Visualización:

mantenerShapefileArriba(), visualizarResultados()

Estas funciones se encargan de:

mantenerShapefileArriba(): Asegura que la capa del shapefile siempre esté visible en la parte superior del mapa

visualizarResultados(): visualiza en el mapa una imagen de un índice específico con parámetros optimizados, además también centra el mapa en el área de estudio, restaura el shapefile y limpia las capas de resultados anteriores.

PASO 0: BIENVENIDA

Explicación general del paso

Es el panel introductorio que presenta la aplicación al usuario y el propósito, que es la identificación automática de cultivos en parcelas agrícolas mediante análisis de series temporales de imágenes satelitales y algoritmos de Machine Learning.

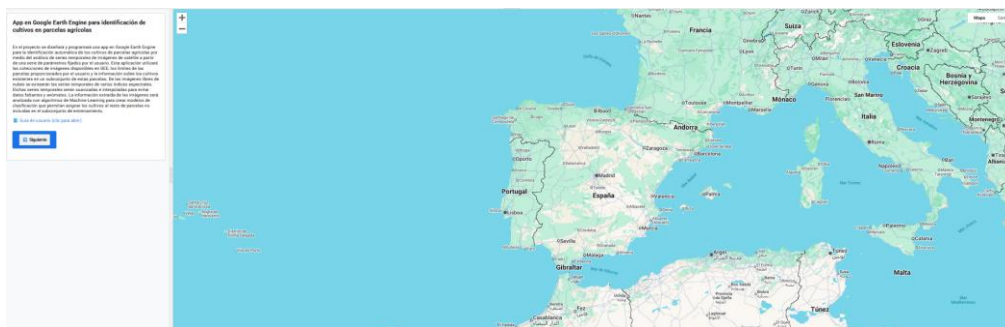



Figura 11: Muestra de interfaz de GEE con el paso 0 (Fuente: Elaboración propia)

Información que empleamos en este paso

Para este paso, necesitamos hacer una guía de usuario y subirla a Google Drive, además de un resumen del proyecto que estamos realizando.

Flujo de trabajo interno del paso



Esquema 2: Flujo de trabajo del paso 0 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entrada: Ninguna
- Salida: bienvenidaPanel configurado y visible al hacer “Run”

Diseño de la interfaz del paso

- bienvenidaPanel: Panel principal con título y descripción
- Título: "App en Google Earth Engine para identificación de cultivos en parcelas agrícolas"
- Descripción del proyecto
- Enlace a guía de usuario
- Botón "Siguiente"

Explicación del funcionamiento interno del código para el paso

Las funciones internas que realizamos son:

- bienvenidaPanel (creación del panel, no depende de otras funciones)
- Función onClick del botón "Siguiente"

PASO 1: CARGA DE DATOS (SHAPEFILE)

Explicación general del paso

Este paso permite cargar un shapefile con datos de entrenamiento que debe contener geometrías de parcelas y campos numéricos para entrenamiento, evaluación e identificación única.

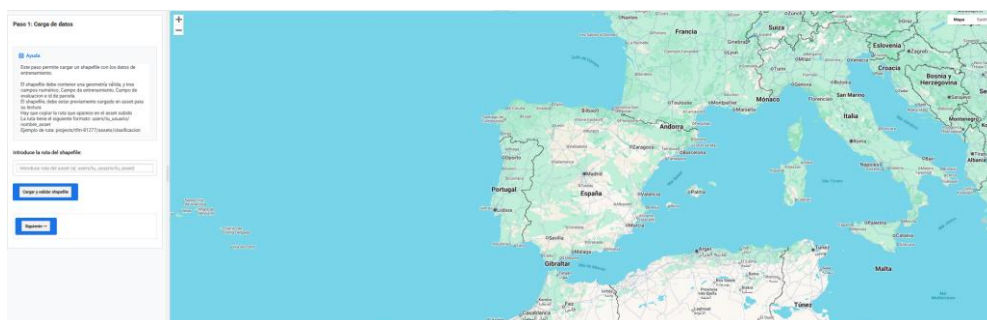


Figura 12: Muestra de interfaz de GEE con el paso 1 (Fuente: Elaboración propia)

Información que empleamos en este paso

Para este paso, necesitamos preparar bien el shapefile de entrada (tal cual se explica en el apartado Datos) al igual que saber añadir un asset al proyecto de GEE que estemos realizando (esta información aparece en la guía de usuario).

Flujo de trabajo interno del paso



Esquema 3: Flujo de trabajo del paso 1 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entrada:

assetInput.getValue() - Ruta del asset en GEE

Shapefile con 3 campos integer

- Salida:

shapefile - Referencia al shapefile cargado

shapefileGeometria - Geometría original

shapefileGeometriaBuffer - Geometría con buffer de 2km

shapefileLayer - Capa visual del shapefile

Diseño de la interfaz del paso

Los elementos de la interfaz son:

shapefilePanel: Panel principal del paso

assetInput: Campo de texto para ruta del asset

Botón "Cargar y validar shapefile"

crearPanelAyuda(): Panel de ayuda con instrucciones

crearBotonesNavegacion(): Botones Anterior/Siguiente

Explicación del funcionamiento interno del código para el paso

En este paso tenemos 2 funciones principales:

FUNCIÓN PRINCIPAL: `validarYCargarShapefile()`: Función principal que coordina la carga y validación del shapefile llama a `validarTabla()`

`validarTabla()`: valida la estructura del shapefile cargado, verificar que el shapefile tenga al menos 3 columnas con valores integer, genera el buffer de 2km para los siguientes pasos y carga el shapefile en el mapa

Generamos variables globales que tienen dependencias en los otros pasos: `shapefile`, `shapefileGeometria` y `shapefileGeometriaBuffer`

PASO 2: SELECCIÓN DE IMÁGENES SATELITALES

Explicación general del paso

El paso permite seleccionar el satélite, configurar el rango de fechas (según cada satélite, el rango de fechas cambia) y cargar imágenes satelitales en el mapa para el área de estudio definida en el paso anterior. También tenemos la información sobre los distintos satélites y sobre la colección cargada.

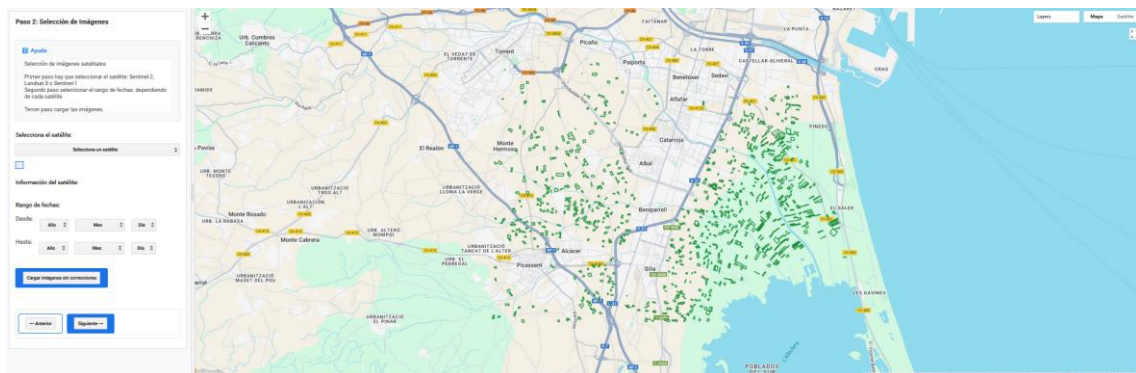
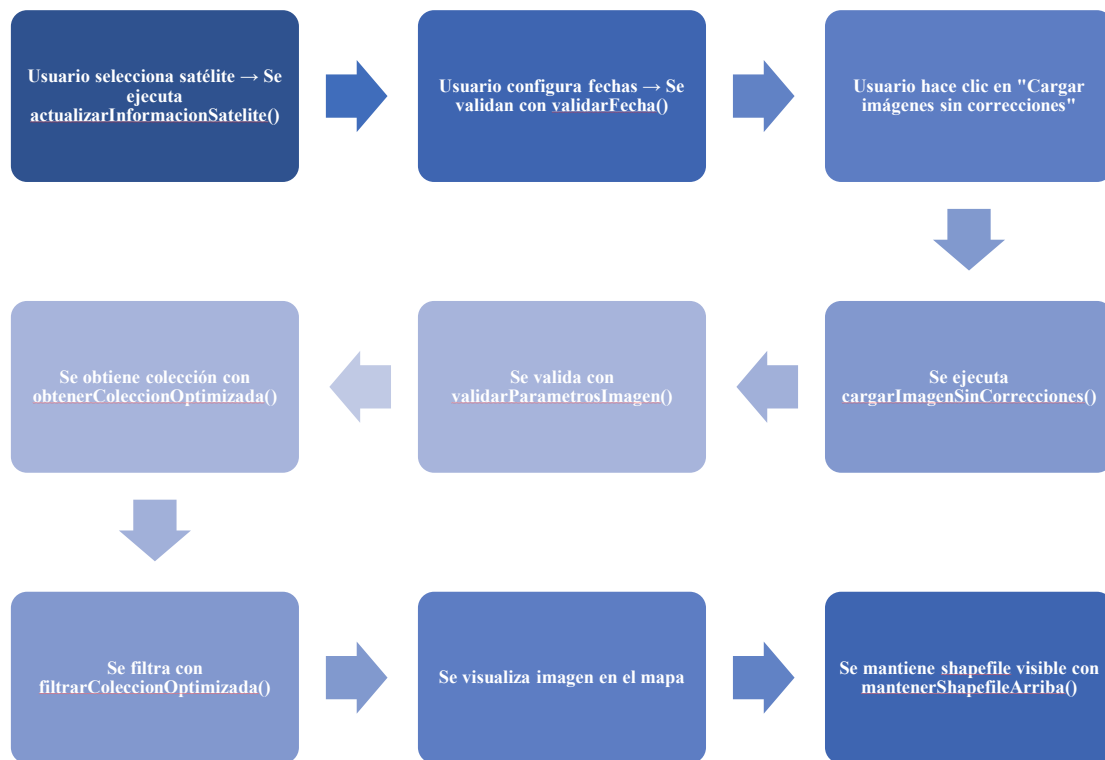


Figura 13: Muestra de interfaz de GEE con el paso 2 (Fuente: Elaboración propia)

Información que empleamos en este paso

Para este paso, hemos sacado la información de diferentes satélites al igual que su rango de fechas. Esta información se encuentra resumida en el apartado Datos de este mismo documento. Los datos de sentinel-1 no se procesan para cálculos, solo es para visualizar.

Flujo de trabajo interno del paso



Esquema 4: Flujo de trabajo del paso 2 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entrada:

selectorSatelite.getValue() - Satélite seleccionado

anioInicio.getValue(), mesInicio.getValue(), diaInicio.getValue() - Fecha inicio

anioFin.getValue(), mesFin.getValue(), diaFin.getValue() - Fecha fin

shapefileGeometria – calculada en el paso anterior

- Salida:

coleccionImágenes - Colección de imágenes filtrada

Imagen visualizada en el mapa y la información del satélite seleccionado.

Diseño de la interfaz del paso

Para este paso, se han configurado los siguientes elementos en la interfaz:

satelitePanel: Panel principal del paso

selectorSatelite: Selector de satélite

sateliteSeleccionadoLabel: Etiqueta del satélite seleccionado

infoLabelSatelite: Información del satélite

panelFechas: Panel con selectores de fecha

loadImageButton: Botón para cargar imágenes

numImagenesLabelSatelite: Etiqueta con número de imágenes cargadas

Explicación del funcionamiento interno del código para el paso

FUNCIÓN PRINCIPAL: cargarImagenSinCorrecciones(): Carga y visualiza imágenes satelitales sin aplicar correcciones. Internamente, visualiza la imagen más reciente en el mapa, ejecuta validar parámetros y filtra las imágenes

FUNCIÓN DE CONFIGURACIÓN: actualizarInformacionSatelite(): Actualiza la información mostrada del satélite seleccionado (también cambia el rango de los paneles ajustables de fecha)

FUNCIÓN VALIDADORA: validarParametrosImagen(): Valida todos los parámetros necesarios para cargar imágenes satelitales (como los rangos de fechas, y el formato)

obtenerFechaFormateada(): Convierte año, mes y día en formato de fecha estándar YYYY-MM-DD

validarFecha(): Valida si una fecha tiene formato correcto y es válida

obtenerColeccionOptimizada(): Obtiene una colección de imágenes optimizada para el satélite seleccionado (crea la colección base para procesar después)

filtrarColeccionOptimizada(): Filtra una colección de imágenes usando el área optimizada del shapefile

FUNCIONES DE GEE:

En este apartado utilizamos algunas funciones propias de GEE importantes como: e.ImageCollection(configSatelite.coleccion) que crea colección de imágenes del satélite seleccionado o imagen.bandNames() que recoge el nombre de las bandas.

PASO 3: CORRECCIONES DE NUBES

Explicación general del paso

En este paso, se aplican correcciones atmosféricas y de nubes a las imágenes cargadas, permitiendo filtrar por porcentaje de nubes y aplicar máscaras para eliminar píxeles nublados.



Figura 14: Muestra de interfaz de GEE con el paso 3 (Fuente: Elaboración propia)

Información que empleamos en este paso

- Sentinel-2: las nubes se identifican desde el conjunto de datos de probabilidad de nube S2 (s2cloudless) y las sombras se definen por intersección de proyección de nubes con píxeles de infrarrojo cercano a la falta de baja importancia (NIR)

Utiliza la banda QA60 para detección de nubes

Bit 10: Nubes

Bit 11: Cirros

Filtro usado: CLOUDY_PÍXEL_PERCENTAGE < umbral

- Landsat 8: as nubes y sombras se identifican desde la banda de control de calidad QA_PÍXEL que contiene información de la calidad de cada píxel, incluyendo la presencia de nubes, sombras de nubes, nieve o agua.

Bit 3: Nubes

Bit 4: Sombras de nubes

Filtro usado: CLOUD_COVER < umbral

Flujo de trabajo interno del paso



Esquema 5: Flujo de trabajo del paso 3 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entrada:

selectorNubes.getValue() - Porcentaje máximo de nubes

checkboxCorrecciones.getValue() - Aplicar correcciones

coleccionImágenes - Del paso anterior

sateliteSeleccionado - Del paso anterior

shapefileGeometria ← Para filtrado espacial

- Salida:

coleccionImágenesCorregidas - Colección procesada

coleccionOriginal - Colección original guardada

Imagen visualizada con correcciones aplicadas

Diseño de la interfaz del paso

Tenemos los siguientes elementos en la UI del paso:

correccionesPanel: Panel principal del paso

selectorNubes: Slider para porcentaje de nubes

nubesSeleccionadasLabel: Etiqueta del porcentaje seleccionado

checkboxCorrecciones: Checkbox para aplicar correcciones

panelExplicacionCorrecciones: Panel explicativo

infoLabelCorrecciones: Información del procesamiento

numImágenesLabelCorrecciones: Estadísticas de filtrado

Explicación del funcionamiento interno del código para el paso

FUNCION PRINCIPAL: `cargarImagenConCorrecciones()` – Aplica todo el proceso de filtrado de nubes, para ello: valida parámetros del Paso 2, filtra imágenes por porcentaje de nubes, aplica máscaras de nubes específicas por satélite y almacena la colección para el siguiente paso

FUNCIONES DEPENDIENDO DEL SATÉLITE:

`maskS2clouds(image)` - Máscara para Sentinel-2, utiliza `ee.Filter.lt('CLOUDY_PIXEL_PERCENTAGE', porcentajeNubes)`

Usa la banda QA60 (Quality Assurance) Y Detecta nubes y cirros usando bits 10 y 11.

Aplica una máscara para ocultar píxeles nublados

Escala valores dividiendo por 10,000

Selecciona solo bandas espectrales con B.

Mantiene propiedades de tiempo

`maskL8clouds(image)` - Máscara para Landsat 8, utiliza `ee.Filter.lt('CLOUD_COVER', porcentajeNubes)`

Usa la banda QA_PIXEL (Quality Assurance) y detecta nubes usando bit 3

Aplica una máscara más conservadora

Escala valores usando factor 0.0000275 y offset -0.2

Mantiene propiedades de tiempo y cobertura de nubes

`filtrarColeccionOptimizada()` - Filtra por nubes y área

PASO 4: CÁLCULO DE ÍNDICES Y REDUCCIÓN DE RUIDO

Explicación general del paso

Calcula múltiples índices espectrales (NDVI, EVI, SAVI, etc.) seleccionables por el usuario y aplica técnicas de para reducir ruido en las series temporales.

Primeramente, aparecerán unos checkboxes para el cálculo de bandas y damos a calcular, por cada banda se mostrará una imagen en el mapa, seguidamente se habilitará un checkbox con slider para aplicar las técnicas de reducción de ruido.



Figura 15: Muestra de interfaz de GEE con el paso 4 (Fuente: Elaboración propia)

Tras esta selección de reducción se puede elegir la opción de visualizar y de exportar resultados.




Figura 16: Muestra de visualización tras el cálculo de una banda (Fuente: Elaboración propia)

Información que empleamos en este paso

La teoría en la que se basa esta aplicación es en entrenar un modelo en base a la reflectancia o absorción de energía de múltiples superficies, cada superficie deja una firma espectral única de cómo se comporta.




Figura 17: Comportamiento de la reflectancia sobre diferentes superficies (Fuente: Presentación de Amber McCullum (BAERI), Britnay Beaudry (BAERI), Juan Torres-Pérez (NASA ARC), Sativa Cruz (BAERI), Índices Espectrales para Aplicaciones Terrestres y Acuáticas, Sesión 1: Resumen General de los Índices Espectrales)

Una vez que sabemos el comportamiento de estas superficies, podemos encontrar similitudes, enseñar a nuestro modelo a identificarlas y que así nos dé un modelo automático.

Para esta aplicación, se han seleccionado un total de 10 índices por su importancia a la hora de identificar cultivos y para tener un abanico de elección más grande para el usuario.

Las fórmulas de estos índices se han obtenido de diferentes fuentes, como algunos índices tienen diferentes formas de cálculo, se ha optado por elegir la fórmula que más se usa, los índices mencionados son:

- NDVI: relaciona las longitudes de onda del rojo y el infrarrojo cercano, ya que la clorofila absorbe el rojo y la estructura de la planta refleja el infrarrojo. Se ha utilizado la fórmula más utilizada.

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (1)$$

- NDWI: tiene dos versiones principales. La primera, desarrollada por McFeeters, usa la banda verde. La segunda, por Gao, usa el infrarrojo de onda corta (SWIR). La fórmula que vamos a usar es la de Gao, que es la más común para detectar la humedad del agua en la vegetación.

$$NDWI = \frac{(NIR-SWIR)}{(NIR+SWIR)} \quad (2)$$

- SI: Se ha cogido una formula basada en múltiples estudios, se basa en la reflectancia del suelo

$$SI = \frac{(SWIR1-RED)}{(SWIR1+RED)} \quad (3)$$

- EVI: para áreas de alta biomasa y para reducir los efectos atmosféricos y del fondo del suelo.

$$EVI = 2.5 \cdot \frac{(NIR-RED)}{(NIR+6 \cdot RED-7.5 \cdot BLUE+1)} \quad (4)$$

- SAVI: para reducir el impacto del brillo en el suelo, donde L es el factor de ajuste en nuestro caso 0.5

$$SAVI = \frac{(NIR-RED)}{(NIR+RED+L)} \cdot (1 + L) \quad (5)$$

- GNDVI: Es parecido al NDVI, pero usa la banda Verde en lugar de la Roja

$$GNDVI = \frac{(NIR-GREEN)}{(NIR+GREEN)} \quad (6)$$

- NDBI: para resaltar las áreas urbanas y construidas. Aprovecha la alta reflectancia de los materiales de construcción en el infrarrojo de onda corta.

$$NDBI = \frac{(SWIR1-NIR)}{(SWIR1+NIR)} \quad (7)$$

- MNDWI: para detectar cuerpos de agua y reducir el ruido de las zonas urbanas y la vegetación

$$MNDWI = \frac{(GREEN-SWIR1)}{(GREEN+SWIR1)} \quad (8)$$

- NBI: Compara las bandas del Infrarrojo de Onda Corta. La banda SWIR2 es la que denominamos MIR en el código

$$NBI = \frac{(SWIR2-SWIR1)}{(SWIR2+SWIR1)} \quad (9)$$

- BSI: para resaltar el brillo inherente al suelo y diferenciarlo de la vegetación.

$$BSI = \frac{((SWIR1+RED)-(NIR+BLUE))}{((SWIR1+RED)+(NIR+BLUE))} \quad (10)$$

REDUCCIÓN DE RUIDO:

Partimos de tener una serie temporal corregida, con la banda de índice calculada, tenemos 4 técnicas dependientes entre sí:

- Suavizado de la ventana móvil: Calcula el promedio móvil para eliminar valores atípicos.
Para corregir estos datos, se elige cuantas imágenes utilizar tanto antes como después para aplicar el suavizado, pero si la serie temporal tiene muchos huecos, no funciona.
Para calcularlo, se pueden hacer varios cálculos, pero se ha optado por el promedio móvil hacia delante y hacia atrás.



Figura 18: Suavizado de una serie temporal (Fuente: documentación de ArcGIS Pro-3.4)

El resultado sería:




Figura 19: Gráfica de suavizado (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/29938f5fcf023a281d71f98323cb0281>)

- Relleno de huecos en series temporales: Rellena píxeles faltantes de la serie temporal. Para ello, busca vecinos temporales, es decir, píxeles que estén cerca de la fecha (aquí se selecciona el periodo de búsqueda antes y después), tras esto se calcula el valor del relleno mediante la media y se sustituye el píxel enmascarado por este valor.




Figura 20: Grafica de relleno de huecos temporales (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/9477d1c8738d9a879e9f0d86c5e11cb0>)

- Interpolación de series temporales: Crea una serie temporal con intervalos regulares.

Para este paso, primero generamos una colección vacía que van a ser los marcadores de posición para cada punto de la serie temporal, aquí añadimos el tiempo que tenemos seleccionable y se genera una imagen para cada fecha.

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

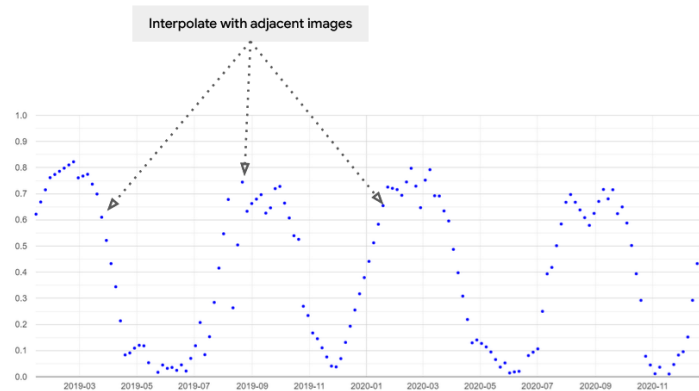


Figura 21: Gráfica del proceso de interpolación (Fuente: Presentación de Time-Series Processing using Google Earth Engine Ujaval Gandhi Spatial Thoughts October 2022)

Tras esto, juntamos la colección que tenemos corregida, se une a la colección vacía, teniendo una imagen corregida con el marcador de posición.

Por último, para cada imagen vacía, se busca la imagen real más cercana dentro de un intervalo y cuando se encuentren las dos imágenes se hace una interpolación lineal.

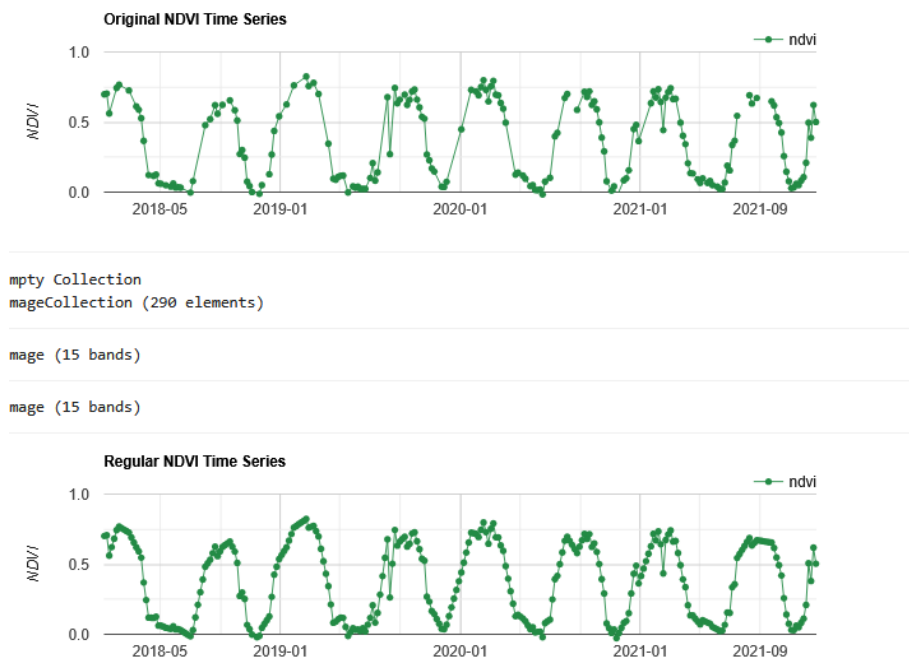


Figura 22: Gráfica de interpolación (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/fe4e9c27f262efc5bdbc7610fa03b146>)

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

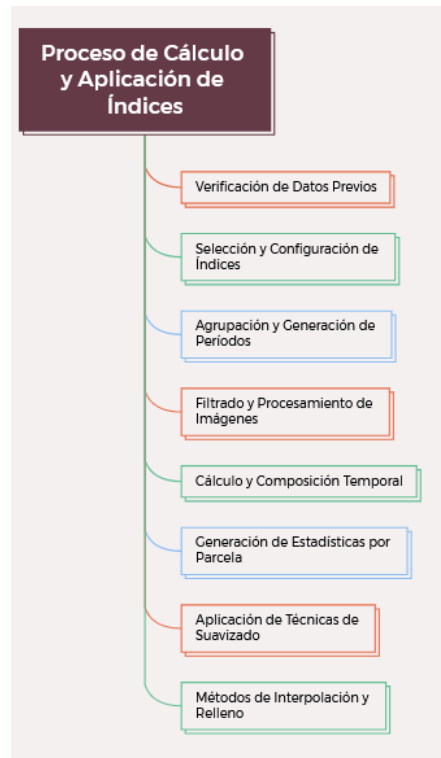
- Filtrado avanzado de series temporales: Aplica el filtro Savitzky–Golay para suavizar series temporales. Necesitamos tener implementada la librería Open Earth Engine Library (OEEL)

Para ello, reduce el filtro a un determinado periodo más pequeño, para este periodo, ajusta un polinomio a los puntos para crear una curva polinomial minimizando el error cuadrático. Por último, recalcula el valor del punto central del periodo seleccionado



Figura 23: Grafica del filtro Savitzky-Golay (Fuente: Generada por código abierto de GEE <https://code.earthengine.google.com/ffd0b9b3c372d5e21181a6144acb0ae3>)

Flujo de trabajo interno del paso



Esquema 6: Flujo de trabajo del paso 4 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entrada

shapefile -FeatureCollection con parcelas agrícolas

shapefileGeometria - Geometría para filtrado espacial

selectorSatelite.getValue() ← Satélite seleccionado

anioInicio.getValue() ← Año de inicio

mesInicio.getValue() ← Mes de inicio

diaInicio.getValue() ← Día de inicio

anioFin.getValue() ← Año de fin

mesFin.getValue() ← Mes de fin

diaFin.getValue() ← Día de fin

coleccionImágenesCorregidas ← Colección de imágenes sin nubes

Para el apartado de reducción de ruido ya aplica:

checkboxesIndices ← Checkboxes de índices seleccionados

configuracionIndices ← Configuración de período y composición por índice

- Salida

imagenIndicesCompleta ← Imagen con todos los índices calculados

parcelasConEstadisticas ← FeatureCollection con estadísticas por parcela

listaCaracteristicas ← Lista de características para clasificación

historialColecciones ← Registro de colecciones procesadas

Shapefile combinado con estadísticas de todos los índices

Asset de GEE para uso en pasos posteriores

Series temporales de cada índice por parcela

Diseño de la interfaz del paso

indice31Panel: Panel principal del paso

panelCheckboxesIndices: Panel con checkboxes de índices

panelContenedorSuavizado: Panel para técnicas de suavizado. Incluye:

-Suavizado con ventana móvil (5-60 días configurables)

-Relleno de vacíos temporales (15-90 días configurables)

-Interpolación regular (3-30 días configurables)

-Filtro Savitzky-Golay (orden polinomio 2-5)

botonCalcularIndices: Botón para calcular índices

botonAplicarSuavizado: Botón para aplicar técnicas

selectIndiceGrafico: Selector de índice para gráficos

botonGenerarGrafico: Botón para generar gráficos

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

The screenshot shows a web interface for selecting indices and noise correction techniques. It is divided into several sections:

- Índices Urbanos:** A checkbox for 'NDBI ((SWIR - NIR) / (SWIR + NIR))' is checked.
- Índices de Suelo:** Three checkboxes are checked: 'NBI ((SWIR + RED - NIR - BLUE) / (SWIR + RED + NIR + BLUE))', 'BSI ((SWIR + RED - NIR - BLUE) / (SWIR + RED + NIR + BLUE))', and 'SI (RED / NIR)'.
- Calcular bandas para índices seleccionados:** A blue button.
- Opciones de suavizado para: NDVI:** Four checkboxes are present: 'Suavizado con ventana móvil (Moving-Window Smoothing)', 'Relleno de vacíos temporales (Gap-Filling)', 'Interpolación a intervalos regulares', and 'Filtro Savitzky-Golay (requiere OEEL)'. None are checked.
- Aplicar técnicas:** A button with a star icon.
- Exportar series temporales (índices seleccionados):** A blue button.
- Gráficos por punto (selecciona índice):** A dropdown menu showing 'Las bandas seleccionadas aún no están disponibles'.
- Generar gráfica (consola):** A blue button.

Figura 24: Muestra de interfaz para seleccionar índices y técnicas de corrección de ruido de GEE en el paso 4 (Fuente: Elaboración propia)

Explicación del funcionamiento interno del código para el paso

FUNCION PRINCIPAL: `calcularIndicesSeleccionados()`, es la función que ejecuta todo el paso 4. esta función, llama a:

a) `calcularTodosLosIndicesJuntos`: Procesa todos los índices seleccionados, esta función a su vez llama a:

`calcularIndiceEspecifico()`: Calcula un índice específico usando fórmulas matemáticas. Es necesario que haya un mapeo de bandas para su ejecución, que procede de las imágenes de los pasos anteriores. Este mapeo se hace para caracterizar las bandas equivalentes de un satélite u otro.

```
var mapaBandas = {
  'Sentinel-2': {
    'NIR': 'B8',
    'RED': 'B4',
    'GREEN': 'B3',
    'BLUE': 'B2',
    'SWIR': 'B11',
    'MIR': 'B12'
  },
  'Landsat 8': {
    'NIR': 'SR_B5',
    'RED': 'SR_B4',
    'GREEN': 'SR_B3',
    'BLUE': 'SR_B2',
    'SWIR': 'SR_B6',
    'MIR': 'SR_B7'
  }
}
```

Figura 25: Muestra de mapeo de bandas en el código de GEE en el paso 4 (Fuente: Elaboración propia)

`function generarPeriodos()`: Genera períodos temporales automáticamente

b) `aplicarTecnicasSeleccionadas()`: Aplica técnicas avanzadas de procesamiento temporal, para realizarlo necesitamos tener la función a calculada, esta a su vez llama a las funciones de reducción de ruido:

`aplicarSuavizadoVentanaMovil()` ← Suavizado temporal

`aplicarRellenoVacios()` ← Relleno de vacíos

`aplicarInterpolacionRegular()` ← Interpolación

`aplicarFiltroSavitzkyGolay()` ← Filtro avanzado, necesitamos tener instalada la librería externa OEEL (Open Earth Engine Library)

Para aplicar estas técnicas, necesitamos tener seleccionados los checkboxes

FUNCIONES PARA INDICES:

Para el cálculo de las bandas, se emplean ciertas tecnicas de GEE:

- `normalizedDifference()` (Google Earth Engine): para hacer la diferencia normalizada

Usado para: NDVI, GNDVI, NDWI, MNDWI, NDBI

- `expression()` (Google Earth Engine) para añadir la formula matemática

Usado para: EVI, SAVI, NBI, BSI, SI

FUNCIONES PARA REDUCCION DE RUIDO:

Para este paso partimos de que tenemos una banda o varias calculadas a las cuales hay que aplicar diferentes tecnicas, estas tecnicas se aplicaran desarrollando el proceso explicado anteriormente:

- Suavizado con ventana móvil: `aplicarSuavizadoVentanaMovil()`
- Relleno de vacíos: `aplicarRellenoVacios()`
- Interpolación regular: `aplicarInterpolacionRegular()`
- Filtro Savitzky-Golay: `aplicarFiltroSavitzkyGolay()`

PASO 5: CÁLCULO DE ÍNDICES TEMPORALES

Explicación general del paso

Este paso genera series temporales de índices espectrales dividiendo el período en intervalos (quincenal, mensual, etc.) y aplicando composiciones temporales (mediana, media, etc.). Esto se aplica para toda la colección de imágenes que tenemos.

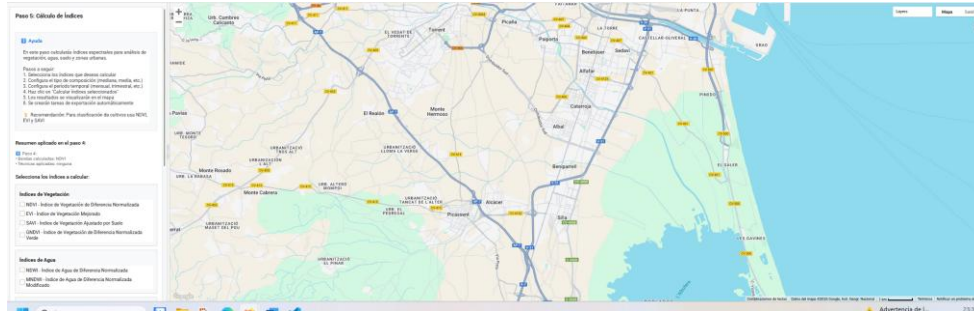


Figura 26: Muestra de interfaz de GEE con el paso 5 (Fuente: Elaboración propia)

Información que empleamos en este paso

Para este paso, hemos añadido los índices del paso anterior, si un índice no viene calculado en el paso 4, se tiene que calcular de la misma forma que calculábamos las bandas en el paso 4.

Para los periodos, tenemos:

Quincenal: 15 días

Mensual: 30 días

Trimestral: 90 días

Semestral: 180 días

Para las composiciones, tenemos:

mediana: Para obtener el valor central del período

media: Para obtener el valor promedio del período


percentil_25: Para obtener el valor del 25% más bajo

percentil_75: Para obtener el valor del 75% más alto

mínimo: Para obtener el valor más bajo del período

máximo: Para obtener el valor más alto del período

Flujo de trabajo interno del paso



Esquema 7: Flujo de trabajo del paso 5 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entrada

coleccionImágenesCorregidas: Colección de imágenes del Paso 3 con correcciones aplicadas

coleccionDespuesTecnicas: Colección del Paso 4 con técnicas de reducción de ruido aplicadas

shapefileGeometria: Geometría del área de estudio cargada en el Paso 1

selectorSatelite: Satélite seleccionado por el usuario

fechaInicio: Fecha de inicio del período de análisis

fechaFin: Fecha de fin del período de análisis

indicesSeleccionados - Índices a procesar

tipoComposicion - Tipo de composición

periodoTemporal - Período temporal

- Salida

coleccionIndicesBase: Snapshot de la colección base para hacer comparativas entre etapas

coleccionIndicesMensuales: Colección final con índices calculados para cada período temporal

coleccionTemporal: Colección temporal que se va procesando durante el cálculo

imagenResultado: Imagen final resultante de cada período con índices calculados

resultado: Resultado intermedio de la composición temporal antes de calcular índices

Archivos exportados (CSV, Asset)

Diseño de la interfaz del paso

Cada vez que seleccionemos un índice, se abrirá su panel correspondiente para añadir el tipo de composición y el periodo temporal. Tenemos muchos elementos para mostrar en este apartado.



Figura 27: Muestra de interfaz para seleccionar índices, composición y periodo temporal de GEE en el paso 4 (Fuente: Elaboración propia)

Los elementos de la interfaz se organizan en paneles principales (indicesPanel, indicesSeleccionadosPanel), controles de configuración (selectorComposicion, selectorPeriodo), botones de acción (botonCalcularIndices2, botonExportarSeries), selectores y menús (selectIndiceGrafico, checkboxesIndices), labels informativos (resumenPaso4Label, mensajeCorrecciones), paneles de configuración (panelContenedorSuavizado, panelExplicacionCorrecciones), selectores de fecha (anioInicio, mesInicio, diaInicio), selectores de satélite (selectorSatelite, selectorNubes), checkboxes de técnicas (checkboxSuavizado, checkboxRelleno), sliders de parámetros (sliderDiasSuavizado, sliderDiasRelleno), labels de valores (nubesSeleccionadasLabel, lbDiasSuav), paneles de navegación (botonesIndices, botonesindice31Panel), paneles de gráficos (panelGraficos, panelEstadisticas), variables auxiliares (opcionesSelectGrafico, indiceSeleccionadoGrafico), paneles de ayuda (ayudaPasos.paso1, ayudaPasos.paso2, ayudaPasos.paso3) y estilos (estilosPaneles.titulo, estilosPaneles.subtitulo, estilosPaneles.boton, estilosPaneles.panel).

Explicación del funcionamiento interno del código para el paso

FUNCIÓN PRINCIPAL: procesarIndicesYReduccion(): Es la función que llama a todas las demás, reutiliza índices ya calculados del anterior paso y verifica que colección escoger para el cálculo (entre los datos calculado en el anterior paso o calcular datos nuevos). Esta función llama a:

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

`calcularMultiplesIndices()`: esta función calcula múltiples índices espectrales para una colección de imágenes, aplica fórmulas matemáticas específicas por satélite y añade bandas de índices a cada imagen de la colección

`actualizarResumenPaso5()`: actualiza la información mostrada al usuario sobre el estado del Paso 4, depende del paso 4.

`refreshOpcionesIndiceGrafico()`: Actualiza el selector de índices para gráficos basándose en las bandas disponibles, sincroniza opciones con índices realmente disponibles y habilita/deshabilita selector según disponibilidad

PASO 6: PREPARACIÓN PARA CLASIFICADOR

Explicación general del paso

En este apartado, se carga el shapefile con estadísticas generado en el paso anterior y configura los códigos de clase y nombres de campos para preparar la clasificación.

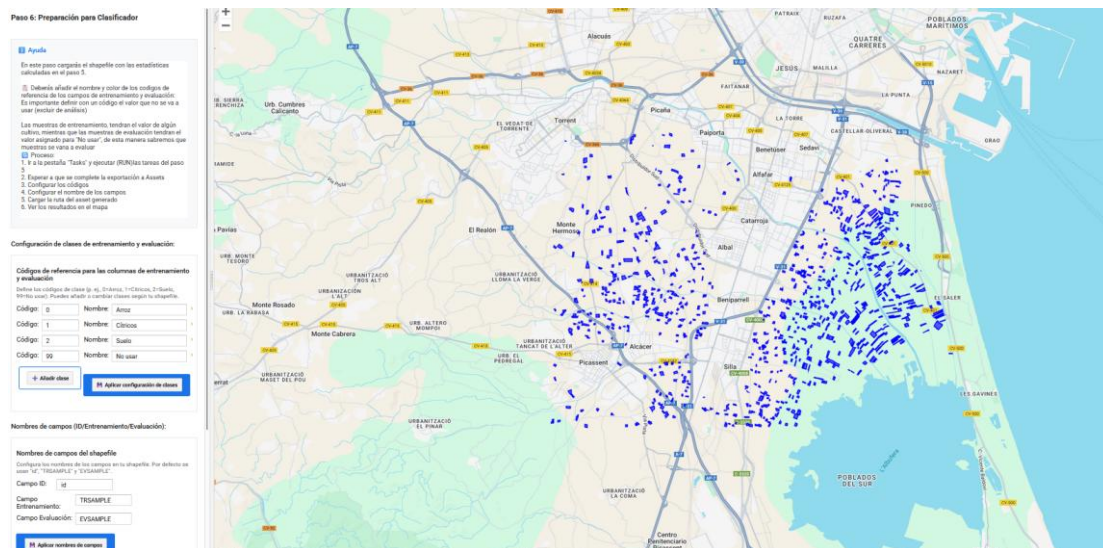


Figura 28: Muestra de interfaz de GEE con el paso 6 (Fuente: Elaboración propia)

Para este paso, necesitamos tener subido un shapefile con el cálculo de los índices del paso anterior, aquí podemos elegir cuál de las exportaciones del paso anterior clasificar.

Información que empleamos en este paso

Para este paso, necesitamos la información procedente del shapefile de origen, aquí añadiremos el nombre de los campos a evaluar y clasificar. Además, también añadiremos las clases en las que hemos dividido los cultivos con su nombre para poderlos mencionar en futuros pasos.

Flujo de trabajo interno del paso



Esquema 8: Flujo de trabajo del paso 6 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entrada:

inputShapefileEstadisticas.getValue() - Ruta del asset

configClases - Configuración de las clases

nombresCampos - Nombres de los campos

- Salida:

muestrasEntrenamiento - Muestras para entrenamiento

parcelasConEstadisticas - Parcelas con estadísticas

listaCaracteristicas - Características disponibles

Shapefile visualizado en el mapa

Diseño de la interfaz del paso

Los elementos que contiene la interfaz de este paso son los siguientes:

preparacionPanel: Panel principal del paso

panelConfigClases: Configuración de clases

panelCamposShapefile: Nombres de campos

inputShapefileEstadisticas: Campo para ruta del asset

botonCargarShapefile: Botón para cargar shapefile

Explicación del funcionamiento interno del código para el paso

FUNCIÓN PRINCIPAL: cargarShapefileEstadisticas()

Esta es la función central del Paso 6 que prepara los datos para la clasificación.

Esta función, carga el shapefile con estadísticas calculadas en el Paso 5 (el que elijamos, no almacena los datos del paso anterior), filtra muestras de entrenamiento (TRSAMPLE < 99), extrae características disponibles de los índices espectrales que hemos calculado, prepara los datos para la clasificación y visualiza las parcelas en el mapa

PASO 7: CLASIFICACIÓN DE PARCELAS

Explicación general del paso

es el módulo central de clasificación supervisada de parcelas agrícolas que implementa un sistema completo de machine learning para categorizar cultivos basándose en índices espectrales calculados en pasos anteriores.

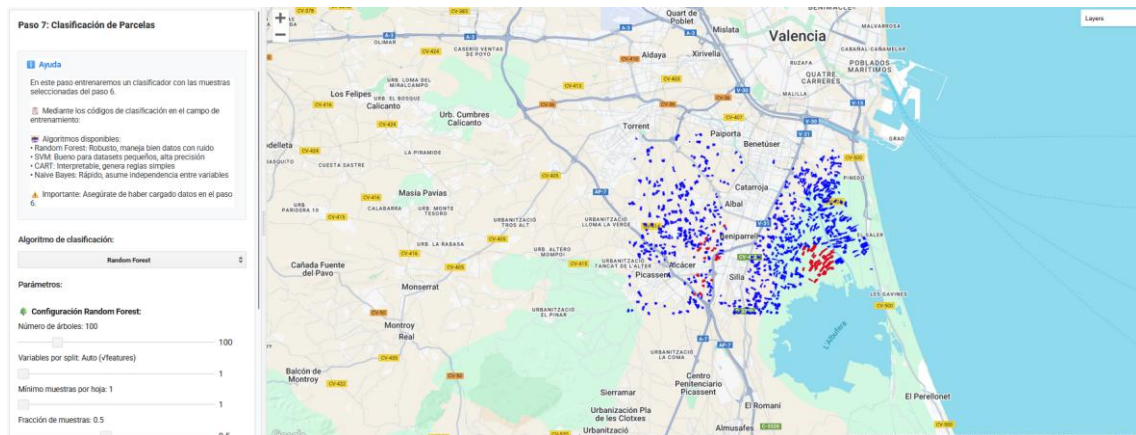


Figura 29: Muestra de interfaz de GEE con el paso 7 (Fuente: Elaboración propia)

El objetivo principal, es entrenar un clasificador supervisado con muestras de entrenamiento y aplicar la clasificación a todas las parcelas para identificar tipos de cultivos (arroz, cítricos, suelo, etc.).

Información que empleamos en este paso

Vamos a emplear una clasificación supervisada mediante el selector de 4 algoritmos de clasificación, para ellos vamos a explicar cómo funcionan dichos algoritmos, en nuestro código, desarrollaremos estos algoritmos con la librería interna Classifier de GEE. El procedimiento general del clasificador, es a partir de una colección de imágenes entrenadas, definir las clases finales.

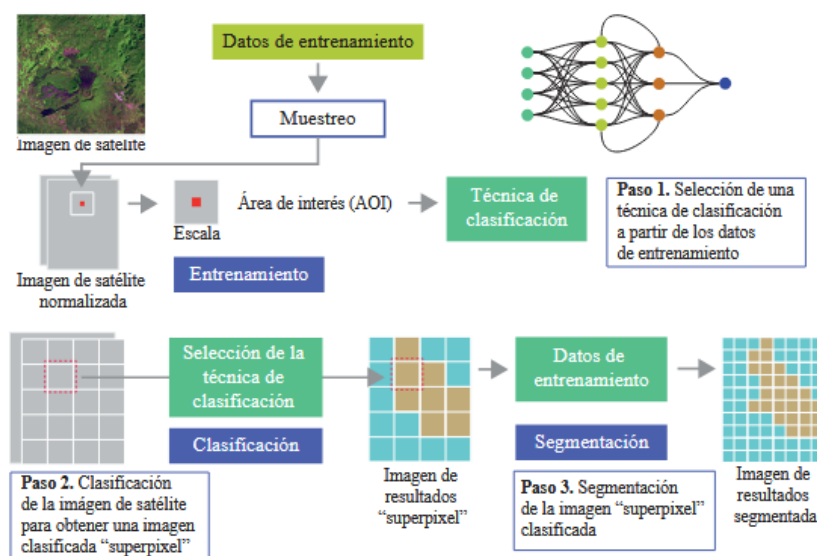


Figura 6.5. Flujo de trabajo de una clasificación supervisada.

Figura 30: Flujo de trabajo de una clasificación supervisada para el paso 7 (Fuente: Técnicas de clasificación de imágenes de satélite en ciencias forestales, Rafael M^a NAVARRO CERRILLO, M^a Ángeles VARO MARTÍNEZ, Antonio J. ARIZA SALAMANCA. Víctor RODRÍGUEZ GALIANO)

Para este proceso se utilizan diferentes clasificadores:

- **Random forest:**

Es un algoritmo que se basa en árboles de decisión, cada uno de los árboles generados, se entrenan de forma independiente con una variable aleatoria del entrenamiento. Para predecir una clase, cada árbol vota por un tipo y el que recibe más votos, es la clase asignada.

Tenemos 4 variables que en nuestra aplicación son seleccionables:

Numero de árboles de decisión que se quieren hacer

Split: En cada nodo de un árbol, el algoritmo no considera todas las variables, sino solo un subconjunto aleatorio. Esto es lo que lo hace "aleatorio" y ayuda a que los árboles sean diversos.

Muestras por hoja: Controla el número mínimo de muestras que deben estar en un nodo para que se pueda dividir. Un valor alto previene que el árbol se vuelva demasiado específico y se sobreajuste.

Bagging: Es la proporción de los datos de entrenamiento que se usan para construir cada árbol.

- **SVM (Máquinas de Vectores de Soporte):**

Este algoritmo busca separar las clases en un plano, en un espacio multidimensional. El plano es una línea (en 2D) o un plano (en 3D) que divide los datos. El objetivo de SVM es encontrar el hiperplano que maximice el margen, es decir, la distancia a las muestras más cercanas de cada clase.

Tenemos 3 parámetros seleccionables:

Parámetro C: Es un término de penalización que controla el "costo" de una clasificación errónea

Gamma: Define la influencia que tiene una sola muestra de entrenamiento.

Grado: Es el exponente del polinomio en el kernel polinomial

Tipo de kernel: transforma los datos para que las clases sean separables en una dimensión superior.

Usar shrinking heuristics: Es una optimización interna que puede acelerar el entrenamiento del algoritmo en conjuntos de datos grandes

Procedimiento de decisión: Es la forma en que el algoritmo maneja los problemas de clasificación multiclase.

- **CART (Árboles de Clasificación y Regresión):**

Es un algoritmo fundamental que construye un único árbol de decisión binario. El proceso es recursivo: en cada paso, divide el conjunto de datos en dos subconjuntos basados en una pregunta sobre una característica

Máximo de nodos: Limita la profundidad y el tamaño del árbol. Limitarlo ayuda a evitar que el árbol crezca demasiado y se sobreajuste.

Mínimo de muestras por hoja: Es el número mínimo de muestras requeridas para que un nodo sea considerado una "hoja" (un nodo terminal).


- **Naive Bayes:**

Asume que todas las características son independientes entre sí, lo que rara vez es cierto en la realidad, pero el modelo sigue funcionando sorprendentemente bien. Calcula la probabilidad de que una muestra pertenezca a una clase basándose en las probabilidades de cada característica. Está basado en el Teorema de Bayes.

Tenemos un parámetro:

Lambda de suavizado: Conocido como suavizado de Laplace. Este parámetro evita que las probabilidades sean cero, lo que podría suceder si una característica no aparece en los datos de entrenamiento.

Flujo de trabajo interno del paso



Esquema 9: Flujo de trabajo del paso 7 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entradas:

muestrasEntrenamiento: ee.FeatureCollection - Parcelas de entrenamiento

listaCaracteristicas: - Lista de índices espectrales

parcelasConEstadisticas: ee.FeatureCollection - Colección completa de parcelas

nombresCampos.entrenamiento: string - Nombre del campo de entrenamiento

selectorClasificador.getValue(): string - Algoritmo seleccionado

Parámetros específicos por algoritmo (árboles, kernel, etc.)

- Salidas:

clasificadorEntrenado: ee.Classifier - Modelo entrenado

parcelasClasificadas: ee.FeatureCollection - Parcelas con columna CLASE_ASIGNADA

Capas del mapa: Visualización separada por tipo de cultivo

Mensajes de estado: Confirmación de clasificación exitosa

Logs de debugging: Información detallada del proceso

Diseño de la interfaz del paso

La interfaz tiene 3 partes diferenciadas:

Panel principal (clasificacionPanel): con el título, panel de ayuda y el selector de algoritmo con 4 opciones (Random Forest, SVM, CART, Naive Bayes)

Panel de parámetros (panelParametros): tiene la configuración de los parámetros del algoritmo seleccionado

Random Forest: Número de árboles, variables por split, muestras por hoja, fracción de bagging

SVM: Tipo de kernel, parámetro C, gamma, grado, shrinking, procedimiento de decisión

CART: Máximo de nodos, mínimo de muestras por hoja

Naive Bayes: Parámetro lambda de suavizado

Controles de Sliders: Para parámetros numéricos con valores predefinidos

Labels dinámicos: Muestran valores actuales de los parámetros

Checkboxes: Para opciones booleanas (shrinking en SVM)

Selectores: Para opciones discretas (tipo de kernel, procedimiento)

Explicación del funcionamiento interno del código para el paso

FUNCION PRINCIPAL: `entrenarClasificador()` es la función que entrena el clasificador

`exportarClasificacion()` - Exporta resultados

Configuración específica por algoritmo, `selectorClasificador.onChange()`:

En este apartado, se emplean funciones específicas de GEE para la realización de las clasificaciones supervisadas, se han empleado con los datos anteriormente mencionados:

Random Forest: `ee.Classifier.smileRandomForest()`

SVM: `ee.Classifier.libsvm()`

CART: `ee.Classifier.smileCart()`

Naive Bayes: `ee.Classifier.smileNaiveBayes()`

PASO 8: EVALUACIÓN Y OPTIMIZACIÓN

Explicación general del paso

Este paso actúa como el sistema de validación y diagnóstico que permite al usuario entender qué tan bien está funcionando su modelo de clasificación y cómo mejorarlo, mediante un análisis completo.

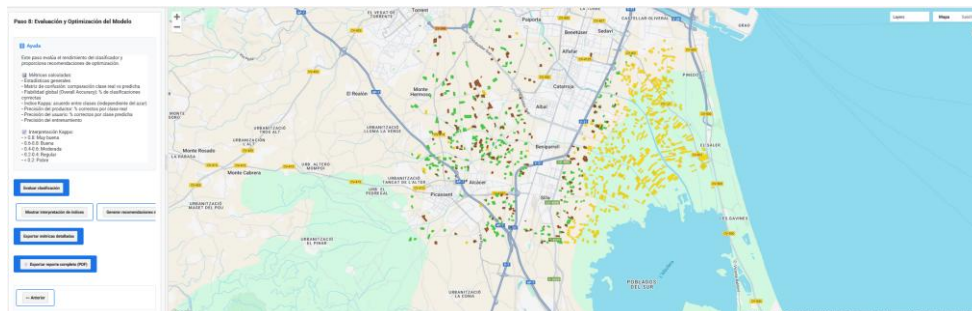


Figura 31: Muestra de interfaz de GEE con el paso 8 (Fuente: Elaboración propia)

El objetivo es evaluar el clasificador mediante estadísticas, proporcionar al usuario una interpretación básica de los índices y unos consejos de optimización.

Información que empleamos en este paso

Para este paso, tenemos que añadir la librería de GEE Classifier, esta librería es la que nos proporcionará los evaluadores que comentamos a continuación.

Las métricas que calculemos y las precisiones, dependen del modelo seleccionado y hay que ir cambiando los parámetros para que sea un modelo más acertado, de ahí que busquemos técnicas de evaluación de modelos. Para esta aplicación, usaremos las siguientes técnicas:

- matriz de confusión: es una tabla que resume el rendimiento del algoritmo, esta matriz muestra la comparación entre la clase predicha del modelo y la real. En la diagonal, encontraremos las predicciones correctas, lo demás, serán falsos positivos o falsos negativos.

		Actual Values	
		Yes	No
Predicted Values	Yes	True Positive	False Positive
	No	False Negative	True Negative

Figura 32: Formato de una matriz de confusión para el paso 8 (Fuente: Comprensión de la Matriz de Confusión y Cómo Implementarla en Python, Admond Lee)

Con el tamaño de las muestras, podemos definir los valores de la matriz de confusión

- Fiabilidad global: calcula la exactitud general de la matriz de confusión. Esta, suma los valores de la diagonal y los divide entre el número total evaluado

$$\text{Fiabilidad Global} = \frac{\text{Verdaderos Positivos} + \text{Verdaderos Negativos}}{\text{Total de Muestras}} \quad (11)$$

- Precisión del productor: es la probabilidad de que en este caso el cultivo sea evaluado correctamente por el modelo. Esto se calcula por cada una de las clases, a esto lo llamamos tasa de acierto.

$$\text{Precisión del Productor} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos}} \quad (12)$$

- Precisión del usuario: a este método se le conoce como precisión, mide la probabilidad de que una predicción del modelo sea correcta. Se hace por cada una de las clases.

$$\text{Precisión del Usuario} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Positivos}} \quad (13)$$

- Índice Kappa: compara la fiabilidad global observada con la fiabilidad global esperada, o, dicho de otro modo, evalúa la concordancia entre las predicciones del modelo y los valores reales del terreno

$$\text{Kappa} = \frac{P_o - P_e}{1 - P_e} \quad (14)$$

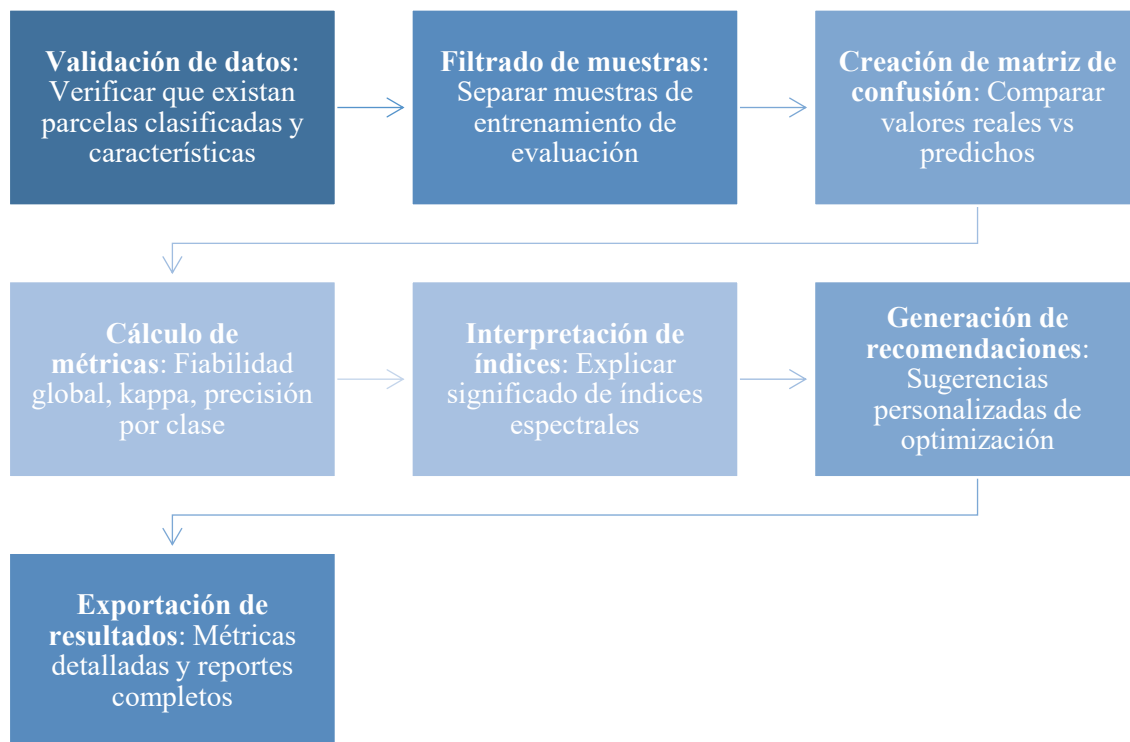
Donde:

P_o (Proporción observada de acuerdo) es la Fiabilidad Global.

P_e (Proporción de acuerdo esperado por azar) es un cálculo más complejo basado en el producto de los totales de filas y columnas. Se calcula como:

$$P_e = \frac{\sum_{i=1}^k (\text{Fila}_i \times \text{Columna}_i)}{\text{Total de Muestras}^2} \quad (14.1)$$

Flujo de trabajo interno del paso



Esquema 10: Flujo de trabajo del paso 8 (Fuente: Elaboración propia)

Variables de entrada y salida del paso

- Entradas:

parcelasClasificadas: ee.FeatureCollection - Parcelas con clasificación aplicada

parcelasConEstadisticas: ee.FeatureCollection - Colección completa de parcelas

listaCaracteristicas: - Lista de índices espectrales utilizados

nombresCampos.evaluacion: string - Nombre del campo de evaluación

configClases: - Configuración de clases y colores

- Salidas:

matrizConfusion: ee.ConfusionMatrix - Matriz de confusión de Earth Engine

metricas: Object - Objeto con todas las métricas calculadas

panelResultadosDetallados: ui.Panel - Panel con resultados de evaluación

panelMatrizConfusion: ui.Panel - Panel con matriz de confusión

panelMetricasDetalladas: ui.Panel - Panel con métricas detalladas

panelRecomendaciones: ui.Panel - Panel con recomendaciones de optimización

Diseño de la interfaz del paso

Panel principal (evaluacionPanel): Contiene el título, el panel de ayuda y los diferentes paneles de resultados

Paneles de resultados:

panelResultadosDetallados: Estadísticas generales y resumen

panelMatrizConfusion: Matriz de confusión visual

panelMetricasDetalladas: Métricas de precisión por clase

panelRecomendaciones: Sugerencias de optimización personalizadas

Explicación del funcionamiento interno del código para el paso

FUNCIÓN PRINCIPAL: evaluarClasificacion(), esta función ejecuta todo el proceso de evaluación, si en alguna métrica aparece NaN, significa que estamos dividiendo por 0 y puede ser un error común. Para este apartado, utilizamos varias funciones propias de GEE que se emplean para la clasificación:

.errorMatrix() - Para crear matriz de confusión

.accuracy() - Para calcular fiabilidad global

.kappa() - Para calcular índice Kappa

.producersAccuracy() - Para precisión del productor

.consumersAccuracy() - Para precisión del usuario

FUNCION DE INTERPRETACION: mostrarInterpretacionIndices(), proporciona explicaciones detalladas de cada índice espectral utilizado en la clasificación. Incluye rangos de valores, significado biológico, casos de uso específicos, y consejos para optimización basados en los índices disponibles.

FUNCION DE VISUALIZACION: mostrarPanelResultadosPaso8(), controla la visibilidad del panel de resultados del Paso 8. Permite mostrar u ocultar los paneles de resultados detallados, matriz de confusión, métricas detalladas, y recomendaciones.

RESULTADOS

Se ha tomado como ejemplo, un shapefile ubicado en la comunidad valenciana y con este shapefile se han hecho las diferentes pruebas para mostrar los resultados:

Primero tenemos en el anexo III, Mapa 1: Mapa de cultivos de SIOSE 2014 sobre parcelas de entrenamiento, un mapa de la distribución de cultivos y sus correspondientes parcelas entrenadas y, en consecuencia, haremos un estudio de las diferentes soluciones que nos tiene que dar la aplicación.

Para el ejemplo, tenemos 3 clases de cultivos asignadas con códigos (0=Arroz, 1=Cítricos, 2=Suelo 99= parcelas que no se usan), esta información está resumida en el apartado de datos donde se menciona como construir el shapefile.

Vamos a observar uno a uno los pasos para verificar que todos requerimientos iniciales se cumplen.

Resultados tras ejecución del paso 0

Tras esta ejecución del Paso 0, los resultados esperables son poder hacer clic en la guía de usuario y que lleve a un enlace con la misma y avanzar al primer paso del proyecto.

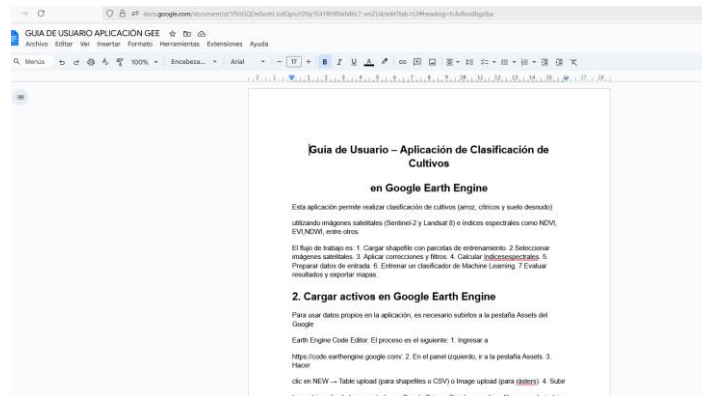


Figura 33: Muestra de la guía de usuario del paso 0 (Fuente: Elaboración propia)

Este resultado ha sido optimo

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

Resultados tras ejecución del paso 1

Tras la ejecución del primer paso, se espera que se visualice un shapefile en el mapa (haciendo zoom a la zona donde se ubica) con 3 campos de tipo integer, que aparezcan los mensajes de éxito o error y que se queden configuradas las variables para futuros pasos (incluido el buffer para futuros cálculos).

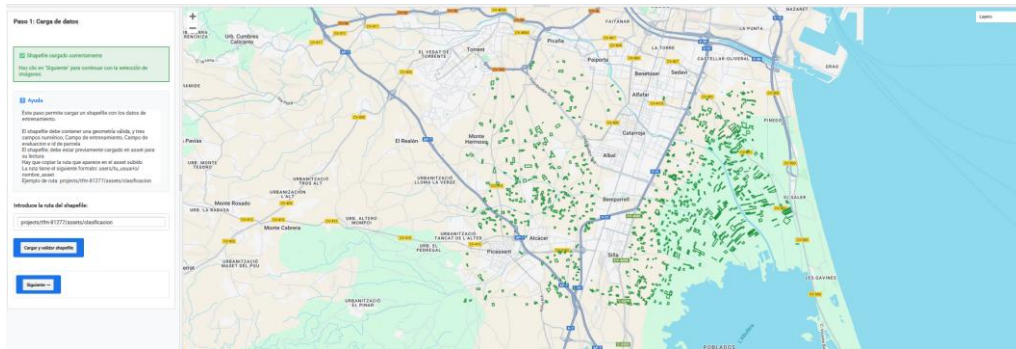


Figura 34: Muestra del resultado del paso 1 (Fuente: Elaboración propia)

Este resultado ha sido optimo.

Resultados tras ejecución del paso 2

Tras la ejecución del paso 2, se busca obtener la información del satélite seleccionado, ver imágenes dentro del buffer establecido pertenecientes al satélite seleccionado y dentro del rango de fechas establecido, crear la colección de imágenes para el siguiente paso.



Figura 35: Muestra del resultado del paso 2 (Fuente: Elaboración propia)

Este resultado ha sido optimo

Resultados tras ejecución del paso 3

Tras la ejecución de este paso, esperamos que cuando tenemos una colección de imágenes y corregimos por un porcentaje de nubes, los huecos que dejan las nubes se rellenan con las imágenes que tiene debajo, pero cuando hay pocas imágenes, se generarán huecos en blanco, como la imagen siguiente.



Figura 36: Muestra del resultado del paso 3 para máscara de nubes (Fuente: Elaboración propia)

Por tanto, esperamos que se visualice la máscara de nubes, que se muestre la información de las estadísticas (mostrando imágenes descartadas que no cumplen el criterio) y dejar la corrección de imágenes corregidas.

Este resultado ha sido optimo.

Resultados tras ejecución del paso 4

Tras este paso, deberían calcularse las bandas y mostrarse en el mapa para cada índice, esto ha resultado de manera óptima. Aunque si se calculan muchos índices, tenemos un problema de limitación de memoria para mostrarlo en el mapa. En el anexo 4 resultado 1, aparece una muestra de la exportación de un periodo. En el anexo III, mapa 2, una muestra de un índice calculado y mostrado sobre el mapa.



Figura 37: Muestra del resultado del paso 4 para cálculo de bandas (Fuente: Elaboración propia)

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

Otro resultado que esperábamos era aplicar las técnicas de suavizado, mostrarlas en graficas temporales y dejar la colección preparada para el siguiente paso.

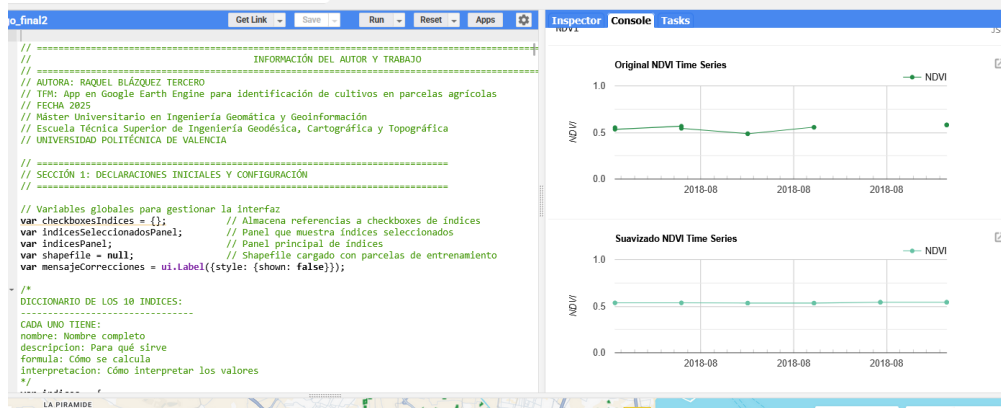


Figura 38: Muestra del resultado del paso 4 para graficas de tecnicas de corrección de ruido (Fuente: Elaboración propia)

Este resultado se ha visto afectado por los límites de memoria de usuario de GEE, dependiendo del periodo seleccionado o el número de índices, llega a calcular algunas graficas. Por otro lado, las tecnicas se aplican, pero dependiendo del periodo o dependiendo de cuantos índices se seleccionen, volvemos a tener el mismo error de “User memory limit exceeded”. Tras esto se han aplicado varias formas de optimizar los resultados, aunque procesa más información, sigue quedándose corto para la memoria que utilizamos.

Paso 4: Calculo de bandas para indices y reducción de ruido

✘ Error en suavizado: User memory limit exceeded.

Selecciona los índices para calcular las bandas correspondientes y reduc

Figura 39: Muestra del resultado del paso 4 error de límite de memoria excedido (Fuente: Elaboración propia)

Por tanto, tras el paso 4, confirmamos que el desarrollo está elaborado de forma correcta, pero hay que hacer pruebas en un entorno donde no esté limitado el uso de memoria.

Resultados tras ejecución del paso 5

Tras este paso, el resultado esperado es una exportación en formato CSV y cargar dichos datos en asset del proyecto. Estos datos van a ser los que utilizemos para el clasificador, los datos tienen que mantener las columnas iniciales del shapefile y tener las composiciones de los diferentes índices, esto se puede ver parte del resultado en el anexo 4, resultado 2

También una muestra de las composiciones calculadas en pantalla. Como podemos ver en el anexo 3, mapa 3.

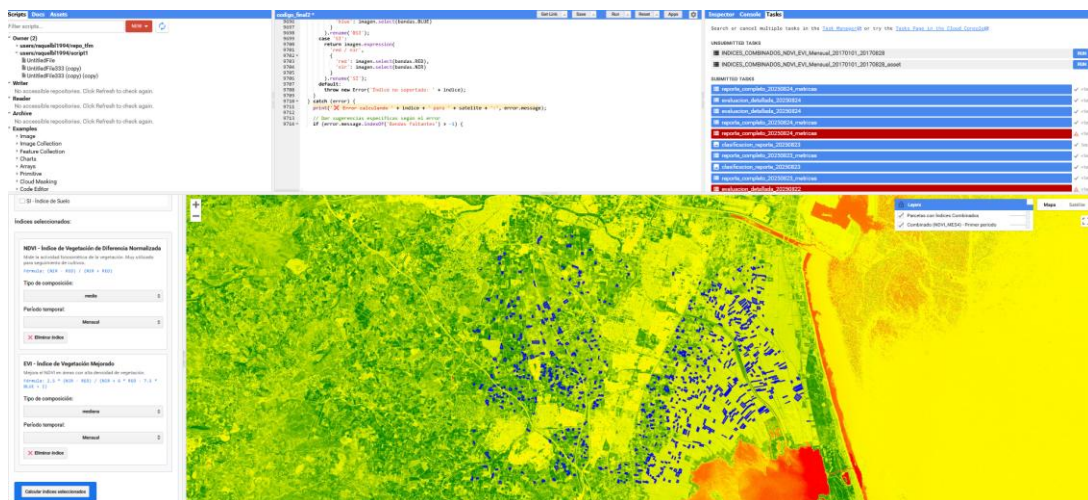


Figura 40: Muestra del resultado del paso 5 (Fuente: Elaboración propia)

Tras la ejecución del paso 5, podemos decir que los resultados son correctos y que se pueden ver los índices para diferentes periodos y composiciones, tanto corregidos como no.

Resultados tras ejecución del paso 6

Los resultados esperados tras la ejecución del paso 6 son: obtener un shapefile con las estadísticas de este en el panel de ayuda, tener identificadas las muestras de entrenamiento para el clasificador así como el nombre de los campos de evaluación y entrenamiento, tener listadas e identificadas todos los códigos de nuestro archivo inicial.

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

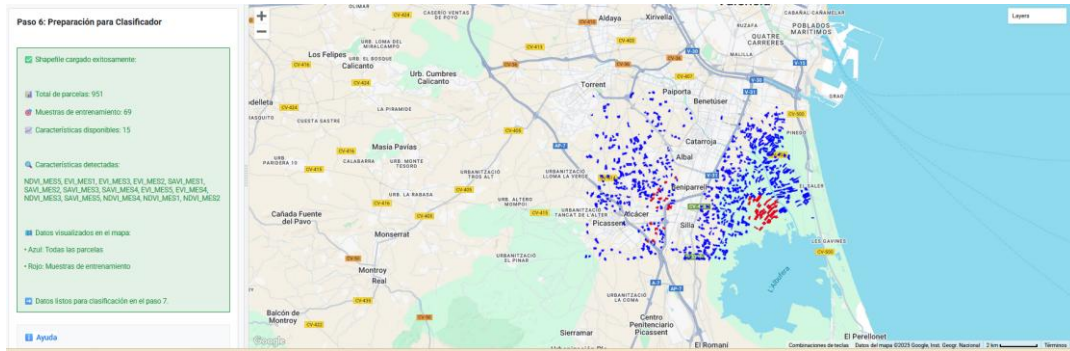


Figura 41: Muestra del resultado del paso 6 (Fuente: Elaboración propia)

Tras la ejecución de este paso, podemos decir que los resultados son óptimos.

Resultados tras ejecución del paso 7

Tras la ejecución del paso 7, los resultados esperados son la muestra de la clasificación en el mapa, con una capa por tipo de cultivo y clase asignadas (también tendremos diferentes colores para asignar dichas clases), información general del clasificador y una exportación de resultados en formato CSV, estos datos los podemos ver en el anexo 4, resultado 3.

También se quiere almacenar el resultado para el siguiente paso.

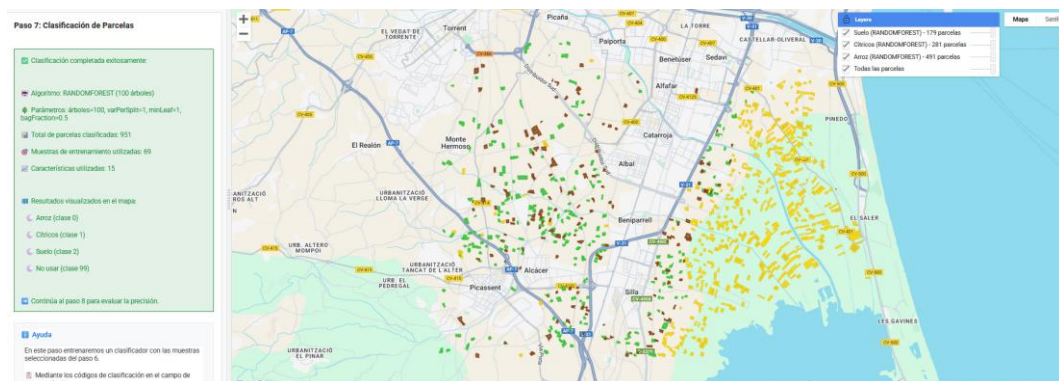


Figura 42: Muestra del resultado del paso 7 (Fuente: Elaboración propia)

Tras la ejecución del paso vemos que todo está como era esperado.

Resultados tras ejecución del paso 8

Tras la ejecución del paso 8, se espera que se haya hecho una evaluación completa del modelo con métricas de precisión calculadas, que haya una interpretación de índices dispuesto como ayuda, que haya una sugerencia de optimización del modelo y que haya la posibilidad de exportar archivos.

Tenemos los siguientes resultados para un modelo usado como ejemplo:

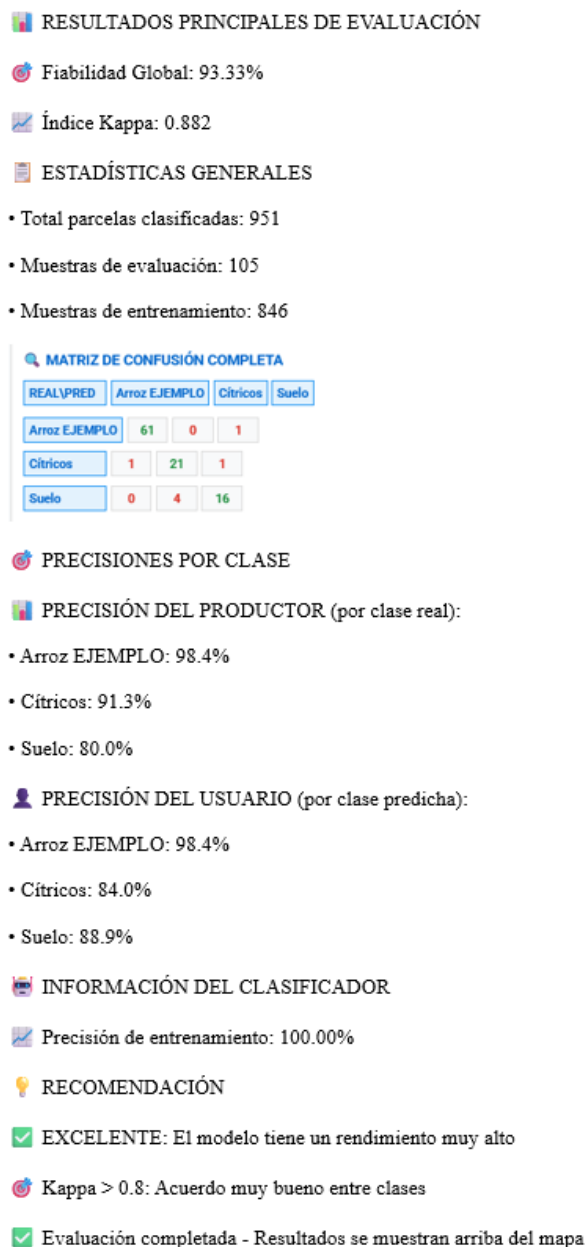


Figura 43: Muestra del resultado de la clasificación del paso 8 (Fuente: Elaboración propia)

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

Esta información saldrá en otro panel con la información de los resultados, además tenemos la opción de ofrecer recomendaciones al usuario.



Figura 44: Muestra del resultado de las recomendaciones del paso 8 (Fuente: Elaboración propia)

También tenemos la opción de ver una interpretación de los índices

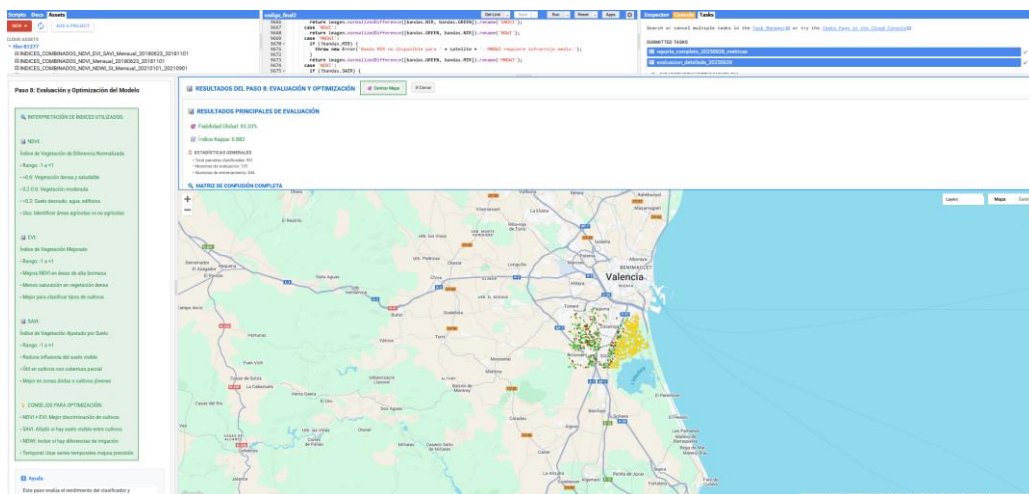


Figura 45: Muestra del resultado de la interpretación de índices del paso 8 (Fuente: Elaboración propia)

Por último, podemos obtener la evaluación detallada y el reporte completo como podemos ver en el anexo 4 resultado 4

En general, todos los resultados son lo esperado para cada uno de los apartados. Durante el desarrollo, se observó que la interfaz de usuario de la aplicación en Google Earth Engine no solo facilitó el proceso, sino que también mejoró la interpretación de los resultados. La visualización interactiva de las series temporales de índices espectrales para cada píxel permitió una validación visual del modelo. Pero también tenemos excepciones.

Para las parcelas que teníamos que entrenar, tenemos que el acierto del tipo de clase es muy elevado, todo ello depende de los datos y la clasificación que el usuario haga con el clasificador, el ejemplo de las parcelas clasificadas sobre el mapa de cultivos, le encontramos en el anexo 3, mapa 4

Como hemos visto en el paso 4, las limitaciones de memoria para GEE son muy importantes y es porque tiene una RAM finita para garantizar la estabilidad de la plataforma. En la siguiente tabla, se muestran las limitaciones:

Tipo de cuota	Valor predeterminado (por proyecto)
Máx. de solicitudes simultáneas (endpoint estándar)	40 solicitudes simultáneas
Máximo de solicitudes simultáneas (endpoint de gran volumen)	40 solicitudes simultáneas
Tasa máxima de solicitudes (por proyecto)	100 solicitudes por segundo (6,000 solicitudes por minuto)
Tasa máxima de solicitudes (por cuenta)	100 solicitudes por segundo (6,000 solicitudes por minuto)
Promedio de tareas por lotes simultáneas	2 tareas (en promedio)
Espacio máximo de almacenamiento de recursos	250 GB
Cantidad máxima de recursos	10,000
Tiempo de procesamiento de Earth Engine (tiempo de EECU) por día en segundos	ilimitado

Figura 46: Muestra de limitaciones de GEE (Fuente: GEE)

Para el código, se han añadido varias medidas de optimización y así los errores de limitación de memoria, se han ido solucionando en gran medida. Las medidas implementadas son:

- REEMPLAZO DE `.median()` POR `.first()`: En lugar de calcular la mediana de todas las imágenes procesadas, solo toma la primera imagen.

Por ejemplo, si antes tenías 500 imágenes procesadas, `median()` intenta cargar TODAS en memoria, calcular la mediana de cada píxel, y luego mostrar el resultado. Tras la medida, solo se carga una imagen en memoria.

- ELIMINACIÓN DE `.getInfo()`: Elimina las llamadas que intentan obtener información exacta de colecciones grandes.

Esta llamada, fuerza a Google Earth Engine a procesar y contar TODAS las imágenes de una colección. Después de esto, solo verifica si la colección existe

- **LÍMITES DINÁMICOS EN GRÁFICOS:** Ajusta automáticamente cuántas imágenes se muestran en los gráficos según el tipo de etapa.

Anteriormente, todos los gráficos mostraban 120 imágenes, sin importar si era la etapa "Original" (con pocas imágenes) o "Interpolación" (con muchas imágenes). Tras esto, se pone las etapas básicas (Original, Suavizado, Relleno) con 120 imágenes y las etapas complejas (Interpolación, Savitzky) con 60 imágenes

- **REGIONES OPTIMIZADAS:** Reduce el tamaño del área que se procesa para generar gráficos.

Antes se usaba un área grande (escala $\times 1$) para generar gráficos. Luego, se usa un área más pequeña (escala $\times 0.5$).

- **VERIFICACIÓN ROBUSTA DE BANDAS:** Verifica que las bandas de índices existan sin operaciones que consuman memoria.

Anteriormente, se intentaba verificar datos en varios pasos, usando operaciones complejas que podían fallar. Tras esta técnica, se intenta acceder directamente a la banda.

- **SISTEMA DE FALLBACK:** Si falla la visualización de las imágenes procesadas, automáticamente muestra las imágenes originales.

Antes si fallaba algo, perdías toda la visualización, ahora se ve lo original.

- **LÍMITE ESTRICTO DE INTERPOLACIÓN:** Limita el número máximo de imágenes interpoladas a 50.

Antes, la interpolación generaba muchísimas imágenes

- **OPTIMIZACIÓN AGRESIVA DE INTERVALOS:** Ajusta automáticamente el intervalo de interpolación según el número de imágenes.

Antes, si tenías 1000 imágenes, se intentaba interpolar cada 5 días, generando 200 imágenes interpoladas. Ahora, si tienes más de 100 imágenes se multiplica por 4 el intervalo (cada 20 días) y si tienes más de 50. Se multiplica por 2 el intervalo (cada 10 días)

- **VERIFICACIÓN SEGURA DE TAMAÑOS:** Esto solo verifica que las colecciones existan, sin contar cuántas imágenes contienen.

Antes, se intentaba contar exactamente cuántas imágenes había en cada etapa, y luego solo se verifica que se haya procesado bien

- **REDUCCIÓN DE BUFFERS:** Reduce el tamaño del área de estudio cuando es muy grande. Reduce el número de píxeles a procesar en áreas grandes. Pero también hay que tener en cuenta, que una buena práctica es tener parcelas no muy separadas

Si es mayor a 50 km², se aplica un buffer más pequeño.

- **LÍMITE EN VENTANAS TEMPORALES:** Limita el número de imágenes que se usan para calcular promedios en cada ventana temporal.

Ahora se cogen máximo 8 imágenes por ventana temporal en vez de todas las imágenes.

- **ESTIMACIÓN DE IMÁGENES:** Si no se puede contar exactamente cuántas imágenes hay, usa una estimación.

Con esto nos aseguramos de que siempre se genera un gráfico, aunque sea con una estimación.

PRESUPUESTO

Para esta parte, se ha tenido en cuenta el salario medio de los desarrolladores geoespaciales, aunque depende de la ubicación del desarrollador, he añadido una oscilación de precios en el rango en el que se puede encontrar la aplicación.

Además de este presupuesto que incluye únicamente el coste humano, hay que tener en cuenta el coste de la plataforma, en este caso se ha utilizado con fines académicos por lo que el precio ha sido gratuito. Enfocado a un uso comercial, el precio puede variar dependiendo de la oferta que se escoja, tienen un programa para Startups y otro para uso comercial (por ejemplo, la básica es de 500 USD al mes). Además de la licencia, aplica cargos adicionales como el almacenamiento, los precios de los recursos de computación se cobran por hora y también cobran aparte los usuarios adicionales.

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

Fase	Actividad	Horas Estimadas	Coste por Hora (€)	Coste Total (€)
1. Planificación y Diseño	Análisis de Requisitos	20	50-75	1.000-1.500
1. Planificación y Diseño	Análisis de Datos	30	50-75	1.500-2.250
1. Planificación y Diseño	Diseño de la Arquitectura	30	50-75	1.500-2.250
Total Fase 1		80		4.000-6.000
---	---	---	---	---
2. Programación y Desarrollo	Codificación Principal (Algoritmos)	200	50-75	10.000-15.000
2. Programación y Desarrollo	Desarrollo de Interfaz de Usuario (UI/UX)	100	50-75	5.000-7.500
2. Programación y Desarrollo	Correcta Integración de Componentes	50	50-75	2.500-3.750
Total Fase 2		350		17.500-26.250
---	---	---	---	---
3. Validación y Pruebas	Pruebas de integración	60	50-75	3.000-4.500
3. Validación y Pruebas	Validación del Resultados	40	50-75	2.000-3.000
Total Fase 3		100		5.000-7.500
---	---	---	---	---
4. Documentación	Documentación del Código	55	50-75	2.750-4.125
4. Documentación	Documentación Técnica	15	50-75	750-1.125
Total Fase 4		70		3.500-5.250
---	---	---	---	---
TOTAL DEL PROYECTO		600		30.000-45.000

Tabla 4: Presupuesto (Fuente: Elaboración propia)

CONCLUSIONES

La teledetección y el aprendizaje automático, han tenido un gran impacto en la agricultura, procesando grandes cantidades de información rápidamente y mejorando las técnicas de trabajo, evolucionando a una forma automática de trabajo.

El desarrollo de una aplicación de detección automática de cultivos en GEE, ha demostrado que, mediante un flujo de trabajo ordenado y automático, unido a los algoritmos de ML para clasificación, hacen posible identificar diferentes tipos de cultivos con gran facilidad, además de proporcionar una evaluación de la clasificación realizada.

La aplicación está orientada a un público con conocimientos básicos de teledetección, pero puede ser fácilmente manejada por otro tipo de usuarios que no tengan dichos conocimientos y necesiten esta herramienta para algún campo del sector agrícola, por tanto, estamos ante una aplicación accesible y fácil de utilizar.

La aplicación se puede usar como dos aplicaciones independientes, por un lado, el tratamiento de imágenes y por otro la clasificación de datos, esto puede facilitar la implementación del código en otros trabajos futuros, ya que no tenemos un código 100% dependiente entre sí.

La plataforma de GEE proporciona grandes volúmenes de imágenes satelitales de forma casi instantánea facilitando los estudios de series temporales que son la clave para identificar los diferentes tipos de cultivo por su ciclo vegetativo.

Tras la realización de la aplicación, se han detectado problemas de limitaciones de memoria al usar una versión gratuita, estas limitaciones no se tenían contemplados antes del desarrollo de la aplicación. Por un lado, se han intentado solventar implementando diferentes medidas de optimización, aunque muchos de los problemas se han logrado solventar, la gran cantidad de memoria que manejamos no ha dejado solucionar todos los rendimientos. Esto se dejará abierto, por lo que habría que investigar en esta dirección para mejorar el rendimiento, ejecutar la aplicación en diferentes tipos de suscripciones de GEE o desarrollar la aplicación en otra plataforma utilizando la API que dispone GEE, esta línea de actuación servirá para utilizar diferentes librerías externas que mejoren el rendimiento. Este problema, hizo que se enfocara la aplicación en la implementación de funciones más robustas y evitar cálculos innecesarios en el proceso de desarrollo.

La aplicación tiene una gran utilidad en el actual contexto de globalización, por un lado, la utilización de bases de datos de cultivos y su necesidad de constante actualización, hace necesario el desarrollo de una herramienta similar para reducir costes y automatizar el monitoreo de grandes áreas, todo esto también influye en la toma de decisiones en el ámbito de la seguridad alimentaria y de la gestión ambiental. Por otro lado, la aplicación puede proporcionar grandes beneficios tecnológicos al ser de código abierto, ayudando a otros desarrolladores a la realización de sus funcionalidades y al ser accesible y fácil de

usar acerca un campo tan complejo como es la teledetección y el ML a otros ámbitos de forma clara y sencilla.

Hemos detectado tras los resultados, varios desafíos, hay una falta de información para el desarrollo de una aplicación de detección automática de cultivos a nivel global, habría que fusionarlo con otras técnicas de teledetección como la delimitación de cultivos de la que ya se están realizando multitud de estudios, y habría que aplicar otras técnicas para zonas donde el tipo de cultivos es más confuso. Como hemos visto, el entrenamiento de cultivos mediante ML, tiene también dificultades para diferenciar algunos tipos de cultivos, ya sea porque entre ellos comparten gran similitud espectral, como puede ser el caso de diferentes tipos de cítricos o tipos de cereales, o bien porque tienen el mismo ciclo fenológico, como puede ser el caso de la agricultura mixta, o que se den diferentes factores ambientales o climáticos que afecten a la clasificación como una sequía en una determinada época o una inundación, también resulta difícil entrenar el modelo en pequeñas parcelas, pudiendo tener en un mismo píxel diferentes tipos de cultivo. La aplicación, es una gran base para futuros trabajos y para diferenciar grupos de cultivos, pero hay en muchos aspectos que hay que hacer bastantes estudios a fondo para mejorar todas estas estadísticas para la diferenciación de cultivos, para entrenar modelos que sepan identificar los patrones complejos a los que nos podemos enfrentar.

Otra línea de actuación, es que además de índices espectrales, se añada información sobre otros datos que nos ayuden a diferenciar el tipo de cultivos como pueden ser las elevaciones o datos climáticos. También, se podrían añadir otros algoritmos de clasificación que no pasan por la clasificación supervisada como pueden ser las redes neuronales. Por otro lado, se podrían combinar diferentes datos como combinar Sentinel-1 y Sentinel-2, ya que es una buena práctica o segmentar las parcelas para diferenciar mejor los cultivos dentro de una misma parcela.

Al incluir una evaluación del modelo, podemos demostrar la precisión de la clasificación realizada objetivamente ya no solo demostrando la precisión sino incorporando un paso fundamental a la hora de realizar estudios con ML, ya que permite diferenciar los tipos de modelos para elegir el más óptimo. Además, esta evaluación nos dirá mediante las métricas de precisión como la matriz de confusión o el índice Kappa, las clases de tipo de cultivos, en las que el modelo tiene más dificultades para identificar, y a su vez convertir estas dificultades en futuras líneas de trabajo, convirtiendo los puntos débiles de los modelos en futuros desarrollos en los que enfocarse y fortalecer.

BIBLIOGRAFÍA

Gao, X., Chi, H., Huang, J., Han, Y., Li, Y., & Ling, F. (2024). Comparison of cloud-mask algorithms and machine-learning methods using Sentinel-2 imagery for mapping paddy rice in Jiangnan Plain. *Remote Sensing*, 16, 1305. <https://doi.org/10.3390/rs16071305>

Gitelson, A. A., & Merzlyak, M. N. (1998). Remote sensing of chlorophyll content in higher plant leaves. *Advances in Space Research*, 22(5), 689–692.

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>

Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309.

Huete, A., et al. (2002). Overview of the MODIS vegetation index products. *Remote Sensing of Environment*, 83(1–2), 1–16. Recuperado de https://cimss.ssec.wisc.edu/dbs/China2011/Day2/Lectures/MODIS_MOD13_NDVI_referenc.pdf

Khan, M. M. A. (2018). Soil Index (SI) and Normalised Difference Water Index (NDWI) for mapping soil and water from Landsat 8 data. *International Journal of Remote Sensing & Geoscience*, 7(3), 10–16.

Lary, D. J., et al. (2016). Machine learning in geosciences and remote sensing. *IEEE Geoscience and Remote Sensing Magazine*, 4(3), 64–81.

Lillesand, T. M., & Kiefer, R. W. (2015). *Remote sensing and image interpretation* (7th ed.). John Wiley & Sons.

Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236.

Xu, H. (2006). Modification of Normalized Difference Water Index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025–3033.

Zha, Y., Gao, J., & Ni, S. (2003). Use of Normalized Difference Built-Up Index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24, 583–594.

Páginas web:

Datasource.ai. (n.d.). Comprensión de la matriz de confusión y cómo implementarla en Python. Recuperado de <https://www.datasource.ai/es/data-science-articles/comprension-de-la-matriz-de-confusion-y-como-implementarla-en-python>

EOS Data Analytics. (2024). Interpretación de imágenes satelitales: elementos y métodos. Recuperado de <https://eos.com/es/blog/interpretacion-de-imagenes-satelitales/>

European Space Agency (ESA). (n.d.). Sentinel-1. Recuperado de <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-1>

European Space Agency (ESA). (n.d.). Sentinel-2. Recuperado de <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>

Google. (n.d.). Debugging and optimizing scripts. Earth Engine Developer Guide. Recuperado de <https://developers.google.com/earth-engine/guides/debugging>

Google. (n.d.). Earth Engine Developer Guide. Recuperado de <https://developers.google.com/earth-engine/guides>

Google. (n.d.). Exporting data. Earth Engine Developer Guide. Recuperado de <https://developers.google.com/earth-engine/guides/exporting>

Google. (n.d.). Machine learning. Earth Engine Developer Guide. Recuperado de <https://developers.google.com/earth-engine/guides/machine-learning?hl=es-419>

Google. (n.d.). Sentinel-2 cloudless. Earth Engine Community Tutorials. Recuperado de <https://developers.google.com/earth-engine/tutorials/community/sentinel-2-s2cloudless>

Mapify. (n.d.). Mapas conceptuales. Recuperado de https://docs.google.com/presentation/d/1-zEOJ565PKX6nMSeWGadge_1S0jDxmU-3_1GKKyVXwA/edit

Máster GeoForest. (2024). Capítulo 6. Recuperado de https://mastergeoforest.es/wp-content/uploads/2024/09/Capitulo_6.pdf

NASA Applied Sciences. (2021). Clasificación de cultivos agrícolas con radar de apertura sintética y teledetección óptica. Recuperado de https://appliedsciences.nasa.gov/sites/default/files/2021-10/Parte4_Teoria_y%20Final_ESP.pdf

NASA Applied Sciences. (2025). Spectral indices. Parte 1. Recuperado de https://appliedsciences.nasa.gov/sites/default/files/2025-02/Spectral_Indices_Part1_JO_Span_0.pdf

DESARROLLO DE UNA APP EN GOOGLE EARTH ENGINE PARA IDENTIFICACIÓN DE CULTIVOS EN PARCELAS AGRÍCOLAS

Raquel Blázquez Tercero

National Aeronautics and Space Administration (NASA) & U.S. Geological Survey (USGS). (n.d.). Landsat 8. Recuperado de <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>

Repuestos Fuster. (2024). ¿Qué es el machine learning y qué usos tiene en el campo? Recuperado de <https://www.repuestosfuster.com/blog/que-es-el-machine-learning-y-que-usos-tiene-en-el-campo/>

SIOSE. (2014). Sistema de Información sobre Ocupación del Suelo en España. Recuperado de <https://www.siose.es/presentacion>

Video tutoriales de la aplicación

PASO 0: <https://youtu.be/vBFIHKQzip4>

PASO 1: <https://youtu.be/kx1pXzKK1Tg>

PASO 2: <https://youtu.be/E2Qc11xQVBE>

PASO 3: <https://youtu.be/JYmUb2GMTxU>

PASO 4: https://youtu.be/_vB_NBSDC-s

PASO 5: https://youtu.be/_cWBYNYyhsU

PASO 6: <https://youtu.be/CYUobUKI30s>

PASO 7: <https://youtu.be/kTjFgbY2oHE>

PASO 8: <https://youtu.be/IBsEHXf63Jo>

Video completo: <https://youtu.be/OPR0N00xhtA>

ANEXOS

Anexo I: Acceso al código abierto

Este código se encuentra disponible en la aplicación de GEE, para poder acceder a ella, se tendrá que acceder a la siguiente url:

<https://code.earthengine.google.com/8bb2b25b1c8722e3c727cf44150be123>

Anexo II: Siglas empleadas

UI: Interfaz de Usuario

GEE: Google Earth Engine

ML: Machine Learning (Aprendizaje Automático)

NDVI: Normalized Difference Vegetation Index (Índice de Vegetación de Diferencia Normalizada)

NDWI: Normalized Difference Water Index (Índice de Agua de Diferencia Normalizada)

SI: Soil Index (Índice de Suelo)

EVI: Enhanced Vegetation Index (Índice de Vegetación Mejorado)

SAVI: Soil Adjusted Vegetation Index (Índice de Vegetación Ajustado al Suelo)

GNDVI: Green Normalized Difference Vegetation Index (Índice de Vegetación de Diferencia Normalizada Verde)

MNDWI: Modified Normalized Difference Water Index (Índice de Agua de Diferencia Normalizada Modificado)

NDBI: Normalized Difference Built-up Index (Índice Normalizado de Áreas Construidas)

NBI: Normalized Burn Ratio Index / Normalized Built-up Index (dependiendo del contexto: Índice de Áreas Quemadas o de Construcciones)

BSI: Bare Soil Index (Índice de Suelo Desnudo)

CORINE Land Cover (CLC): Coordinated Information on the European Environment – Land Cover (Programa de Cobertura del Suelo de Europa)

IDE: Infraestructura de Datos Espaciales

SIOSE: Sistema de Información sobre Ocupación del Suelo en España

SAR: Synthetic Aperture Radar (Radar de Apertura Sintética)

ESA: European Space Agency (Agencia Espacial Europea)

GRD: Ground Range Detected (Imagen de Radar Detectada en Rango Terrestre)

USGS: United States Geological Survey (Servicio Geológico de los Estados Unidos)

OEEL: Open Earth Engine Library

SVM: Support Vector Machines (Máquinas de Vectores de Soporte)

CART: Classification and Regression Trees (Árboles de Clasificación y Regresión)

Anexo III: Mapas completos generados.

Mapa 1: Mapa de cultivos de SIOSE 2014 sobre parcelas de entrenamiento

Mapa 2: Índice NDVI como resultado del cálculo de bandas del paso 4

Mapa 3: Índice NDVI calculado mediante media mensual

Mapa 4: Comparación de parcelas clasificadas con usos del suelo del siose 2014

4360000N


4370000N

720000E

730000E

730000E

730000E



4360000N

4370000N

**Mapa 1 : Mapa de cultivos de SIOSE 2014
sobre parcelas de entrenamiento**

Legenda de usos

	Casco
	Ensanche
	Discontinuo
	Zona verde urbana
	Instalación agrícola y/o ganadera
	Extracción minera
	Industrial
	Servicio Dotacional
	Red viaria o ferroviaria
	Puerto
	Aeropuerto
	Infraestructura de suministro
	Infraestructura de residuos
	Cultivo herbáceo
	Invernadero
	Frutal cítrico
	Frutal no cítrico
	Olivar
	Combinación de cultivos leñosos
	Combinación de cultivos
	Combinación de cultivos con vegetación
	Bosque de coníferas
	Bosque mixto
	Pastizal o herbazal
	Matorral
	Combinación de vegetación
	Playa, duna o arenal
	Temporalmente desartbolado por incendios
	Suelo desnudo
	Marisma
	Curso de agua
	Lago o laguna
	Lámina de agua artificial
	Mar

Autora: Raquel Blázquez Tercero

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,
Cartográfica y Topográfica

SIOSE 2014, elaboración propia




ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

MAPA 2: IMAGEN SATELITE CON BANDA NDVI COMO RESULTADO DEL PASO 4



Autora: Raquel Blázquez Tercero

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,
Cartográfica y Topográfica

NDVI PROCEDENTE DE SENTINEL-2

Fecha: 01/09/2025




ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

MAPA 3: BANDA NDVI COMO RESULTADO DEL PASO 5



Autora: Raquel Blázquez Tercero

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,
Cartográfica y Topográfica

NDVI PRIMER MES MEDIA MENSUAL PROCEDENTE DE SENTINEL-2

Fecha: 01/09/2025




ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA



UNIVERSITAT
POLITECNICA
DE VALÈNCIA

Parcelas clasificadas sobre mapa de cultivos de SIOSE 2014



Legenda de usos

parcelas clasificadas	arroz
	citricos
	suelo
T POLIGONOS	
	Casco
	Ensanche
	Discontinuo
	Zona verde urbana
	Instalación agrícola y/o ganadera
	Extracción minera
	Industrial
	Servicio Dotacional
	Red viaria o ferroviaria
	Puerto
	Infraestructura de suministro
	Infraestructura de residuos
	Cultivo herbáceo
	Invernadero
	Frutal cítrico
	Olivar
	Combinación de cultivos leñosos
	Combinación de cultivos
	Combinación de cultivos con vegetación
	Bosque de coníferas
	Pastizal o herbazal
	Matorral
	Combinación de vegetación
	Playa, duna o arenal
	Temporalmente desarbolado por incendios
	Suelo desnudo
	Marisma
	Curso de agua
	Lago o laguna
	Lámina de agua artificial
	Mar

Autora: Raquel Blázquez Tercero

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Geodésica,

Cartográfica y Topográfica

Parcelas clasificadas con base del SIOSE 2014, elaboración propia



ESCUELA TÉCNICA SUPERIOR
DE INGENIERÍA GEODÉSICA
CARTOGRÁFICA Y TOPOGRÁFICA



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

Anexo IV: Tablas o resultados intermedios.

Resultado 1: Serie temporal exportada del paso 4 para NDVI

Resultado 2: Índice combinado NDVI y EVI para clasificación.

Resultado 3: Parcelas clasificadas con random forest

Resultado 4: Exportación detallada y general de la evaluación de parcelas

system:index	fecha	indice	valor	.geo
20190101T105439_20190101T105645_T30SYJ	01/01/2019	NDVI	0.243968389908871	{"type":"MultiPoint","coordi
20190101T105439_20190101T105645_T31SBD	01/01/2019	NDVI	0.237719070081821	{"type":"MultiPoint","coordi
20190106T105431_20190106T105433_T30SYJ	06/01/2019	NDVI	0.234824287526112	{"type":"MultiPoint","coordi
20190106T105431_20190106T105433_T31SBD	06/01/2019	NDVI	0.229860440925866	{"type":"MultiPoint","coordi
20190111T105419_20190111T105807_T30SYJ	11/01/2019	NDVI	0.239828711223863	{"type":"MultiPoint","coordi
20190111T105419_20190111T105807_T31SBD	11/01/2019	NDVI	0.235880993668411	{"type":"MultiPoint","coordi
20190116T105401_20190116T105431_T30SYJ	16/01/2019	NDVI	0.213767964782514	{"type":"MultiPoint","coordi
20190116T105401_20190116T105431_T31SBD	16/01/2019	NDVI	0.210144958519256	{"type":"MultiPoint","coordi
20190121T105349_20190121T105535_T30SYJ	21/01/2019	NDVI	0.225093289611056	{"type":"MultiPoint","coordi
20190121T105349_20190121T105535_T31SBD	21/01/2019	NDVI	0.221838796045465	{"type":"MultiPoint","coordi
20190126T105321_20190126T105420_T30SYJ	26/01/2019	NDVI	0.219314201361184	{"type":"MultiPoint","coordi
20190126T105321_20190126T105420_T31SBD	26/01/2019	NDVI	0.217412604511336	{"type":"MultiPoint","coordi
20190205T105231_20190205T105330_T30SYJ	05/02/2019	NDVI	0.187200467325022	{"type":"MultiPoint","coordi
20190205T105231_20190205T105330_T31SBD	05/02/2019	NDVI	0.186145081030841	{"type":"MultiPoint","coordi
20190210T105209_20190210T105626_T30SYJ	10/02/2019	NDVI	0.047057340527858	{"type":"MultiPoint","coordi
20190210T105209_20190210T105626_T31SBD	10/02/2019	NDVI	0.044002332065222	{"type":"MultiPoint","coordi
20190220T105059_20190220T105057_T30SYJ	20/02/2019	NDVI	0.223757465848273	{"type":"MultiPoint","coordi
20190220T105059_20190220T105057_T31SBD	20/02/2019	NDVI	0.225967818988292	{"type":"MultiPoint","coordi
20190225T105021_20190225T105315_T30SYJ	25/02/2019	NDVI	0.219398398409986	{"type":"MultiPoint","coordi
20190225T105021_20190225T105315_T31SBD	25/02/2019	NDVI	0.219472175344399	{"type":"MultiPoint","coordi
20190302T105029_20190302T105637_T30SYJ	02/03/2019	NDVI	0.228776835880981	{"type":"MultiPoint","coordi
20190302T105029_20190302T105637_T31SBD	02/03/2019	NDVI	0.229405622920127	{"type":"MultiPoint","coordi
20190307T105021_20190307T105430_T30SYJ	07/03/2019	NDVI	0.297036449945742	{"type":"MultiPoint","coordi
20190307T105021_20190307T105430_T31SBD	07/03/2019	NDVI	0.296060359810311	{"type":"MultiPoint","coordi
20190312T105119_20190312T105121_T30SYJ	12/03/2019	NDVI	0.268903020893792	{"type":"MultiPoint","coordi
20190312T105119_20190312T105121_T31SBD	12/03/2019	NDVI	0.268899249991764	{"type":"MultiPoint","coordi
20190317T105021_20190317T105035_T30SYJ	17/03/2019	NDVI	0.271467963128621	{"type":"MultiPoint","coordi
20190317T105021_20190317T105035_T31SBD	17/03/2019	NDVI	0.272262744707800	{"type":"MultiPoint","coordi
20190322T105029_20190322T105540_T30SYJ	22/03/2019	NDVI	0.165002114468114	{"type":"MultiPoint","coordi
20190322T105029_20190322T105540_T31SBD	22/03/2019	NDVI	0.167356948420487	{"type":"MultiPoint","coordi
20190327T105031_20190327T105026_T30SYJ	27/03/2019	NDVI	0.27786552280873	{"type":"MultiPoint","coordi
20190327T105031_20190327T105026_T31SBD	27/03/2019	NDVI	0.277702507979756	{"type":"MultiPoint","coordi
20190406T105031_20190406T110005_T31SBD	06/04/2019	NDVI		{"type":"MultiPoint","coordi
20190411T105029_20190411T105100_T30SYJ	11/04/2019	NDVI	0.286081213188985	{"type":"MultiPoint","coordi
20190411T105029_20190411T105100_T31SBD	11/04/2019	NDVI	0.286625785648517	{"type":"MultiPoint","coordi
20190416T105031_20190416T105927_T30SYJ	16/04/2019	NDVI	0.193369756434565	{"type":"MultiPoint","coordi
20190416T105031_20190416T105927_T31SBD	16/04/2019	NDVI	0.193629816808743	{"type":"MultiPoint","coordi
20190426T105031_20190426T105613_T30SYJ	26/04/2019	NDVI	0.309599119478783	{"type":"MultiPoint","coordi
20190426T105031_20190426T105613_T31SBD	26/04/2019	NDVI	0.312946255305885	{"type":"MultiPoint","coordi
20190501T105039_20190501T105819_T30SYJ	01/05/2019	NDVI	0.228812861488434	{"type":"MultiPoint","coordi
20190501T105039_20190501T105819_T31SBD	01/05/2019	NDVI	0.229404542990995	{"type":"MultiPoint","coordi
20190506T105031_20190506T105918_T30SYJ	06/05/2019	NDVI	0.275076573470896	{"type":"MultiPoint","coordi
20190506T105031_20190506T105918_T31SBD	06/05/2019	NDVI	0.272942838853142	{"type":"MultiPoint","coordi
20190511T105039_20190511T105205_T30SYJ	11/05/2019	NDVI	0.264174079683038	{"type":"MultiPoint","coordi
20190511T105039_20190511T105205_T31SBD	11/05/2019	NDVI	0.264322294118890	{"type":"MultiPoint","coordi
20190516T105031_20190516T105030_T30SYJ	16/05/2019	NDVI	0.300886178421202	{"type":"MultiPoint","coordi
20190516T105031_20190516T105030_T31SBD	16/05/2019	NDVI	0.296035428463616	{"type":"MultiPoint","coordi
20190526T105031_20190526T105519_T30SYJ	26/05/2019	NDVI	0.300780813934345	{"type":"MultiPoint","coordi
20190526T105031_20190526T105519_T31SBD	26/05/2019	NDVI	0.301684135372420	{"type":"MultiPoint","coordi
20190531T105039_20190531T105900_T30SYJ	31/05/2019	NDVI	0.326488970542249	{"type":"MultiPoint","coordi
20190531T105039_20190531T105900_T31SBD	31/05/2019	NDVI	0.326997371846409	{"type":"MultiPoint","coordi
20190605T105031_20190605T105539_T30SYJ	05/06/2019	NDVI	0.310192048870980	{"type":"MultiPoint","coordi
20190605T105031_20190605T105539_T31SBD	05/06/2019	NDVI	0.315703583017329	{"type":"MultiPoint","coordi
20190610T105039_20190610T105331_T30SYJ	10/06/2019	NDVI	0.313816136881330	{"type":"MultiPoint","coordi
20190610T105039_20190610T105331_T31SBD	10/06/2019	NDVI	0.315490189427645	{"type":"MultiPoint","coordi
20190615T105031_20190615T105149_T30SYJ	15/06/2019	NDVI	0.331327280758464	{"type":"MultiPoint","coordi
20190615T105031_20190615T105149_T31SBD	15/06/2019	NDVI	0.339985238711942	{"type":"MultiPoint","coordi
20190620T105039_20190620T105906_T30SYJ	20/06/2019	NDVI	0.264149846653710	{"type":"MultiPoint","coordi
20190620T105039_20190620T105906_T31SBD	20/06/2019	NDVI	0.265570141828977	{"type":"MultiPoint","coordi
20190625T105031_20190625T105346_T30SYJ	25/06/2019	NDVI	0.311891622585577	{"type":"MultiPoint","coordi
20190625T105031_20190625T105346_T31SBD	25/06/2019	NDVI	0.314368415176480	{"type":"MultiPoint","coordi
20190630T105039_20190630T105035_T30SYJ	30/06/2019	NDVI	0.444959948534846	{"type":"MultiPoint","coordi
20190630T105039_20190630T105035_T31SBD	30/06/2019	NDVI	0.431574477314489	{"type":"MultiPoint","coordi
20190705T105031_20190705T105032_T30SYJ	05/07/2019	NDVI	0.454064881286453	{"type":"MultiPoint","coordi
20190705T105031_20190705T105032_T31SBD	05/07/2019	NDVI	0.452876092256922	{"type":"MultiPoint","coordi
20190710T105039_20190710T105335_T30SYJ	10/07/2019	NDVI	0.583304964556850	{"type":"MultiPoint","coordi
20190710T105039_20190710T105335_T31SBD	10/07/2019	NDVI	0.583689039392762	{"type":"MultiPoint","coordi
20190715T105031_20190715T105159_T30SYJ	15/07/2019	NDVI	0.600557824542950	{"type":"MultiPoint","coordi
20190715T105031_20190715T105159_T31SBD	15/07/2019	NDVI	0.602294557139924	{"type":"MultiPoint","coordi
20190720T105039_20190720T105755_T30SYJ	20/07/2019	NDVI	0.536514946381624	{"type":"MultiPoint","coordi
20190720T105039_20190720T105755_T31SBD	20/07/2019	NDVI	0.536323870668202	{"type":"MultiPoint","coordi
20190725T105031_20190725T105702_T30SYJ	25/07/2019	NDVI	0.610419653645327	{"type":"MultiPoint","coordi
20190725T105031_20190725T105702_T31SBD	25/07/2019	NDVI	0.610045629191805	{"type":"MultiPoint","coordi
20190730T105039_20190730T105502_T30SYJ	30/07/2019	NDVI	0.591587389514221	{"type":"MultiPoint","coordi
20190730T105039_20190730T105502_T31SBD	30/07/2019	NDVI	0.590577355892642	{"type":"MultiPoint","coordi
20190804T105031_20190804T105722_T30SYJ	04/08/2019	NDVI	0.618245810661547	{"type":"MultiPoint","coordi
20190804T105031_20190804T105722_T31SBD	04/08/2019	NDVI	0.620590970318855	{"type":"MultiPoint","coordi
20190809T105039_20190809T105327_T30SYJ	09/08/2019	NDVI	0.639941970369819	{"type":"MultiPoint","coordi
20190809T105039_20190809T105327_T31SBD	09/08/2019	NDVI	0.640188064446234	{"type":"MultiPoint","coordi
20190814T105031_20190814T105153_T30SYJ	14/08/2019	NDVI	0.630615261740383	{"type":"MultiPoint","coordi
20190814T105031_20190814T105153_T31SBD	14/08/2019	NDVI	0.633041530137467	{"type":"MultiPoint","coordi
20190819T105029_20190819T105901_T30SYJ	19/08/2019	NDVI	0.572317685870014	{"type":"MultiPoint","coordi
20190819T105029_20190819T105901_T31SBD	19/08/2019	NDVI	0.573358575270092	{"type":"MultiPoint","coordi
20190824T105031_20190824T105344_T30SYJ	24/08/2019	NDVI	0.636264748959982	{"type":"MultiPoint","coordi
20190824T105031_20190824T105344_T31SBD	24/08/2019	NDVI	0.639168042450020	{"type":"MultiPoint","coordi
20190829T105029_20190829T105844_T30SYJ	29/08/2019	NDVI	0.573069580382707	{"type":"MultiPoint","coordi
20190829T105029_20190829T105844_T31SBD	29/08/2019	NDVI	0.576044537321594	{"type":"MultiPoint","coordi

system:index	CLASE	ASIGH	EVI_MES1	EVI_MES2	EVI_MES3	EVI_MES4	EVI_MESS	EVSAMPLE	NDVL_MES1	NDVL_MES2	NDVL_MES3	NDVL_MES4	NDVL_MESS	SAVL_MES1	SAVL_MES2	SAVL_MES3	SAVL_MES4	SAVL_MESS	TRSAMPLE	id	.geo
0	0.146900367	0.439528071	0.485888506	0.352247752	0.210365431	0.287963357	0.614583532	0.765339621	0.597460189	0.401586160	0.145187972	0.392544877	0.450423108	0.329373204	0.225000163	0	1	{type: "Polyg			
1	0.241462534	0.436267543	0.556749267	0.4047752	0.171204940	0.369981441	0.65015332	0.805185372	0.707644581	0.294965878	0.205685039	0.378919984	0.506019801	0.443371009	0.177310049	0	221	{type: "Polyg			
2	0.518603650	0.675566915	0.682850499	0.448603343	0.225563487	99.811061757	0.792581203	0.877793298	0.709752928	0.357207923	0.488181668	0.574716752	0.604286866	0.430493989	0.230040420	0	4	{type: "Polyg			
3	0.103472328	0.427117089	0.627609944	0.473481384	0.195024014	99.225139492	0.677912682	0.866536887	0.674320827	0.391816570	0.107805556	0.395552563	0.562634941	0.444611687	0.202026279	0	25	{type: "Polyg			
4	0.113035110	0.420110898	0.609196984	0.489673681	0.194775352	99.248547523	0.665429603	0.855515105	0.672778030	0.381510327	0.114373633	0.390034000	0.551613324	0.443300400	0.200924049	0	26	{type: "Polyg			
5	0.111292099	0.391864281	0.591517649	0.428510694	0.132926355	99.194986467	0.656890339	0.841073906	0.635136006	0.181871398	0.107553849	0.363890479	0.534427053	0.406804938	0.122308166	0	30	{type: "Polyg			
6	0.346432488	0.53748470	0.586604449	0.40322767	0.33703662	99.075504962	0.698268489	0.798419904	0.644856082	0.572919077	0.326953909	0.471053462	0.522389902	0.391194366	0.338477729	0	51	{type: "Polyg			
7	0.379561426	0.596224474	0.637659452	0.48226267	0.174979194	99.695187339	0.745861633	0.847423794	0.698872774	0.261558420	0.370426063	0.516143697	0.594720956	0.453480953	0.180161132	0	53	{type: "Polyg			
8	0.182168476	0.479133164	0.631085371	0.43860283	0.330605479	99.257766556	0.708699475	0.870284746	0.687147383	0.588977479	0.158049308	0.434504239	0.567438653	0.426769697	0.343794604	0	62	{type: "Polyg			
9	0.361369531	0.570924607	0.598116627	0.484263302	0.202544970	99.644242303	0.728018977	0.830981174	0.696809817	0.276127360	0.357554368	0.497363956	0.540233834	0.455873347	0.175228505	0	76	{type: "Polyg			
0000000000	0.175007494	0.545833761	0.656510995	0.504533272	0.181165336	99.362584816	0.721173824	0.872727690	0.678601910	0.317804248	0.178305629	0.478239931	0.584466902	0.446826329	0.181887856	0	95	{type: "Polyg			
0000000000	0.542316034	0.639626115	0.684367072	0.446422823	0.233061704	99.542316034	0.775410699	0.87239867	0.669329130	0.315866475	0.503632624	0.546940040	0.601944328	0.430458506	0.223090505	0	96	{type: "Polyg			
0000000000	0.093506855	0.270950362	0.48606575	0.436933955	0.314501154	99.016322343	0.500665792	0.784932028	0.705400713	0.580795106	0.087963146	0.256648790	0.447635206	0.419215691	0.329490078	0	118	{type: "Polyg			
0000000000	0.12836061	0.457989708	0.608908269	0.44603016	0.327532739	99.276317161	0.692562428	0.860327172	0.687273513	0.580495628	0.129300146	0.419272340	0.552344783	0.42837377	0.340046239	0	119	{type: "Polyg			
0000000000	0.460683875	0.659263232	0.659988262	0.53216852	0.288712800	99.679489780	0.722218341	0.871817114	0.725414126	0.394066033	0.421798408	0.563102721	0.588565718	0.497338538	0.246489848	0	140	{type: "Polyg			
0000000000	0.357686967	0.587621316	0.645767939	0.448929258	0.372110849	99.67789362	0.764224422	0.86954751	0.689893352	0.634257088	0.346340276	0.513401247	0.572080094	0.437908673	0.37938073	0	169	{type: "Polyg			
10	0.273278586	0.573088549	0.615618481	0.473864978	0.376667143	99.334813265	0.75195394	0.871003982	0.717195385	0.635915608	0.216254056	0.505216361	0.557390803	0.454032718	0.383796222	0	186	{type: "Polyg			
11	0.131019749	0.476800905	0.645253873	0.511071163	0.195689754	99.286489785	0.694514042	0.872390805	0.688891607	0.368468786	0.136680702	0.434567619	0.576650301	0.458424020	0.200901905	0	200	{type: "Polyg			
12	0.371233809	0.497290152	0.559290470	0.436795003	0.33956122	99.318605603	0.672659387	0.740856964	0.630682947	0.517526233	0.166841993	0.439429575	0.504149844	0.419952777	0.346420771	0	212	{type: "Polyg			
13	0.436926741	0.603995496	0.587897676	0.390475787	0.186587673	99.705289449	0.725071107	0.792947978	0.645714249	0.296776049	0.414447570	0.516790130	0.526017996	0.385037560	0.191046034	0	218	{type: "Polyg			
14	0.248507981	0.587392371	0.669362362	0.431692865	0.118269190	99.495151445	0.754891364	0.857357544	0.665827872	0.233887844	0.240395057	0.510447879	0.591835710	0.419874170	0.126578807	0	228	{type: "Polyg			
15	0.136308998	0.509388859	0.57123640	0.341382904	0.235943276	99.328473977	0.698935066	0.803408693	0.611831483	0.423291335	0.140369710	0.448816861	0.519901622	0.438547612	0.248476128	0	234	{type: "Polyg			
16	0.317616660	0.550013969	0.609502655	0.385629744	0.232536408	99.622045145	0.737532033	0.833579055	0.640882003	0.436500125	0.309021544	0.483485750	0.546336594	0.378496263	0.250817285	0	236	{type: "Polyg			
17	0.159090260	0.544862133	0.667386700	0.507496869	0.399391274	99.307402179	0.743963950	0.883915376	0.732631807	0.640660603	0.151375187	0.481805903	0.597295170	0.479908813	0.403784315	0	260	{type: "Polyg			
18	0.445375102	0.628693200	0.609855822	0.431587688	0.209004300	99.684364607	0.741038811	0.826744025	0.701663684	0.321116557	0.420070498	0.522397458	0.548161212	0.419212852	0.209004300	0	271	{type: "Polyg			
19	0.526995263	0.598057234	0.614971876	0.447105766	0.340383457	99.769963999	0.721930994	0.795571331	0.670200304	0.573529977	0.491066521	0.514769512	0.545601147	0.426219017	0.348033446	0	275	{type: "Polyg			
0000000000	0.173416301	0.560259318	0.632925184	0.490363695	0.199827778	99.241727229	0.746959746	0.859784447	0.686237445	0.369540433	0.152882726	0.497425110	0.556533803	0.457596462	0.196917834	0	304	{type: "Polyg			
0000000000	0.196774387	0.573222256	0.649678793	0.445129292	0.136922812	99.232892882	0.730421256	0.853539590	0.690526208	0.240330300	0.198175460	0.490079081	0.578232821	0.442418986	0.147125899	0	350	{type: "Polyg			
0000000000	0.194801943	0.528314714	0.595375990	0.395329622	0.178538108	99.422886581	0.708506353	0.819665499	0.654031114	0.302356936	0.197568749	0.462949254	0.536438151	0.389211255	0.185539667	0	364	{type: "Polyg			
0000000000	0.387401649	0.604910851	0.666354476	0.450808279	0.175647323	99.718289800	0.763156709	0.856568984	0.682189407	0.27587982	0.378880462	0.521660402	0.590053030	0.435795456	0.176163489	0	365	{type: "Polyg			
0000000000	0.090776690	0.542251026	0.625451079	0.441395053	0.340539171	99.203481004	0.685375682	0.856316483	0.720128490	0.611299094	0.090903200	0.412147199	0.538051603	0.427142277	0.351254258	0	368	{type: "Polyg			
0000000000	0.112564927	0.292184015	0.546826882	0.426320788	0.341311630	99.198420541	0.596094039	0.840577187	0.714913912	0.636058841	0.102577299	0.273562530	0.502608024	0.415767130	0.353478481	0	369	{type: "Polyg			
20	0.405034128	0.617552857	0.647655010	0.432405116	0.315945265	99.711901844	0.759662152	0.846493957	0.681154422	0.460290170	0.392819895	0.530284111	0.575958900	0.416536600	0.305786434	0	372	{type: "Polyg			
21	0.512020432	0.599470138	0.629485404	0.430336660	0.154477949	99.756745973	0.752882688	0.824512227	0.681180099	0.224613001	0.478317086	0.519387513	0.559686714	0.435692069	0.152090694	0	376	{type: "Polyg			
22	0.484091713	0.620919726	0.668644165	0.453006458	0.149115284	99.773407222	0.763177083	0.842413362	0.675752282	0.223960255	0.460446647	0.538112066	0.587821040	0.434760539	0.145587757	0	378	{type: "Polyg			
23	0.337541561	0.588706596	0.660294413	0.440395920	0.166445078	99.649852176	0.747882306	0.853314595	0.671273091	0.266335687	0.330367030	0.507391207	0.587411638	0.428364999	0.171608872	0	381	{type: "Polyg			
24	0.164544235	0.421730183	0.634526107	0.431621078	0.165110733	99.218320500	0.680943109	0.856994344	0.644352087	0.224613001	0.148259093	0.387985742	0.568422399	0.414122550	0.179036072	0	391	{type: "Polyg			
25	0.411306396	0.598472669	0.624030393	0.425823886	0.245691022	99.726740593	0.764716766	0.850129429	0.688480008	0.427149797	0.391826666	0.520956923	0.561074729	0.416396475	0.252678715	0	393	{type: "Polyg			
26	0.225632138	0.521417465	0.596643413	0.425767202	0.239172146	99.347011209	0.703435627	0.825807768	0.679417679	0.356880898	0.196658243	0.49501094	0.540476967	0.411941938	0.236120556	0	410	{type: "Polyg			
27	0.322894607	0.579235751	0.620685826	0.417620701	0.267261173	99.584534752	0.742320802	0.826516483	0.720128490	0.611299094	0.090903200	0.412147199	0.538051603	0.427142277	0.351254258	0	434	{type: "Polyg			
28	0.351873509	0.511087537	0.549139767	0.392215376	0.201872988	99.453497964	0.612147442	0.682358438	0.												

system:index	Descripción	Métrica	Tipo	Valor
0	Porcentaje total de clasificación	Fiabilidad Global	Métricas Principales	93.33%
1	Acuerdo entre clases independiente	Índice Kappa	Métricas Principales	0.882
2	Precisión del productor para Arroz	Arroz - Productor	Precisión por Clase	98.4%
3	Precisión del usuario para Arroz	Arroz - Usuario	Precisión por Clase	0%
4	Precisión del productor para Cítricos	Cítricos - Productor	Precisión por Clase	91.3%
5	Precisión del usuario para Cítricos	Cítricos - Usuario	Precisión por Clase	0%
6	Precisión del productor para Suelo	Suelo - Productor	Precisión por Clase	80.0%
7	Precisión del usuario para Suelo	Suelo - Usuario	Precisión por Clase	0%
8	Algoritmo de machine learning utilizado	Algoritmo	Clasificador	NAIVEBAYES
9	Precisión del clasificador sobre el conjunto de entrenamiento	Train Accuracy	Clasificador	100.00%
10	Número de índices espectrales utilizados	Total de Características	Características	15
11	Índice espectral utilizado para la clasificación de Arroz	Característica 1	Características	NDVI_MES5
12	Índice espectral utilizado para la clasificación de Cítricos	Característica 2	Características	EVI_MES1
13	Índice espectral utilizado para la clasificación de Suelo	Característica 3	Características	EVI_MES3
14	Índice espectral utilizado para la clasificación de Arroz	Característica 4	Características	EVI_MES2
15	Índice espectral utilizado para la clasificación de Cítricos	Característica 5	Características	SAVI_MES1
16	Índice espectral utilizado para la clasificación de Suelo	Característica 6	Características	SAVI_MES2
17	Índice espectral utilizado para la clasificación de Arroz	Característica 7	Características	SAVI_MES3
18	Índice espectral utilizado para la clasificación de Cítricos	Característica 8	Características	SAVI_MES4
19	Índice espectral utilizado para la clasificación de Suelo	Característica 9	Características	EVI_MES5
20	Índice espectral utilizado para la clasificación de Arroz	Característica 10	Características	EVI_MES4
21	Índice espectral utilizado para la clasificación de Cítricos	Característica 11	Características	NDVI_MES3
22	Índice espectral utilizado para la clasificación de Suelo	Característica 12	Características	SAVI_MES5
23	Índice espectral utilizado para la clasificación de Arroz	Característica 13	Características	NDVI_MES4
24	Índice espectral utilizado para la clasificación de Cítricos	Característica 14	Características	NDVI_MES1
25	Índice espectral utilizado para la clasificación de Suelo	Característica 15	Características	NDVI_MES2
26	Número total de parcelas clasificadas	Total de Muestras	Muestras	951
27	Número de parcelas utilizadas para la evaluación	Muestras de Evaluación	Muestras	105

system:in:Algoritmo_Características_Utilizadas_Corrector/Fecha_Evaluacion_Fiabilidad_Global_Fiabilidad_Indice_Kai/Interpreta/Num_Arb/Num_Care_Periodo_E_Porcentaje/Precision_Precision_Precision_Precision_Precision_Precision_Precision_Precision_Precision_Precision_Satellite_geo
0 naivebayes/NDVI_MES5/EVI_MES1/EVI_MES3/EVI_MES2/SAVI_MES1/SAVI_MES2/SAVI_MES3/SAVI_MES4/EVI_MES5/EVI_MES4/NDVI_MES3/SAVI_MES5/NDVI_MES4/NDVI_MES1/NDVI_MES2
31/08/2025 0.9333333333333333 93 0.8823246 Muy_bueno/A 15 2017-06-2 85 [0.9838709677419355 [0.913043 [0.8 [0.9838709677419355 0.84 0.8 Sentinel-2 ("vpe", "w