

Facultad
de
Ciencias

**Diseño de un algoritmo de análisis de imagen
para el estudio de la erosión en zonas
afectadas por precipitaciones extremas**

(Design of an image analysis algorithm for the study of erosion in
areas affected by extreme precipitation)

Trabajo de Fin de Grado
para acceder al

GRADO EN FÍSICA

Autor: Marco-Tristán Hernández van Polen

Director: Alberto González Díez

Fecha: 13/06/2025

Quisiera expresar mi profundo agradecimiento a mi familia, a mis hermanos Sa y Moi y a mis padres, por su esfuerzo y apoyo incondicional, ya que sin ellos no habría sido posible llegar a la realización de este trabajo. A mis amigos, Raúl, Roberto, Sara, Natalia, Óscar, Nico y Gus, por su apoyo y amistad durante estos años que han sido fundamentales para hacer este largo recorrido más ameno. A mi director, Alberto, por su orientación, tiempo y dedicación a lo largo de este proceso de investigación y por haberme dado la oportunidad de entrar en este campo de conocimiento. Sin él este trabajo no habría sido posible. Además, a Esri por haber desarrollado ArcGIS PRO y al proyecto Sentinel, que han sido herramientas clave para poder realizar este trabajo. Y por supuesto a Simba y Roma.



Resumen

En este Trabajo de Fin de Grado se pretende desarrollar un algoritmo que obtenga de forma simultánea diferentes índices de imagen con los que tratar zonas afectadas por lluvias extremas. El algoritmo se ha desarrollado en Python para aplicarlo en un Sistema de Información Geográfica, ArcGIS PRO. Mediante el mismo se han obtenido 8 índices de imagen con los que se ha analizado situaciones anteriores y posteriores a un evento de lluvias extremas. El evento de precipitaciones extremas analizado ocurrió el 29 de abril de 2024 en Rio Grande del Sur, Brasil. La metodología empleada ha permitido calcular distintos índices de imagen así como aplicar diferentes análisis estadísticos para conocer el grado de dependencia entre los índices y el fenómeno natural. Los resultados muestran que hay una serie de índices de imagen y variables como la geología, la vegetación, la altimetría, la orientación o la inclinación que están bastante bien relacionadas con los deslizamientos de tierra. Los índices más significativos son NDMI, NDVI, MSAVI, GNDVI y NDSI. Los análisis previos y posteriores a las lluvias muestran resultados coherentes con la aparición de deslizamientos. Además, desde un punto de vista de análisis de imagen es mucho más significativo la diferencia entre los índices (pre-post) para la identificación de deslizamientos que los análisis individuales.

Palabras clave: deslizamientos de tierra, teledetección, índice de imagen, Sentinel-2, precipitaciones extremas.



Abstract

In this Bachelor's Final Project, the aim is to develop an algorithm capable of simultaneously obtaining different image indices to analyze areas affected by extreme rainfall. The algorithm has been developed in Python for application in a Geographic Information System, ArcGIS PRO. Using this method, eight image indices have been obtained to analyze pre- and post- event situations related to extreme rainfall. The analyzed extreme precipitation event occurred on April 29, 2024, in Rio Grande do Sul, Brazil. The methodology employed has allowed for the calculation of various image indices as well as the application of different statistical analyses to determine the degree of dependence between the indices and the natural phenomenon. The results show that several image indices and variables such as geology, vegetation, elevation, orientation, and slope are strongly related to landslides. The most significant indices are NDMI, NDVI, MSAVI, GNDVI, and NDSI. Pre- and post-rainfall analyses provide results consistent with the occurrence of landslides. Moreover, from an image analysis perspective, the difference between indices (pre-post) is much more significant for landslide identification than individual analyses.

Keywords: landslides, remote sensing, image index, Sentinel-2, extreme rainfall.



Índice

1	Introducción	1
1.1	Estado del arte	2
1.2	Área de estudio	3
1.3	Programa Copernicus	6
1.4	Sentinel-2	7
1.5	ALOS	9
1.6	Concrección de la hipótesis de trabajo	9
2	Desarrollo experimental	11
2.1	Algoritmo	11
2.2	Descarga de imágenes	12
2.3	Índices de imagen	14
2.4	Métodos estadísticos	16
2.4.1	Análisis de Componentes Principales (PCA)	16
2.4.2	Regresión Lineal Ordinaria (OLS)	19
3	Resultados	22
3.1	Algoritmo	22
3.2	Geodatabase de trabajo	22
3.3	Bandas de trabajo	26
3.4	Índices de imagen	28
3.5	Análisis PCA	31
3.6	Análisis OLS	32

4	Discusión	33
5	Conclusiones	37
	Referencias	42
	Anexo	43
5.1	Imágenes	43
5.2	Tablas	44
5.3	Algoritmo	44
5.3.1	Código para descargar el DEM	44
5.3.2	Código para cambiar de nombre a los archivos y reescalar las bandas a 10m	45
5.3.3	Código para calcular los índices de imagen	46
5.3.4	Código para almacenar valores de los índices en el mapa	48
5.3.5	Código para realizar OLS	49
5.3.6	Código para realizar PCA	50
5.4	Análisis PCA	51
5.5	Análisis OLS	55

1

Introducción

Durante los últimos años, el cambio climático ha incrementado significativamente la cantidad de fenómenos naturales extremos que se producen en el planeta, como el aumento en la frecuencia y la magnitud de las lluvias torrenciales [1]. Estas precipitaciones son muy impredecibles y pueden tener consecuencias graves para la población. Un ejemplo cercano es la reciente DANA de octubre de 2024 en Valencia, la cual dejó 225 muertos, además de ocasionar graves daños en la infraestructura de las localidades afectadas [2]. Estas lluvias también pueden causar una rápida erosión del terreno, provocando deslizamientos de tierra [3]. Por esta razón, es crucial estudiar estos fenómenos para prevenir daños y desarrollar estrategias de mitigación.

En este contexto, la teledetección constituye una herramienta fundamental en el estudio de fenómenos ambientales como los ocasionados por riesgos naturales. Esta técnica, no solo engloba los procesos de obtención de imágenes mediante satélites, aviones o drones sino también su posterior tratamiento y análisis, involucrando muchos ámbitos de la Física. La teledetección, debido a su naturaleza, es una herramienta muy dependiente del desarrollo tecnológico y por ello, en los últimos años ha experimentado un gran crecimiento, progresando tanto en la cantidad como en la variedad y calidad de la información proporcionada en un rango amplio de campos científicos, entre los que se encuentra la Física de la Tierra [4, cap.1]. Rama de las Ciencias Físicas que se centra en estudiar procesos físicos que ocurren en nuestro planeta incluyendo disciplinas como la geofísica; la geodinámica, etc; y que analiza fenómenos físicos internos de la tierra (sismicidad, volcanismo, campos potenciales) o aquellos que se desarrollan sobre la superficie del planeta (externos) como la meteorología y climatología enfocados al estudio de la atmósfera; y/o la oceanografía [5]. Por tanto, el tratamiento o procesamiento de imágenes engloba un conjunto de técnicas y métodos que permiten mejorar, analizar o extraer información de imágenes digitales mediante el empleo de una serie de técnicas (también conocido como Teledetección según la International Society of Remote Sensing, ISPRS) que se aplican en esta rama del conocimiento o en otras como la medicina, la astronomía o también la Física de la Tierra [6].

En particular, existe una relación estrecha entre la Física de la Tierra y el procesamiento de imágenes dado que aportan información clave para el estudio de fenómenos físicos como los incluidos dentro de los efectos de cambios ambientales y climáticos, las actividades sísmicas o la erosión del

terreno manifestada por movimientos o deslizamientos de tierra, entre otros [7].

Con el objetivo de optimizar el tratamiento de imágenes, este Trabajo de Fin de Grado tiene como propósito desarrollar un algoritmo específico para la detección y su posterior análisis de deslizamientos de tierra causados por precipitaciones extremas. El objetivo de este estudio es demostrar que los procesos de erosión, como los deslizamientos, pueden ser investigados mediante técnicas de tratamiento de imágenes con el fin de obtener información sobre qué tipo de combinación de imágenes sensibles a la identificación de estos procesos. Para ello, se desarrollará un algoritmo en Python que facilite la obtención de índices de imagen, su ejecución dentro de un Sistema de Información Geográfica (SIG) y su tratamiento estadístico que permitirá la detección y análisis de los deslizamientos causados por dichas precipitaciones [8].

1.1. Estado del arte

Un trabajo como este exige el manejo de una serie de herramientas que no son muy familiares en el área de la Física, como los Sistemas de Información Geográfica (SIG) o la teledetección. Dichos entornos emplean datos geospaciales provenientes de sensores satelitales, cuyos principales suministradores de datos son la NASA, ESA, entre otros. Para este trabajo se ha empleado el software ArcGIS Pro (Esri) como Sistema de Información Geográfica (Figura 1.1). Un Sistema de Información Geográfica es una herramienta que permite extraer, almacenar, analizar y visualizar datos geospaciales de un entorno de trabajo. Una de las principales ventajas que tienen este tipo de programas es que permiten integrar datos de múltiples fuentes, realizar análisis avanzados y visualizar la información tras un proceso de forma detallada. Esto hace que los SIG sean una herramienta ideal para el estudio de fenómenos físicos relacionados con procesos de erosión como los deslizamientos de tierra.

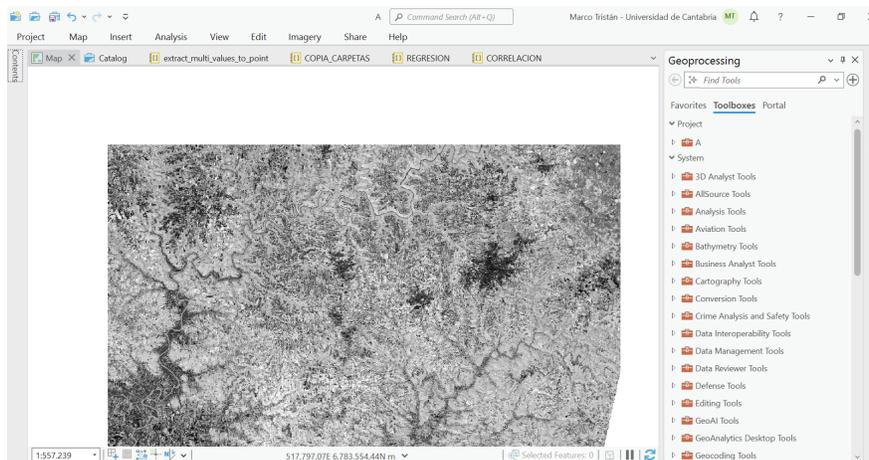


Figura 1.1. Entorno de trabajo en ArcGIS Pro.

En particular, ArcGIS Pro ofrece un conjunto sólido de herramientas para la visualización, análisis y gestión en superficies de n dimensiones. Además, es compatible con Python, lo que permite ejecutar scripts de Python directamente en ArcGIS Pro y desarrollar código que permita realizar análisis de imágenes enfocados en el estudio de deslizamientos de tierra. Sin embargo, ArcGIS PRO

no incluye todas las librerías Python. No obstante, incluye la librería ArcPy, que permite realizar análisis espacial, administración y conversión de datos, además de ArcGIS API, que integra muchas bibliotecas de Python como Numpy o Scikit-Learn [9]. Dado que ArcGIS Pro no incluye todas las librerías de Python, se emplea el entorno de edición de Visual Studio Code (VS Code), que es un editor de código fuente gratuito y de código abierto desarrollado por Microsoft, para completar las carencias del SIG (Figura 1.2).

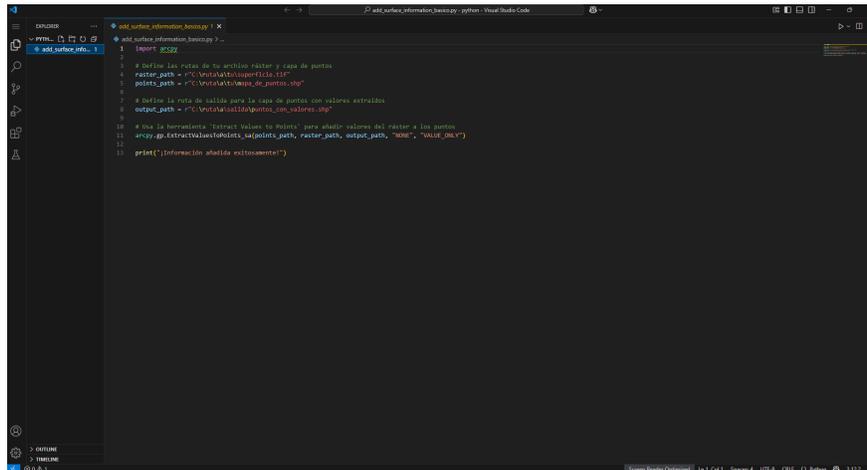


Figura 1.2. Entorno de trabajo en Visual Studio Code.

La versión de Python empleada en este trabajo es la 3.12.2 y los códigos desarrollados se han basado en otros aportados en la literatura (GitHub), en ejemplos proporcionados por Esri y la comunidad de ArcGIS Pro además de realizar consultas a distintas inteligencias artificiales generativas (Copilot, ChatGPT...), teniendo así referencias respecto a la programación elegida.

1.2. Área de estudio

La zona de estudio seleccionada para este trabajo es el estado de Río Grande del Sur, en Brasil. El área analizada se encuentra delimitada entre las coordenadas 52,05°W y 51,20°W de longitud, y entre 30,15°S y 28,50°S de latitud, tal como se observa en la Figura 1.3.

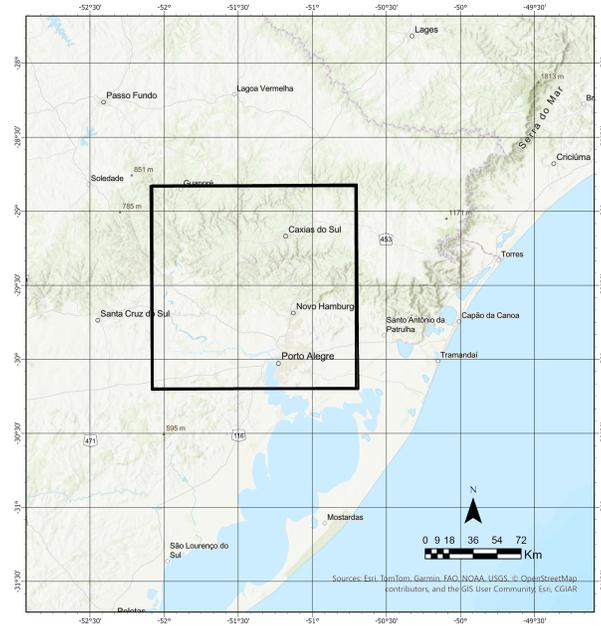


Figura 1.3. Imagen del área geográfica de estudio. Dentro del cuadrado negro se encuentra la zona de estudio.

En esa zona, tras unas lluvias extremas generadas el 29 de abril de 2024, se desarrollaron decenas de deslizamientos, como ejemplo de uno de estos deslizamientos se muestra la Figura 1.4.



Figura 1.4. Imagen del 10 de mayo de 2024 que muestra un deslizamiento de tierra cerca de la carretera Mundo dos Vinhos, en Caxias do Sul, estado de Rio Grande do Sul, Brasil.[10]

La NASA ya se ha fijado en este área de estudio para validar también algunas tecnologías desarrolladas dentro del ámbito de los riesgos naturales. Existen imágenes que permiten ilustrar la situación de la zona poco tiempo antes de las lluvias y después de las mismas, así como un mapeo de deslizamientos generados tras las precipitaciones ocurridas que se presentará más adelante. La imagen de estos deslizamientos se va a presentar como *groundtruth*, es decir, como la referencia del terreno real que servirá para verificar los análisis que posteriormente se comentarán.

El estado de Río Grande del Sur se caracteriza por su diversidad de paisajes, que incluyen llanuras, sierras y valles. Desde un punto de vista climático, la región tiene un clima subtropical húmedo

(Cfa), con estaciones bien definidas y una alta incidencia de lluvias en ciertas épocas del año. Se caracteriza por una temperatura media en torno a 18,6 °C; abundantes precipitaciones a lo largo del año, con un promedio de 1304 mm anuales, tal y como se observa en el climograma de la Figura 1.5 [11].

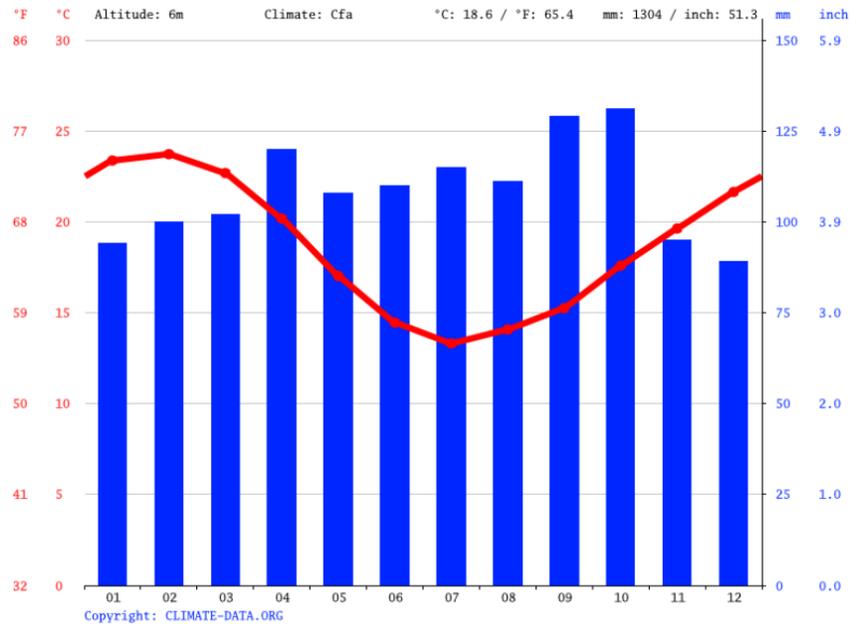


Figura 1.5. Climograma de la zona de estudio, Rio Grande del Sur, Brasil [11].

Cabe destacar, que esta zona es una de las áreas agrícolas más productivas de Brasil. El territorio destaca por sus cultivos de arroz, soja y maíz, además por ser una fuente importante de pastos para la ganadería y un soporte de complejos industriales. [12] [13]

Desde un punto de vista geológico la zona está formada por materiales Paleozoicos y Mesozoicos con una cobertura de materiales cuaternarios, fundamentalmente mantos de alteración y depósitos de movimientos en masa, junto con algunos depósitos fluviales. Desde un punto de vista de la vegetación la zona está dominada por áreas forestales de carácter subtropical, como las que se presentan en la Figura 1.6.



Figura 1.6. Vegetación típica de la zona de estudio, Rio Grande del Sur, Brasil [13].

La combinación de las características climáticas, geológicas y la intensa deforestación propicia que Rio Grande del Sur sea una zona altamente propensa a los deslizamientos de tierra.

1.3. Programa Copernicus

Para realizar este estudio se han empleado imágenes tanto antes como después de las lluvias ocasionadas el 29 de abril de 2024. Las imágenes se han localizado a través del área geográfica analizada. Dentro de las distintas fuentes de imágenes que se han podido emplear, se ha optado por usar las imágenes proporcionadas por el satélite Sentinel-2, que forma parte del programa Copernicus [14]. Este programa, dirigido y coordinado por la Unión Europea, tiene como principal objetivo la observación y el análisis del planeta Tierra para el beneficio de todos los ciudadanos europeos. Su implementación se realiza en colaboración con los Estados miembros de la Unión Europea, la Agencia Espacial Europea (ESA), la Organización Europea para la Explotación de Satélites Meteorológicos (EUMETSAT), el Centro Europeo de Previsiones Meteorológicas a Medio Plazo (ECMWF), agencias de la UE, Mercator Océan, la Agencia Europea de Medio Ambiente (EEA) y el Centro Común de Investigación (JRC).

Los datos aportados por Copernicus son de acceso abierto y gratuitos para todos los usuarios, siendo esta una de las razones principales para trabajar con un satélite enmarcado en este programa. Para cumplir con su objetivo de proporcionar datos globales en tiempo real, el programa Copernicus cuenta con una flota de satélites Sentinel que aportan distintas funcionalidades (Figura 1.7). Cabe destacar que solo los países miembros de la Unión Europea y sus respectivas agencias de inteligencia, ministerios de defensa y seguridad tienen acceso en tiempo real a las imágenes. Estos satélites están diseñados para satisfacer las necesidades de los servicios Copernicus y sus usuarios. Desde que se llevó a cabo el primer lanzamiento en 2014 hasta 2030 la UE pretende emplazar 20 satélites de esta constelación [15]. Es importante destacar que los servicios de Copernicus procesan y analizan grandes volúmenes de datos procedentes de los satélites, además de sistemas *in situ* para transformarlos en información útil y accesible. Para facilitar la búsqueda y comparación de los mismos se organizan en una serie de categorías: vigilancia atmosférica, marina, terrestre, de cambio climático, de seguridad y de emergencias.



Figura 1.7. Ilustración de los satélites del programa Copernicus [16].

1.4. Sentinel-2

Como se ha mencionado anteriormente, en este trabajo se han empleado imágenes obtenidas del satélite Sentinel-2. La Figura 1.8 muestra un detalle de esta plataforma orbitando sobre la superficie terrestre, mientras que en el Anexo 5.1 se muestra una imagen de los componentes del mismo.



Figura 1.8. Imagen artística del satélite Sentinel-2 [17].

El lanzamiento del Sentinel-2A se llevó a cabo el 23 de junio de 2015 [18], y el del Sentinel-2B el 7 de marzo de 2017 [19]. En la Tabla 5.1, en el Anexo 5.2, se muestra un resumen de los satélites Sentinel con sus características más importantes.

La combinación de imágenes de alta resolución espacial y espectral, y su continua adquisición en un rango muy amplio del espacio electromagnético (elevada capacidad espectral), un campo de visión amplio que abarca 290 kilómetros de ancho y los revisitados de la zona de estudio frecuentes, proporcionan muchísimas ventajas para el estudio de fenómenos terrestres. Para lograr que la resolución temporal sea la más baja posible, la misión Sentinel-2 está compuesta por dos satélites idénticos que se encuentran en oposición a 180 grados y comparten la misma órbita polar heliosíncrona a una altitud de 786 km (Figura 1.9) [20], logrando de este modo una cobertura y recolección de datos óptimos.

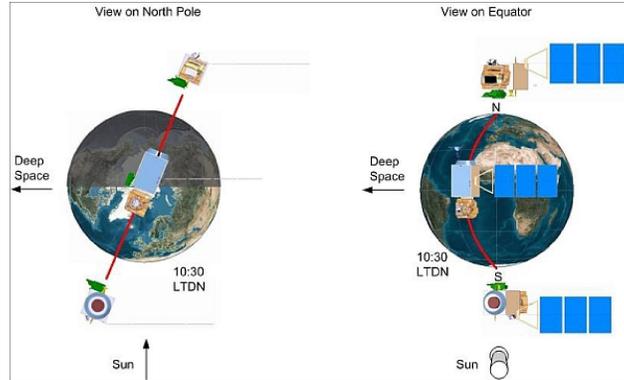


Figura 1.9. Constelación de satélites Sentinel-2 en órbita [17].

Los Sentinel-2 están equipados con una innovadora cámara multispectral de alta resolución, que incluye 13 bandas como se muestra en la Figura 1.10 [21]. Estas bandas proporcionan información detallada sobre la superficie terrestre y la vegetación con diferentes resoluciones espaciales de 10, 20 y 60 metros en función de la banda (Figura 1.10). Este formato lo hace ideal para el estudio de cambios en el terreno como los deslizamientos de tierra. Además, el satélite tiene una resolución temporal de cinco días, es decir, los satélites cubren toda la superficie terrestre con un periodo de cinco días, lo que permite obtener imágenes de la zona de estudio antes y después de un evento de lluvias como el analizado. Por otro lado el sensor empleado, el Multi Spectral Instrument, tiene una resolución radiométrica de 12 bits, lo que permite adquirir la imagen en un rango de 0 a 4095 valores, que en la imagen se traduce a 4096 tonos de gris [22]. Esta mayor resolución radiométrica permite mayor sensibilidad para captar diferencias de reflectancia proporcionando imágenes de mayor calidad. Además, desde un punto de vista técnico el sensor multiplica la reflectancia por 10.000, lo que permite incrementar notablemente las diferencias de tono entre clases [23]. Sin embargo, esta circunstancia obliga a corregir la señal para ser comparativa a la captada por otros sensores con una resolución radiométrica menor. Por ejemplo, en el caso de que se quiera comparar la resolución radiométrica de la de Sentinel con la de Landsat, se puede convertir la señal utilizando la siguiente expresión:

$$L = \left(\frac{S}{4095} \right) \times 255$$

donde L es Landsat y S Sentinel. Además, se debe corregir el factor de conversión como

$$L = \left(\frac{S}{10000} \right) \times 255$$

obteniendo así imágenes de resolución radiométrica comparables a la de Landsat.

	SENTINEL 2	
	Longitud de onda (μm)	Resolución (m)
Banda 1 - Aerosol	0,43 - 0,45	60
Banda 2 - Blue	0,45 - 0,52	10
Banda 3 - Green	0,54 - 0,57	10
Banda 4 - Red	0,65 - 0,68	10
Banda 5 - Red edge 1	0,69 - 0,71	20
Banda 6 - Red edge 2	0,73 - 0,74	20
Banda 7 - Red edge 3	0,77 - 0,79	20
Banda 8 - Near Infrared (NIR) 1	0,78 - 0,90	10
Banda 8A - Near Infrared (NIR) 2	0,85 - 0,87	20
Banda 9 - Water vapour	0,93 - 0,95	60
Banda 10 - Cirrus	1,36 - 1,39	60
Banda 11 - SWIR 1	1,56 - 1,65	20
Banda 12 - SWIR 2	2,10 - 2,28	20

Figura 1.10. Bandas espectrales del satélite Sentinel-2 [24].

1.5. ALOS

ALOS o *Advanced Land Observing Satellite* es una plataforma de teledetección desarrollada por la Agencia Japonesa de Exploración Aeroespacial (JAXA) cuyas imágenes se han adquirido entre 2006 y 2011 [25]. La plataforma ALOS, también conocida como DAICHI, lleva a bordo tres sensores: el PRISM que permite capturar imágenes pancrómicas; el Radar de Apertura Sintética (SAR) PALSAR y el radiómetro AVNIR-2. Los instrumentos instalados dentro de esta plataforma permiten obtener productos multitemporales, muy útiles para trabajar en zonas de baja cobertura satelital como en los polos, América del Sur, zonas del Himalaya, etc. ALOS aporta un portal (<https://search.asf.alaska.edu/#/>) donde se puede seleccionar Modelos Digitales de Superficie, de la superficie terrestre con una resolución espacial de 30 metros o 1 arcosegundo que permite recoger escenas sobre el terreno con recubrimientos de 35x35 Km cada 45 días. Además, el sensor PRISM cuenta con una resolución radiométrica de 8 bits.[26][27]

1.6. Concrección de la hipótesis de trabajo

Es posible el diseño de un algoritmo para el tratamiento de imágenes que permita extraer simultáneamente diversos índices de imagen con los que analizar riesgos naturales como los generados por problemas de erosión producidos por precipitaciones extremas. Dentro de este contexto, los índices de imagen permitirán analizar la capacidad de detección de los cambios en la superficie terrestre generados por fenómenos erosivos.

Estas hipótesis conllevan los siguientes objetivos:

- Construir una serie de algoritmos que permitan concatenar la extracción de índices de imagen así como su incorporación a Sistemas de Información Geográfica y captura de elementos en otras geodatabases presentes en modo ráster.

- Creación de una geodatabase con la información ambiental relevante incluyendo imágenes del Sentinel-2 posteriores y anteriores al evento de precipitaciones extremas.
- Cálculo de diversos índices de imagen a partir de las imágenes de después y antes del evento.
- Evaluación mediante diversos métodos estadísticos de la importancia de estos índices de imagen para la identificación de áreas erosionadas por deslizamientos.
- Análisis del cambio del índice de imagen en la identificación de áreas erosionadas por deslizamientos.

2

Desarrollo experimental

En esta sección, se explica el desarrollo seguido en este trabajo desde la creación del algoritmo necesario para realizar todo el análisis hasta los análisis estadísticos. En primer lugar, se desarrolló un algoritmo para realizar el análisis de este trabajo, después se descargaron las imágenes obtenidas por Sentinel-2 de la zona de estudio. Más tarde, se explican los índices de imagen que se han precisado y finaliza desarrollando los análisis estadísticos que se han llevado a cabo.

2.1. Algoritmo

En este trabajo se ha diseñado un algoritmo de análisis de imagen con el fin de estudiar deslizamientos de tierra ocurridos con anterioridad y posterioridad al evento de precipitaciones extremas. Aunque se trata también de un resultado de este trabajo, desde un punto de vista metodológico se puede indicar que el código completo (ver Anexo 5.3) permite la obtención concatenada de los índices de imagen. En primer lugar, se ejecuta el código para descargar el Modelo Digital de Elevaciones (DEM). Una vez descargadas las imágenes de las bandas, se emplea el código para renombrarlas y reescalarlas a 10 metros de resolución. Posteriormente, se aplica el código para calcular los índices de imagen. Dado que el mapa de deslizamientos utilizado en el estudio es un ráster virtual, no es posible editarlo directamente. Por ello, se ha optado por reelaborarlo manualmente, ubicando cada deslizamiento en un punto. A este mismo mapa se le ha añadido una malla de puntos con el objeto de que las poblaciones de deslizamientos y no deslizamientos estén equilibradas desde un punto de vista estadístico. Después, los valores de los índices de imagen de cada punto se almacenan en la tabla de atributos de los mapas, generando tres conjuntos de datos: índices de antes, después y diferencia. Finalmente, se presenta el código para llevar a cabo el análisis mediante Regresión Lineal Ordinaria (OLS) y Análisis de Componentes Principales (PCA). Además, los mapas de vegetación, geología y DEM han sido repixelados a 10 metros mediante la toolbox de ArcGIS. A partir del DEM, utilizando herramientas de la toolbox, se han calculado altimetría, pendiente y orientación. Del mismo modo que con los índices de imagen, se ha utilizado un código similar para almacenar los valores en cada punto y realizar el análisis PCA.

2.2. Descarga de imágenes

Para realizar la descarga de las imágenes del satélite Sentinel-2, se ha utilizado el portal Copernicus Browser de Copernicus Data Space Ecosystem [28]. Esta herramienta permite seleccionar la fecha deseada y el área de estudio, facilitando la descarga de las imágenes de las bandas espectrales necesarias. En la Figura 2.1 se muestra un ejemplo de selección de las imágenes deseadas.

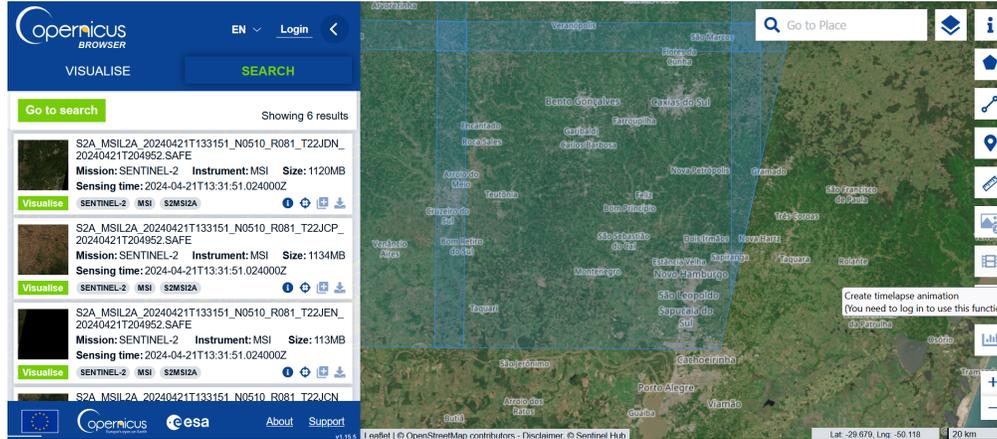


Figura 2.1. Acceso a los datos de trabajo a través de la plataforma Copernicus Browser.

Para garantizar la cobertura de la zona de estudio, se ha seleccionado un área extensa de la zona de interés asegurando que las imágenes incluyeran toda la región deseada. Además, en los parámetros de búsqueda se ha especificado que las imágenes tengan una nubosidad muy baja, inferior al 5%, obteniéndose de esta manera imágenes lo más claras posibles para poder ser analizadas sin la presencia de nubosidad. Se han buscado imágenes correspondientes a efemérides del 21 de abril de 2024. Dicha imagen se ha tomado como la previa a las precipitaciones. De manera similar, se buscó una imagen posterior al 29 de abril de 2024, fecha en la que ocurrieron las lluvias, seleccionándose finalmente la imagen del 6 de mayo como la imagen posterior a las precipitaciones.

Como se observa en la Figura 2.1, cada imagen lleva una nomenclatura que indica información sobre la misma. Por lo general, todas las imágenes del satélite Sentinel-2 llevan la siguiente nomenclatura: MS2_MSILLL_YYYYMMDD. Donde:

- **MS2:** identifica la misión de Sentinel 2, pudiendo encontrar S2A para el Sentinel 2A o S2B para el Sentinel 2B.
- **MSI:** indica que el instrumento de observación fue el MultiSpectralInstrument.
- **LLL:** indica el nivel de procesado, que puede ser L0, L1C, L1B o L2A.
- **YYYYMMDD:** indica la fecha en la que se tomó la imagen (año, mes y día).[24]

En particular, las nomenclaturas de las imágenes utilizadas en este trabajo son:

- Imagen previa:
S2A_MSIL2A_20240421T133151_N0510_R081_T22JDN_20240421T204952.SAFE

- Imagen posterior:
S2B_MSIL2A_20240506T133149_N0510_R081_T22JDN_20240506T154438.SAFE

Empleando las imágenes anteriores como ejemplo descriptivo de su nomenclatura se puede deducir que la imagen previa fue tomada por el Sentinel-2A y la posterior por el Sentinel-2B. En las imágenes Sentinel-2 escogidas se realiza un paso previo, convertir la radiancia espectral a reflectancia en superficie, que es lo que indica el procesado L2A. Este procesado, transforma radiancia a reflectancia aparente en el techo de la atmósfera o TOA¹ para una superficie plana. A continuación, se transforma la reflectancia aparente a real, en otras palabras, se transforma a nivel de superficie o BOA² [24][29]. Cabe destacar, como ya se ha comentado, que previamente al cálculo de los índices de imagen las bandas han sido normalizadas, dividiendo los valores de reflectancia por 10.000, ya que, el Sentinel-2 proporciona imágenes con valores de reflectancia del orden de 10.000 unidades. En este caso, dado que hay bandas de diferentes resoluciones, se ha optado por repixelar todas las bandas a la resolución de 10 metros. Cabe señalar, que se debe tener en cuenta que los cambios de resolución implican ciertas consecuencias. Por un lado, al tener todas las bandas en la misma resolución nos permite trabajar con ellas de forma conjunta para calcular, por ejemplo, los índices de imagen, ya que, en caso contrario no sería posible realizar las operaciones necesarias para calcular los índices. Por otro lado, al cambiar la resolución, no se obtiene una mejora real de la resolución de la imagen, sino que se interpolan los datos de la imagen original, lo que puede llevar a errores en el análisis posterior, por ejemplo, puede afectar a la precisión de ciertos análisis o realizar interpretaciones erróneas de detalles que no se encuentran presentes en la imagen original. Además, dado el largo nombre de los archivos, se van a renombrar de manera que sea más fácil identificarlos, nombrando cada archivo con el nombre de la banda, por ejemplo, el archivo de la banda 11 se llama *T22JDN_20240421T133151_B11_20m.jp2* y se renombrará como *B11_ANTES*.

Al descargar las imágenes, estas vienen doblemente comprimidas en una estructura de carpetas donde se almacenan los metadatos y las bandas necesarias para su procesamiento. A partir de aquí, es cuando ya se pueden procesar en cualquier programa de teledetección, por ejemplo si se emplea el programa SNAP diseñado por la ESA, estas imágenes se pueden utilizar directamente. Sin embargo, para este trabajo como se ha optado por utilizar ArcGIS Pro como la herramienta de visualización y procesado se requiere llevar a cabo unos pasos adicionales. Para acceder a las imágenes en ArcGIS PRO, se utilizó el directorio GRANULE y se trabajó con archivos en formato de compresión JP2, los cuales son difíciles de leer en Sistemas de Información Geográfica como Arcview o Arcmap, excepto en SIG como ArcGIS PRO. La evolución de ArcGIS ha ido condicionada para leer imágenes de satélite y poder procesarlas correctamente. Hay que tener presente que trabajar con este tipo de documentos se debe contar con suficiente almacenamiento, debido que las imágenes tienen un peso considerable, en torno a 1GB cada una comprimidas, debido a la gran resolución y a los metadatos almacenados.

Además, se ha descargado el mapa de vegetación [30], el geológico [31] y el Mapa de Elevaciones Digital, escogiéndose el ALOS DSM. El DEM se ha obtenido a través de la plataforma Google Earth Engine (<https://code.earthengine.google.com/>). Primero se seleccionó la zona de estudio y a continuación, con el código del Anexo 5.3.1 se descargó el DEM [32]. Cabe destacar, que para poder emplear estos mapas se han repixelado a una resolución de 10 metros.

¹Top Of Atmosphere: niveles de reflectancia por encima de la atmósfera.

²Bottom Of Atmosphere: niveles de reflectancia por debajo de la atmósfera.

2.3. Índices de imagen

Para realizar el análisis, se han calculado diferentes índices de imagen que son de utilidad para desarrollar el objetivo de este trabajo. La construcción de un índice de imagen implica la combinación de diferentes bandas, por ejemplo, para calcular el NDVI se combinan las bandas del infrarrojo cercano (NIR) y la banda roja (RED) como se puede ver en la Tabla 2.1. En concreto, para el satélite Sentinel-2, esas bandas son la B08 y la B04 respectivamente. El NDVI tomará valores altos en aquellos lugares en los que exista vegetación vigorosa y valores bajos en las zonas donde no existe vegetación o se encuentre con muy poco vigor. Este índice ayudará a identificar deslizamientos, porque cuando se produce un deslizamiento, se destruye o se pierde la vegetación, dando valores bajos de NDVI. Cuanto mayor sea la diferencia de las reflectividades de la banda NIR y RED, mejor podrá el índice detectar las diferencias de vegetación existentes, ya sea áreas con mayor vigor de la vegetación o en las que la vegetación ha desaparecido. Por otro lado, bajos contrastes del índice indican una vegetación debilitada en su crecimiento o con poca densidad. Un fenómeno que puede provocar este deslizamientos son unas precipitaciones extremas que en su desarrollo erosionan la superficie del terreno y eliminan vegetación causando deslizamientos de tierra [4, cap.7].

En la Tabla 2.1 se muestra un resumen de los índices de imagen calculados a través de las bandas espectrales.

Tabla 2.1. Tabla resumen del cálculo de los índices de imagen empleados en este trabajo.

Índice de imagen	Ecuación general	Ecuación bandas Sentinel-2
NDMI	$(NIR-SWIR1)/(NIR+SWIR1)$	$(B08-B11)/(B08+B11)$
NDSI	$(GREEN-SWIR1)/(GREEN+SWIR1)$	$(B03-B11)/(B3+B11)$
NDVI	$(NIR-RED)/(NIR+RED)$	$(B08-B04)/(B08+B04)$
PRI	$(GREEN-RED)/(GREEN+RED)$	$(B03-B04)/(B03+B04)$
VARI	$(GREEN-RED)/(GREEN+RED-BLUE)$	$(B03-B04)/(B03+B04-B02)$
CMI	$(SWIR1)/(SWIR2)$	$B11/B12$
MSAVI	$((2 \cdot NIR + 1) - \sqrt{(2 \cdot NIR + 1)^2 - 8 \cdot (NIR - RED)})/2$	$((2 \cdot B08 + 1) - \sqrt{(2 \cdot B08 + 1)^2 - 8 \cdot (B08 - B04)})/2$
GNDVI	$(NIR-GREEN)/(GREEN+NIR)$	$(B08-B03)/(B08+B03)$

En detalle los índices de imagen calculados proporcionan la siguiente información:

- **NDMI:** *Normalized Difference Moisture Index* o Índice de Humedad de Diferencia Normalizada es sensible a los niveles de humedad de la vegetación. Se usa para monitorizar la sequía y los niveles de combustible en las áreas vulnerables a los incendios, siendo una gran herramienta agrícola. Usa las bandas NIR y SWIR para crear una relación diseñada para mitigar efectos producidos por la iluminación y la atmósfera. En particular, este índice permite identificar áreas con cambios en el contenido de humedad, lo que es clave en fenómenos como los deslizamientos de tierra. Por ejemplo, valores del NDMI próximos a -1 indican estrés hídrico,

mientras que cercanos a 1 indican inundaciones [33].

- **NDSI:** *Normalized Difference Snow Index* o Índice Diferencial Normalizado de Nieve es una medida de la magnitud relativa de la diferencia de reflectancia entre el rango visible del espectro en el verde y el infrarrojo de onda corta, SWIR. La nieve no solo es muy reflectante en las partes visibles del espectro electromagnético sino también muy absorbente en el infrarrojo cercano (NIR) o en la parte infrarroja de onda corta del espectro [34]. Aunque se emplea para mapear la nieve, también puede ser útil en el estudio de los deslizamientos, ya que, si proporciona un valor bajo significa que se está ante suelo desnudo húmedo, característico tras haberse producido un deslizamiento.
- **NDVI:** *Normalized Difference Vegetation Index* o índice de Vegetación de Diferencia Normalizada es un indicador de la salud de la vegetación. El NDVI ayuda a diferenciar la vegetación de otros tipos de cubierta terrestre y a determinar su estado general. Este hecho, es de gran utilidad a la hora de identificar los deslizamientos. Si se obtienen valores altos del NDVI indica que la vegetación está sana, sin embargo si son bajos y/o negativos el estado de salud de la vegetación será pésimo, por ejemplo, al haber sido arrastrada por la tierra [35] [36].
- **PRI:** *Photochemical Reflectance Index* es un índice que se usa principalmente para evaluar el estado fisiológico de la vegetación, especialmente el estrés fotosintético y la eficiencia en el uso de la luz [37]. Es por ello, que es de gran interés en el estudio de los deslizamientos de tierra, zonas en las que la vegetación ha sido arrancado o afectada, generando estrés fisiológico a las plantas o modificando la eficiencia fotosintética de las mismas. En este caso, en la zona de los deslizamientos habrá valores bajos de este índice.
- **VARI:** *Visible Atmospherically Resistant Index* o Índice de Resistencia Atmosféricamente Visible está diseñado para resaltar la vegetación en la parte visible del espectro, a la vez que mitiga las diferencias en la iluminación y los efectos atmosféricos [38]. Valores altos de este índice indican la presencia de vegetación exuberante mientras que valores bajos indican la presencia de suelo desnudo, propio tras haberse producido deslizamientos.
- **CMI:** *Clay Mineral Index* o índice de minerales arcillosos, está diseñado para resaltar la presencia de minerales en el suelo. La relación de minerales arcillosos es una proporción entre las bandas SWIR1 y SWIR2. Esta relación aprovecha el hecho de que los minerales hídricos, como la arcilla, absorben radiación en la parte de 2,0–2,3 micras del espectro. [39] Cuando se produce un deslizamiento de tierra generalmente se desplaza terreno arcilloso, por eso el índice CMI es útil para la identificación de deslizamientos. Valores altos de este índice, indican alta presencia en arcillas, características de los deslizamientos de tierra superficiales, pudiendo así ayudar a la identificación de deslizamientos.
- **MSAVI:** *Modified Soil-Adjusted Vegetation Index* o índice de Vegetación Ajustado al Suelo Modificado es un índice que amplía los límites de aplicación del NDVI a las áreas con una alta composición de suelo desnudo. Se emplea en zonas donde los valores del NDVI no son válidos debido a que hay solo una pequeña cantidad de vegetación o a la falta de clorofila [40]. De

igual modo que el NDVI, se debe tener en cuenta en el estudio de deslizamientos de tierra. Este índice debería proporcionar valores complementarios al NDVI, donde valores cercanos a 1 indicarán una vegetación vigorosa y valores cercanos a -1 indicarán poca o ninguna vegetación.

- **GNDVI:** *Green Normalized Difference Vegetation Index* o Índice de Vegetación de Diferencia Normalizada Verde se enfoca en el verdor relativo de la vegetación, empleando únicamente el espectro visible. Una caída en GNDVI puede indicar que la vegetación ha sido removida o dañada, como ocurre al producirse un deslizamiento de tierra [41].

El resumen de los índices de imagen y su rango de aplicabilidad se presenta en la Tabla 2.2.

Tabla 2.2. Tabla resumen de los índices de imagen y sus características empleados en este trabajo. Se muestra los índices de vegetación, rango que indica el máximo y mínimo teórico normalizado, cómo se expresa el rango y que información aporta el índice.

Índice de imagen	Rango	Tipo de valores del rango	Información que aporta:
NDMI	[-1,1]	Continuo	Humedad de la vegetación
NDSI	[-1,1]	Continuo	Humedad del suelo
NDVI	[-1,1]	Continuo	Salud de la vegetación
PRI	[-1,1]	Continuo	Estado fisiológico vegetación
VARI	[-1,1]	Continuo	Resalta vegetación en espectro visible
CMI	-	Continuo	Resalta la presencia de arcillas
MSAVI	[-1,1]	Continuo	Amplia NDVI minimizando influencia del suelo
GNDVI	[-1,1]	Continuo	Verdor relativo vegetación

2.4. Métodos estadísticos

Con el objeto de comprobar la hipótesis de trabajo, se han empleado diferentes métodos estadísticos. Se han aplicado dos técnicas estadísticas: el Análisis de Componentes Principales (PCA) y un análisis de regresión lineal, en concreto, la Regresión Lineal Ordinaria (OLS).

2.4.1. Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales o *Principal Component Analysis*, PCA en sus siglas en inglés (que se van a utilizar a lo largo de este trabajo), facilita el tratamiento de sistemas naturales complejos formados por un amplio número de variables transformándolas en un conjunto más pequeño de variables significativas sin perder la parte importante de la información [4, Cap.7].

El Análisis de Componentes Principales aporta una matriz con los autovalores y una matriz con los autovectores. Los autovectores indican las componentes principales del sistema que están definidas por la magnitud de los autovalores, expresados a través de la covarianza entre las diferentes variables analizadas. El funcionamiento del PCA implica la realización de una serie de pasos. Un primer paso es conocer si las variables tienen la misma escala. Para estandarizar las variables se resta la media y se divide por la desviación estándar de cada variable. El siguiente paso es calcular la matriz de covarianza. La covarianza muestra como dos variables cambian juntas. Si las variables ya han sido estandarizadas se puede usar la matriz de correlación en vez de la de covarianza para llevar a cabo

los correspondientes cálculos. Después, se lleva a cabo el cálculo de los autovalores y autovectores de la matriz. Los valores propios o eigenvalues indican la cantidad de varianza explicada por medio de cada componente principal, mientras que los vectores propios o eigenvectors indican la dirección de cada componente principal. A continuación, se seleccionan las componentes principales. Estas son las que explican la mayor parte de la varianza de los datos. Dichos valores se obtienen observando los valores propios, y seleccionando aquellos que sean mayores que 1 o que expliquen un porcentaje significativo de variabilidad. El paso siguiente es la transformación de los datos, donde los datos originales se transforman empleando los vectores propios seleccionados obteniéndose así una nueva componente principal. Por último, se debe interpretar los resultados, las componentes principales se interpretan a partir de las variables originales y se emplean para análisis posteriores, como la visualización de los datos y la construcción de los modelos predictivos. [42][43]

En este trabajo, se toman varias bandas y con ellas se calculan índices de imagen. Tomando cada índice de imagen como una capa independiente, se puede aplicar el PCA para transformar esas capas de datos originales en nuevas componentes independientes, que surgen a partir de combinaciones matemáticas de las originales. A esas componentes, se las denomina componentes principales. Por ejemplo, se podría tener una componente principal (PC1) que aporte información sobre la humedad del suelo, mientras que otra (PC2) proporcione información sobre la vegetación. De esta manera se agrupa la información sobre la zona de estudio en nuevas capas. Posteriormente, se analizan las imágenes visualmente tratando de observar algún patrón que se pudiera detectar en la zona, ya que se conoce que hay deslizamientos. De esta manera las componentes principales cobran más fuerza interpretativa. A partir de los patrones que se hayan encontrado, se podría entrenar un modelo de clasificación autónoma de ocurrencia de deslizamientos.

En resumen, el PCA ayudará a identificar qué índices tienen mayor relevancia y cómo están relacionados con los deslizamientos, permitiendo eliminar redundancias y concentrarse en las variables más significativas.

Con el objetivo de explicar la información que proporciona un análisis de PCA, se va a usar como ejemplo los resultados obtenidos para el análisis PCA antes de las lluvias.

La Tabla 2.3 muestra la matriz de covarianza del análisis PCA. La matriz de covarianza proporciona información sobre cómo varían las variables en relación unas con otras, permitiendo encontrar patrones o redundancias.

Tabla 2.3. Matriz de covarianza correspondiente al análisis PCA de los índices de imagen anteriores a las lluvias.

Capa (índice)	NDMI	NDSI	NDVI	PRI	VARI	CMI	MSAVI	GNDVI
NDMI	1,6679e-02	1,5339e-03	1,5752e-02	3,8942e-03	2,7287e-03	9,8707e-03	1,3682e-02	1,2719e-02
NDSI	1,5339e-03	4,2793e-03	-2,6948e-03	1,0207e-04	7,1294e-05	-2,6772e-03	-1,9054e-03	-2,8010e-03
NDVI	1,5752e-02	-2,6948e-03	1,9582e-02	4,4891e-03	3,1528e-03	1,3458e-02	1,6331e-02	1,6043e-02
PRI	3,8942e-03	1,0207e-04	4,4891e-03	1,5784e-03	1,1131e-03	3,1731e-03	3,8094e-03	3,2127e-03
VARI	2,7287e-03	7,1294e-05	3,1528e-03	1,1131e-03	7,8540e-04	2,2294e-03	2,6763e-03	2,2516e-03
CMI	9,8707e-03	-2,6772e-03	1,3458e-02	3,1731e-03	2,2294e-03	1,2633e-02	1,1275e-02	1,0949e-02
MSAVI	1,3682e-02	-1,9054e-03	1,6331e-02	3,8094e-03	2,6763e-03	1,1275e-02	1,8579e-02	1,3405e-02
GNDVI	1,2719e-02	-2,8010e-03	1,6043e-02	3,2127e-03	2,2516e-03	1,0949e-02	1,3405e-02	1,3554e-02

Por otro lado, se normaliza la matriz de covarianza para obtener la matriz de correlación. La matriz de correlación muestra la relación entre variables sin importar su magnitud, proporcionando valores entre -1 y 1, donde la diagonal principal de la matriz siempre tiene el valor 1, tal y como se observa en la Tabla 2.4. Asimismo, en la Tabla 2.4 se observa que el NDSI y NDMI tienen una correlación baja (0,18) mientras que el GNDVI y el NDMI presentan una correlación alta (0,85).

Tabla 2.4. Matriz de correlación correspondiente a antes de las lluvias.

Capa (índice)	NDMI	NDSI	NDVI	PRI	VARI	CMI	MSAVI	GNDVI
NDMI	1,00000	0,18156	0,87161	0,75898	0,75393	0,68001	0,77722	0,84591
NDSI	0,18156	1,00000	-0,29438	0,03927	0,03889	-0,36412	-0,21369	-0,36778
NDVI	0,87161	-0,29438	1,00000	0,80747	0,80393	0,85565	0,85620	0,98472
PRI	0,75898	0,03927	0,80747	1,00000	0,99977	0,71062	0,70345	0,69459
VARI	0,75393	0,03889	0,80393	0,99977	1,00000	0,70778	0,70060	0,69010
CMI	0,68001	-0,36412	0,85565	0,71062	0,70778	1,00000	0,73595	0,83677
MSAVI	0,77722	-0,21369	0,85620	0,70345	0,70060	0,73595	1,00000	0,84473
GNDVI	0,84591	-0,36778	0,98472	0,69459	0,69010	0,83677	0,84473	1,00000

El análisis PCA permite aportar además la matriz de autovalores y autovectores con las que se transforma variables originales en otras nuevas, las componentes principales. La matriz de autovalores contiene los valores propios o eigenvalues que indican la varianza explicada por cada componente principal. Cuanto más grande sea este valor, más importancia tendrá la componente principal. Por ejemplo, en la Tabla 2.5 la primera componente principal es la más importante. Por otro lado, la matriz de autovectores indica la dirección de las componentes principales en el espacio original de variables. En la matriz de autovectores, en cada columna se puede ver cuanto influye cada variable original (los índices de imagen) en cada componente principal. Por ejemplo, la primera componente

principal está influenciada por el NDMI (0,43), NDVI (0,51), MSAVI (0,46) y GNDVI (0,42) en su mayoría. Cabe destacar, que en cada columna se indican los coeficientes de los vectores propios normalizados y se cumple la norma euclidiana, es decir, la raíz cuadrada de la suma de los coeficientes al cuadrado es 1, como se puede comprobar haciendo uso de la Tabla 2.5.

Tabla 2.5. Matriz de autovalores y autovectores correspondiente a antes de las lluvias.

PC	1	2	3	4	5	6	7	8
Autovalores	0,07215	0,00796	0,00401	0,00258	0,00094	0,00003	0,00000	0,00000
Autovectores Capa (índice)								
NDMI	0,43247	-0,60465	0,20242	-0,12058	0,26458	-0,53358	-0,19272	-0,00241
NDSI	-0,05513	-0,68887	0,05893	0,31798	0,00159	0,61009	0,21355	0,00457
NDVI	0,51342	0,08626	0,19539	-0,28317	-0,38032	0,45228	-0,50997	-0,03633
PRI	0,11835	-0,07668	0,06185	0,17480	-0,67098	-0,28051	0,32421	-0,55832
VARI	0,08308	-0,05346	0,04297	0,12460	-0,47888	-0,18233	0,15834	0,82779
CMI	0,36498	0,34922	0,40068	0,72339	0,24674	0,00986	0,00305	0,00056
MSAVI	0,46364	0,00716	-0,85664	0,21964	0,05046	0,01911	-0,00282	-0,00072
GNDVI	0,42101	0,14719	0,13166	-0,43191	0,20587	0,16168	0,72593	0,04128

Por último, el análisis de PCA proporciona una tabla con el porcentaje y acumulación de autovalores, indicando cuanta variabilidad representa cada componente principal, teniendo las primeras componentes principales los valores más altos, son aquellos que conservan la mayor cantidad de información, como se observa en la Tabla 2.6. Además, el porcentaje de autovalores indica la varianza total explicada por cada componente principal y su acumulación debe ser el 100 %. Teniendo en cuenta el ejemplo anterior y la Tabla 2.6, se puede observar como se puede reducir la dimensionalidad a dos componentes principales, ya que, entre ambas explican el 91 % de la varianza, quedando las demás componentes principales redundantes.

Tabla 2.6. Tabla de porcentaje y acumulación de autovalores correspondiente a antes de las lluvias.

PC	Autovalor	% de Autovalores	Acumulación
1	0,07215	82,3009	82,3009
2	0,00796	9,0743	91,3752
3	0,00401	4,5733	95,9485
4	0,00258	2,9420	98,8905
5	0,00094	1,0749	99,9654
6	0,00003	0,0304	99,9958
7	0,00000	0,0040	99,9998
8	0,00000	0,0002	100,0000

2.4.2. Regresión Lineal Ordinaria (OLS)

La regresión lineal ordinaria u *Ordinary Least Squares*, OLS en sus siglas en inglés (que se van a utilizar en este trabajo) es una técnica estadística que modela la relación entre una variable dependiente, y una o más variables independientes [44].

El OLS se basa en un modelo matemático que emplea una correlación lineal en la que los coeficientes de la recta de regresión se calculan minimizando la suma de los cuadrados de los errores, es decir, la diferencia entre valores observados y predichos. La OLS asume que las variables son independientes, la varianza es homogénea y los residuos siguen una distribución normal. Tras aplicar la OLS, nos proporciona los coeficientes de la regresión, que nos indican la fuerza y dirección de las relaciones entre las variables. R^2 , que es el coeficiente de determinación, indica cuanta varianza de la variable dependiente explican las independientes. Además, proporciona un coeficiente, los p-valores, a través de los cuales podemos conocer si los resultados son estadísticamente significativos. En la práctica, esta técnica se puede aplicar en numerosos campos: en la meteorología, para predecir temperaturas; en biología para predecir número individuos de una especie basado en factores como recursos existentes o depredadores; en economía, para predecir las ganancias; o en Física de la Tierra, como es este caso, para predecir la relación entre deslizamientos de tierra e índices de imagen. [45]

En este trabajo, la OLS se emplea para determinar si existe una relación significativa entre los índices de imagen y la ocurrencia de deslizamientos. Además, ayudará a cuantificar cuánto afecta las variables independientes a la dependiente, siendo la dependiente los deslizamientos y las independientes los índices de imagen. Por último, si los coeficientes son significativos, se puede deducir qué variables tienen mayor impacto en los deslizamientos.

En conclusión, la regresión OLS será fundamental para verificar las hipótesis planteadas en este estudio y establecer las relaciones matemáticas que permitan predecir los deslizamientos de tierra a partir de los índices de imagen.

Del mismo modo que en el apartado anterior se va a mostrar un resultado del análisis OLS, tomando como ejemplo el análisis antes del evento de lluvias extremas. En primer lugar el análisis OLS proporciona una tabla con los coeficientes del modelo de regresión y parámetros estadísticos, que se puede ver en la Tabla 2.7. En esta tabla, la columna coeficiente indica la dirección y magnitud de cada variables con la variable dependiente, es decir, indica cómo influye cada índice de imagen en la detección de deslizamientos. El error estándar (StdError) indica la precisión de las estimaciones, mientras que el estadístico-t informa sobre la significancia de una variable en el modelo, teniendo mayor significancia cuanto mayor sea el valor absoluto de este coeficiente. Un valor de probabilidad menor que 0,01 indica que la probabilidad de que la relación observada entre la variable independiente y la dependiente no sea casual. Por último, el Factor de Inflación de la Varianza o VIF, es otra medida que indica colinealidad entre variables independiente, es decir, dice si una variables está muy relacionada con otras en el modelo. A partir de un VIF mayor de 10 se considera que hay alta multicolinealidad. Los parámetros descritos son algunos de los que aporta el análisis OLS y los que se van a usar en este trabajo.

Tabla 2.7. Tabla que muestra los coeficientes del modelo de regresión para cada variable explicativa (índices de imagen) además de algunos parámetros estadísticos del análisis OLS antes del evento de lluvias.

Variable	Coeficiente	StdError	t-Statistic	Probabilidad	VIF
Ordenada	-0,562602	0,066987	-8,398701	0,000000	-
NDMI	2,808031	0,620462	4,525707	0,000008	760,536137
NDSI	-3,015807	0,686762	-4,391342	0,000015	261,126951
NDVI	-3,860762	1,132336	-3,409556	0,000669	> 1000,0
PRI	126,994415	5,012690	25,334582	0,000000	> 1000,0
VARI	-171,706180	7,530639	-22,801012	0,000000	> 1000,0
CMI	0,522635	0,059939	8,719408	0,000000	5,723638
MSAVI	-1,994720	0,163793	-12,178302	0,000000	47,447399
GNDVI	1,717287	1,505265	1,140853	0,253950	> 1000,0

En la anterior Tabla 2.7 se observa como el coeficiente de valor 126,99 correspondiente al índice PRI indica que influye significativamente en la detección de deslizamientos con una correlación positiva, además y dado que la probabilidad es cero, es significativamente estadístico. Por otro lado, el VIF indica que puede haber posibles problemas de multicolinealidad, lo que significa que el índice PRI puede estar demasiado correlacionado con alguno de los índices empleados en el análisis OLS.

Otro resultado del OLS se muestra en la Tabla 2.8 donde se muestran los resultados de las verificaciones de diagnóstico de OLS que se van a tener en cuenta en este estudio. Se observa que el número de observaciones, es decir, el número de puntos que se han estudiado son 12420, de los cuales 183 son deslizamientos. Además, el valor R^2 indica que el 14,54 % de la variabilidad de los índices.

Tabla 2.8. Resultados estadísticos del modelo OLS para antes del evento de lluvias.

Parámetro	Valor
Número de Observaciones	12420
R cuadrado	0,145377
R cuadrado ajustado	0,144826

3

Resultados

El capítulo de resultados se va a organizar de la siguiente manera: en primer lugar, se va a presentar el algoritmo empleado para realizar este trabajo y después se presenta la geodatabase construida mediante un proyecto con ArcGIS Pro en el que se van a ir acumulando el resto de los datos obtenidos, como el mapa geológico, el de vegetación o los mapas con información geométrica. A continuación, se van a ir añadiendo a dicha geodatabase las bandas extraídas de Sentinel-2. Posteriormente, y a partir de dichas bandas, se van a calcular los índices de imagen tanto previamente de las lluvias como posteriormente a las mismas.

3.1. Algoritmo

El algoritmo ya ha sido presentado en el apartado de desarrollo experimental (Anexo 5.3). Consta de 6 secciones y 260 líneas de comando que ejecutan tanto la descarga del DEM, el repixelado de las bandas, el cálculo de los índices de imagen además de los análisis estadísticos.

3.2. Geodatabase de trabajo

En primer lugar, la geodatabase del trabajo incluye datos de las características geométricas del terreno, geológicas, de vegetación y de los deslizamientos identificados en la zona de estudio. Los deslizamientos se muestran en la Figura 3.1, las características geológicas en la Figura 3.2 y la distribución de la vegetación en la Figura 3.3.

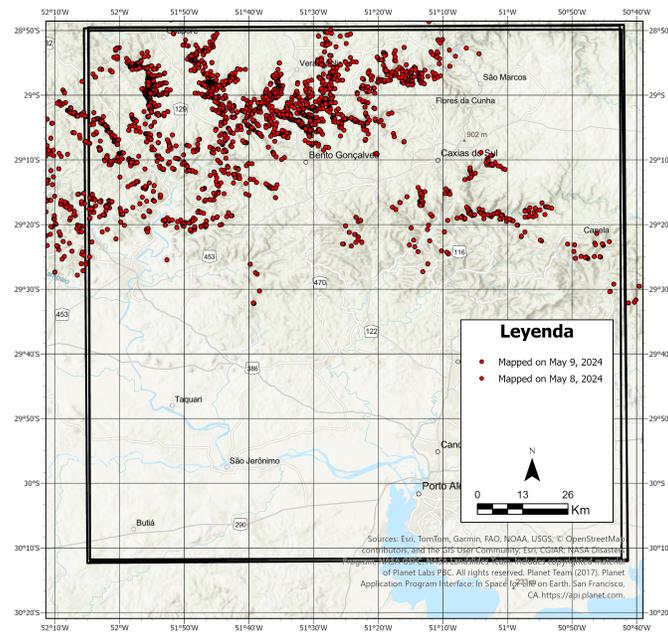


Figura 3.1. Detalle de los deslizamientos que aparecen en la zona de estudio, mapeados entre el 8 y 9 de mayo de 2024 [46].

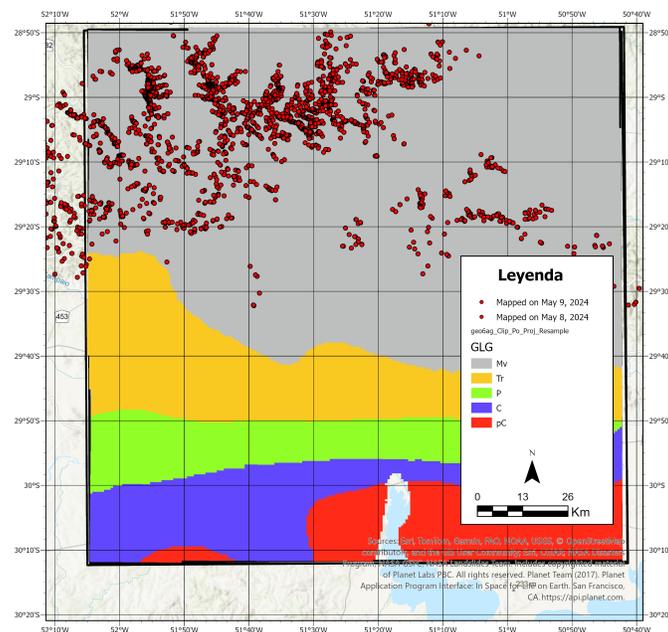


Figura 3.2. Detalle de las unidades cronoestratigráficas de la zona de estudio, además de los deslizamientos de tierra. Las siglas de la leyenda tienen el siguiente significado: Mv, Mesozoic volcanics; Tr, Triassic; P, Permian; C, Carboniferous; pC, Precambrian undifferentiated [31].

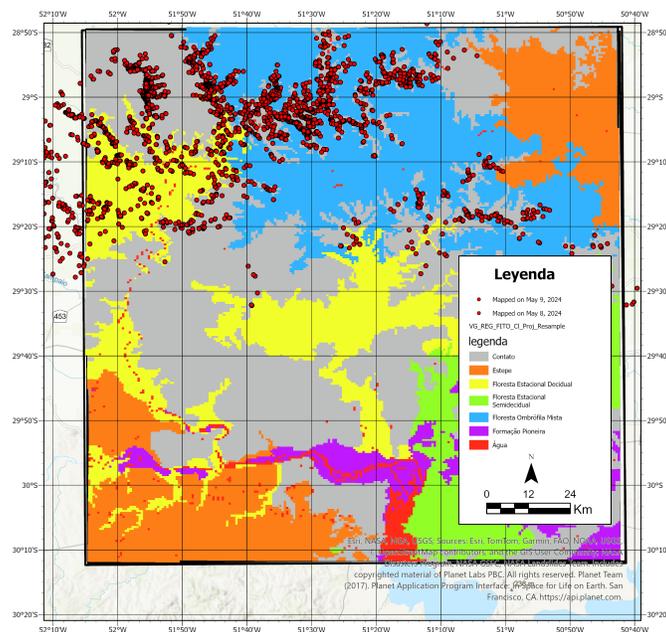


Figura 3.3. Detalle de las unidades de vegetación sobre las que se observan los deslizamientos de tierra producidos[30].

Asimismo, para la geometría del terreno se ha utilizado un DEM (Modelo Digital de Elevación) a partir del cual podemos conocer la altitud además de la orientación e inclinación del terreno que se presentan a continuación. El DEM se muestra en la Figura 3.4, el mapa de orientaciones en la Figura 3.5 y el de pendientes en la Figura 3.6.

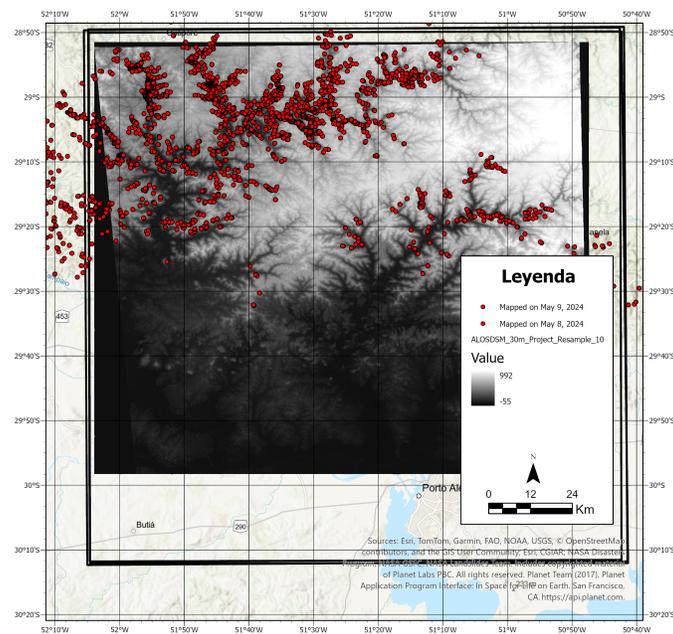


Figura 3.4. Detalle del DEM de la zona de estudio, representando la altitud y el relieve de la misma.

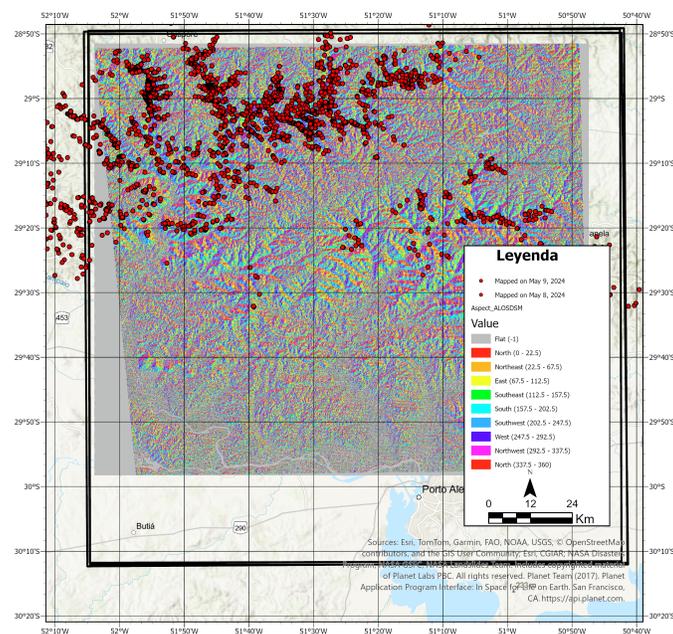


Figura 3.5. Detalle de la orientación de las laderas en la zona de estudio.

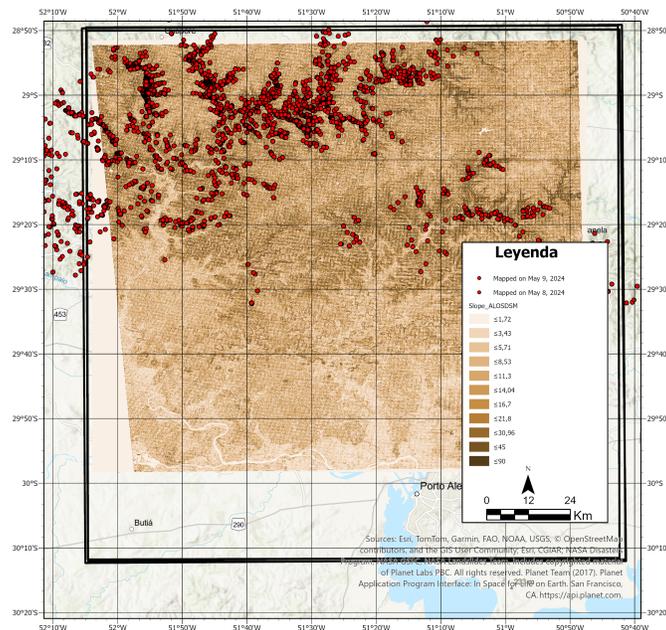


Figura 3.6. Detalle de la pendiente de la zona de estudio.

Además, en la geodatabase mencionada se han incluido las diferentes bandas de información e índices de imagen que se detallarán en los apartados siguientes.

3.3. Bandas de trabajo

La imagen Sentinel considerada antes del evento está compuesta por las bandas 2, 3, 4, 8, 11 y 12 que se muestran en la Figura 3.7. En la misma se indica la reflectancia espectral de cada una de las bandas tomando valores entre 0 y 19.000 niveles digitales, como ya se ha comentado en apartados anteriores.

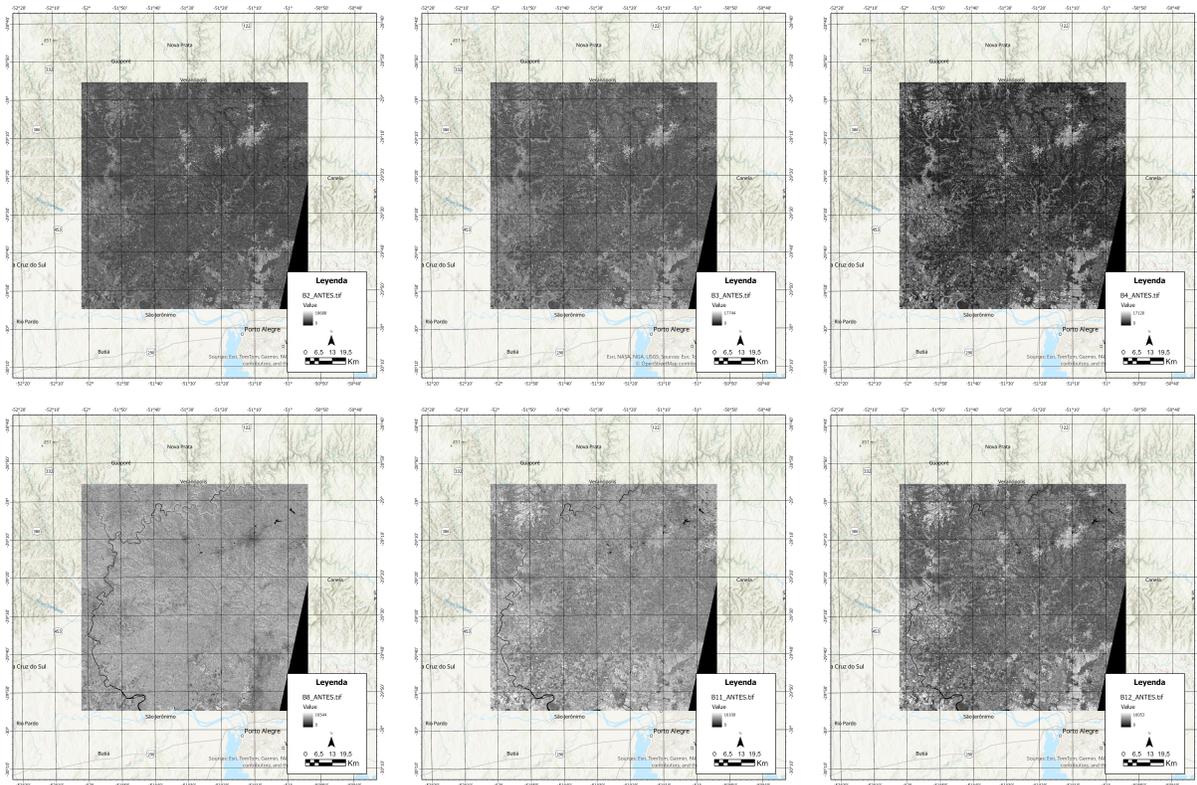


Figura 3.7. Imágenes de las bandas correspondientes a la señal de Sentinel-2 previa a las lluvias. De izquierda a derecha y de arriba a abajo se muestran las bandas en el siguiente orden: B02, B03, B04, B08, B11 y B12.

Además, en la Figura 3.8 se presentan las imágenes de las bandas correspondientes a después del evento de lluvias.

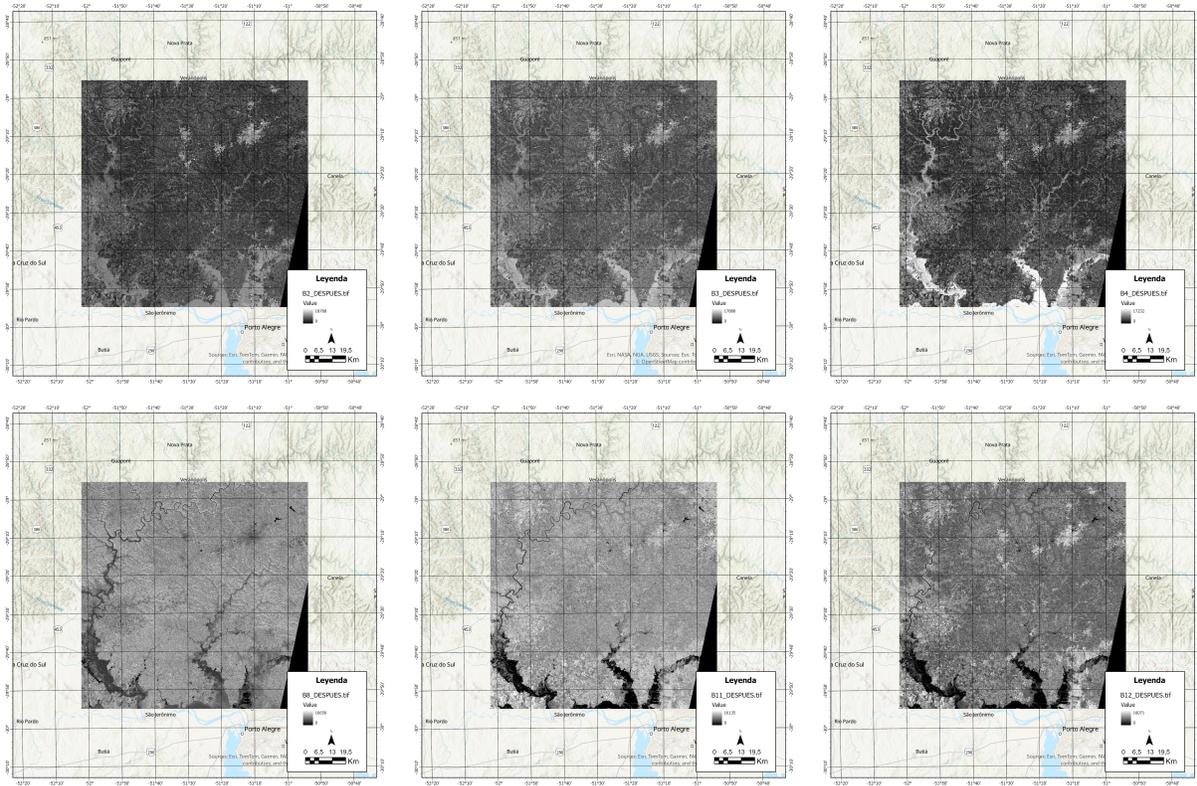


Figura 3.8. Imágenes de las bandas correspondientes a la señal de Sentinel-2 posterior a las lluvias. De izquierda a derecha y de arriba a abajo se muestran las bandas en el siguiente orden: B02, B03, B04, B08, B11 y B12.

3.4. Índices de imagen

Una vez incorporadas las bandas anteriores al proyecto arcgis y haciendo uso del código del Anexo 5.3.3 en el que se emplean las ecuaciones de la Tabla 2.1, se han calculado los índices de imagen correspondientes al periodo anterior y posterior al evento de precipitaciones además de la diferencia entre ambas. La Figura 3.9 muestra los índices de imagen correspondientes a fecha anterior al evento de lluvias.

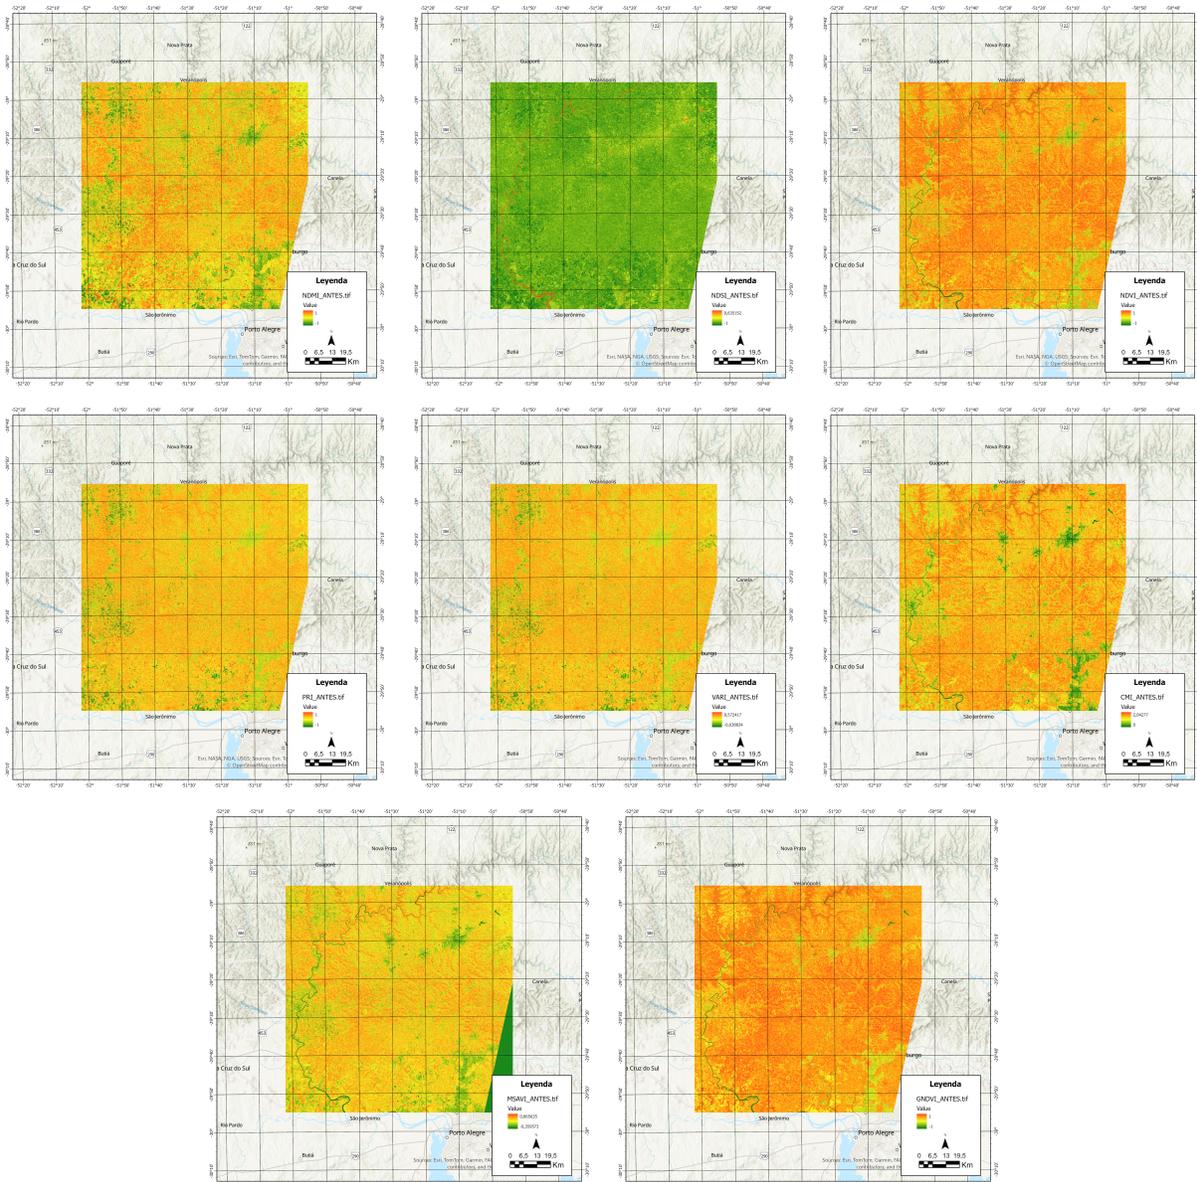


Figura 3.9. Índices de imagen previos a las lluvias. De izquierda a derecha y de arriba a abajo se muestran los índices en el siguiente orden: NDMI, NDSI, NDVI, PRI, CMI, MSAVI y GNDVI.

La siguiente Figura 3.10 corresponde con los índices de imagen correspondientes a una fecha posterior a las lluvias extremas ocurridas.

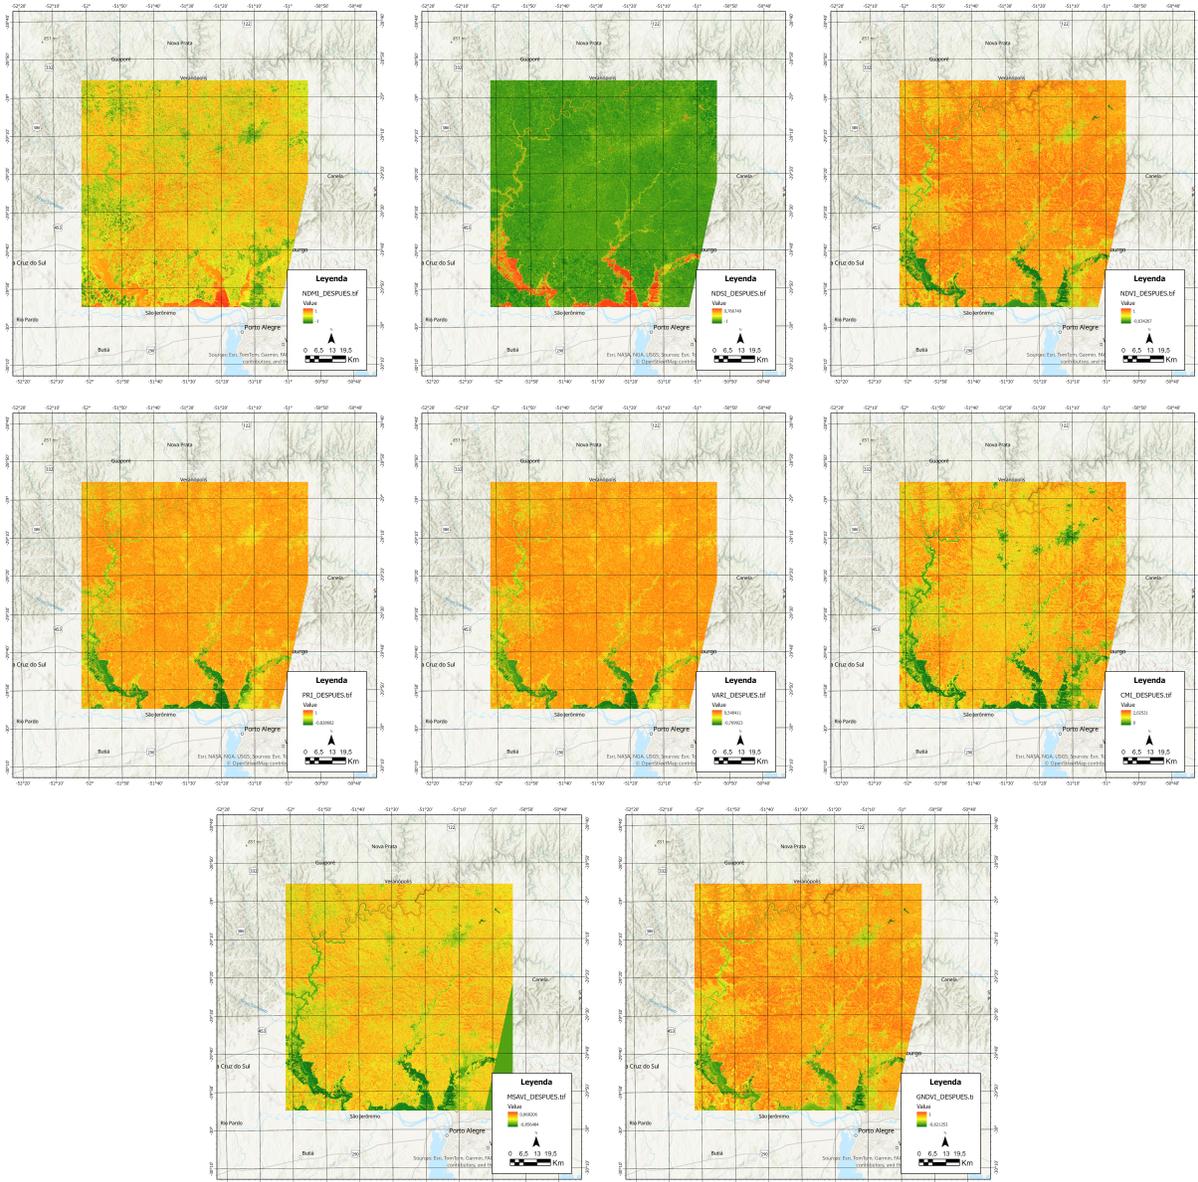


Figura 3.10. Índices de imagen posteriores a las lluvias. De izquierda a derecha y de arriba a abajo se muestran los índices en el siguiente orden: NDMI, NDSI, NDVI, PRI, CMI, MSAVI y GNDVI.

Por último, una vez calculados los índices de imagen para ambos eventos, se han calculado los índices de diferencia como las del evento previo menos el posterior. Los valores de los índices de imagen diferencia se muestran en la Figura 3.11. Asimismo, en el Anexo 5.3.3 se muestra el código empleado para calcular los índices de diferencia.

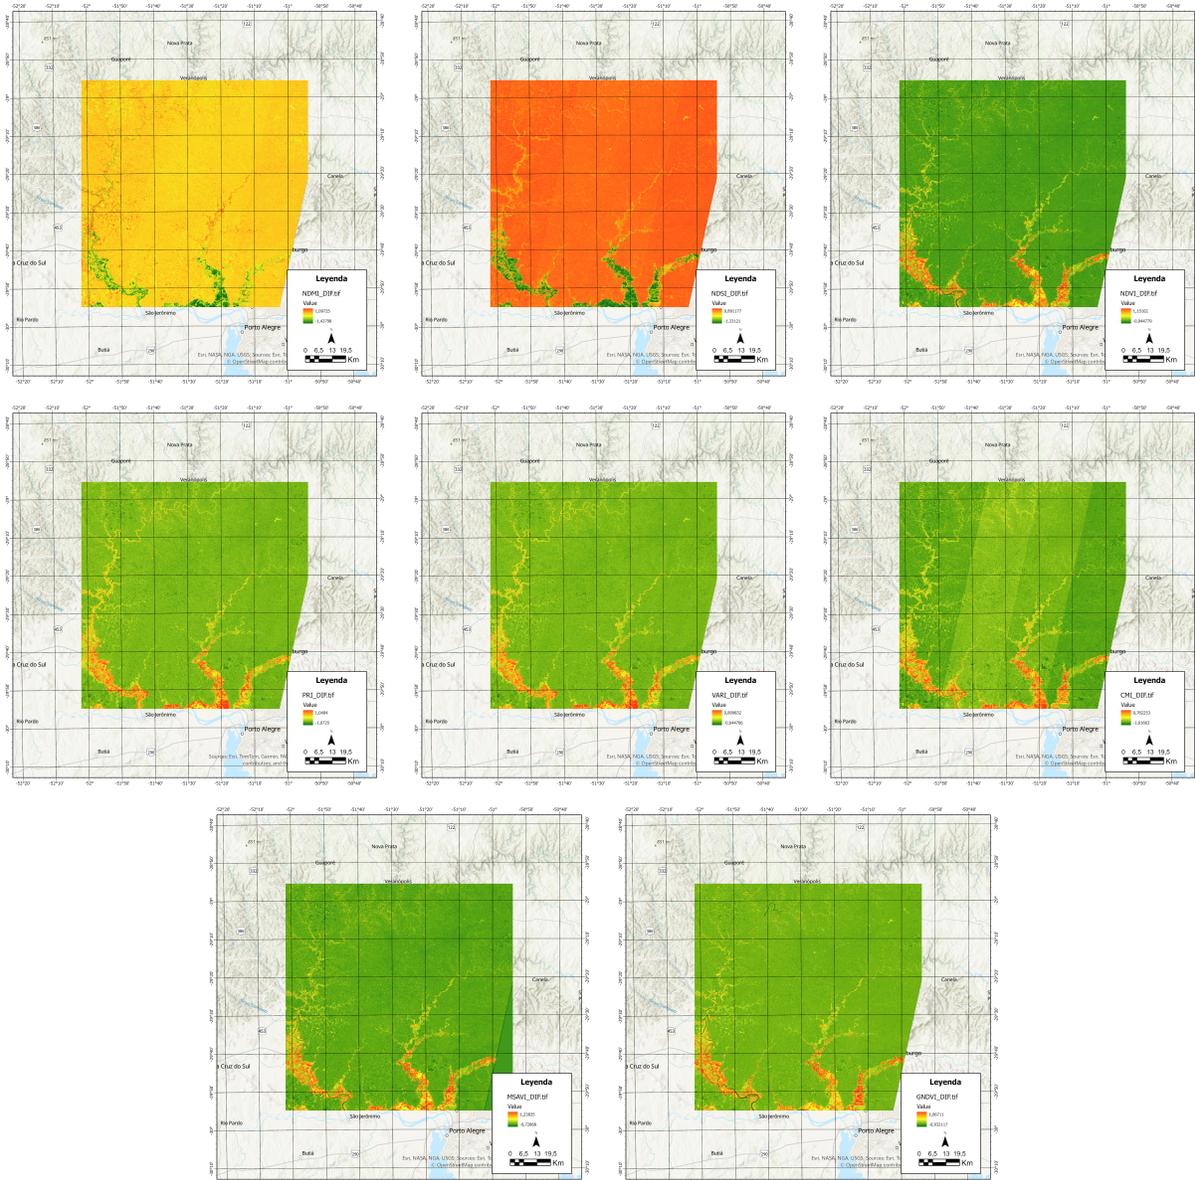


Figura 3.11. Índices de imagen diferencia previas menos posteriores a las lluvias. De izquierda a derecha y de arriba a abajo se muestran los índices en el siguiente orden: NDMI, NDSI, NDVI, PRI, CMI, MSAVI y GNDVI.

Como se ha podido observar en la Figura 3.9, Figura 3.10 y Figura 3.11, se han tintado los índices de imagen de una gama de colores distinta al gris para poder observar mejor las diferencias entre los índices de imagen.

3.5. Análisis PCA

En el Anexo 5.4 se muestran los resultados de los análisis PCA realizados, el posterior a las lluvias en la Tablas 5.6, 5.7, 5.8 y 5.9, la diferencia entre pre-post en las Tablas 5.10, 5.11, 5.13 y 5.12 y

el de las variables topográficas en las Tablas 5.2, 5.3, 5.4 y 5.5, a excepción del resultado para el PCA realizado antes del evento de precipitaciones que ya se ha mostrado en la sección de desarrollo experimental en las Tablas 2.3, 2.4, 2.5 y 2.6.

3.6. Análisis OLS

En el Anexo 5.5 se muestran de los análisis OLS realizados, el posterior a las lluvias en las Tablas 5.14 y 5.15, la diferencia pre-post en las Tablas 5.16 y 5.17, a excepción del análisis OLS previo al evento de lluvias que ya se ha mostrado en la sección de desarrollo experimental en las Tablas 2.7 y 2.8.

4

Discusión

Mediante el análisis de las imágenes presentadas en las Figuras 3.2 y 3.3, se ha podido establecer una correlación visual entre áreas afectadas y características geológicas, de cobertura vegetal y geométricas del terreno. La Figura 3.2 se observa que a pesar de que la zona de estudio es extensa, la mayoría de los deslizamientos se concentran en el noroeste. La zona de estudio está compuesta por tres conjuntos de rocas del substrato; rocas sedimentarias del Carbonífero, rocas ígneas y metamórficas del Mesozoico y Precámbrico. En estos tres tipos de grandes unidades las condiciones climáticas van a favorecer el desarrollo de matos de alteración muy heterogéneos en cuanto a su espesor y distribución espacial. Los mantos de alteración propiciarán el desarrollo de suelos arcillosos que cuando se producen deforestaciones intensas generan zonas muy propensas a la aparición de deslizamientos de tierra. En función del tipo de roca el manto de alteración evoluciona de una manera más o menos efectiva. En todos ellos a través de la red de fracturas presentes se permite el paso del agua de lluvia al interior del macizo rocoso, favoreciendo procesos de alteración físico-químicas de los materiales. En las rocas ígneas, esta red de fracturación está detrás del desarrollo de mantos de alteración en zonas teóricamente resistentes, siendo áreas muy propensas a la aparición de movimientos de tierras. En las rocas metamórficas del mesozoico, la descompresión producida también genera una red de fracturas de distensión a través de la que se produce una meteorización¹ física y producción de deslizamientos. En rocas sedimentarias la meteorización produce pérdidas de cohesión del material y la disminución de la fricción entre granos minerales dando lugar a deslizamientos de tierra. Teóricamente, entre los tres tipos de rocas características de la zona, las que más influyen en los deslizamientos de la zona de estudio son las sedimentarias, debido a su baja cohesión y alta permeabilidad [48].

Por otro lado, atendiendo a la vegetación, la zona de estudio está formada por tres grandes tipos de asociaciones vegetales: Floresta Ombrófila Mista también conocido como bosque de Araucaria (es decir, un bosque subtropical de montaña característico del sur de Brasil), Floresta Estacional Decidual (bosque caracterizado por la pérdida de hojas de árboles en determinadas épocas del año, generalmente durante la estación seca o fría) y zonas de estepa (llanuras de vegetación herbácea) así

¹La meteorización es el proceso natural mediante el cual las rocas de la superficie terrestre se desintegran debido a agentes externos. La meteorización solo implica la alteración o ruptura de la roca. En caso de haber transporte de materiales, se considera erosión[47].

como lugares de transición. Las dos primeras unidades están caracterizadas por disponer de raíces que se desarrollan en mayor medida en la horizontal que en la vertical. La Figura 3.3 muestra la relación que hay entre deslizamientos y vegetación. Como se puede apreciar los deslizamientos son más abundantes en las dos primeras unidades de vegetación mencionadas. A pesar de que se esperaría que la concentración de deslizamientos de tierra se situara en zonas de menor densidad vegetal, los resultados muestran, que las zonas de Floresta Estacional Decidual y Floresta Ombrófila Mista, caracterizadas por una gran cobertura de vegetación es donde se ha producido la mayor parte de los deslizamientos. Una posible explicación puede ser que es una zona con gran humedad a lo largo de todo el año. Al ocurrir precipitaciones extremas se ha podido saturar el terreno en mayor medida que en las zonas esteparias produciendo una reducción de su cohesión gracias al escaso desarrollo en profundidad de las raíces en estas asociaciones vegetales.

El análisis de las características geológicas, de vegetación y características geométricas del terreno mediante un PCA permite identificar las variables que influyen en la susceptibilidad de la zona de estudio para producir deslizamientos. A partir de los resultados de la matriz de correlación presentados en la Tabla 5.3 se puede observar una correlación fuerte y negativa entre la geometría del terreno y rocas del sustrato. Es decir, en las zonas más elevadas donde aparecen las rocas ígneas del Mesozoico volcánico, pero muy alteradas es donde hay mayor propensión a deslizamientos de tierra. La vegetación también está fuertemente correlacionada de forma negativa con la geología, lo que implica que en función de la geología habrá un tipo de vegetación u otro, lo que muestra características de susceptibilidad del terreno a los deslizamientos. Así, la vegetación está relacionada de forma negativa con las rocas descritas anteriormente, se desarrollan más deslizamientos en zonas elevadas donde hay más mantos de alteración. Además, la pendiente y orientación del terreno también muestran una correlación con la geología, aunque en menor medida, lo que sugiere que la geología es una parte importante de la morfología del terreno y es bastante explicativa de los procesos de erosión. Siguiendo con el análisis de los resultados del PCA, en la Tabla 5.4, se puede comprobar que cada componente principal corresponde con una de las variables que hemos descrito, geología, pendiente, orientación, vegetación y altimetría. Por último, en la Tabla 5.5 se observa que entre la primera y segunda componente principal explican el 99,85 %, es decir, la variabilidad correspondiendo con el DEM o altimetría y con la orientación del terreno, respectivamente.

En cuanto a los índices de imagen y para entender la relación entre ellos, y su conexión con los deslizamientos se va a acudir a los análisis estadísticos realizados. Por un lado, el análisis PCA nos ayuda a detectar la relación entre los índices de imagen, tanto antes y después de las lluvias, además de la diferencia entre ambos.

- Atendiendo a la Tabla 2.5, el análisis PCA de los índices previos a las lluvias revela que la primera componente principal, asociada al NDMI, NDVI, MSAVI y GNDVI, es la que más influye en la variabilidad de los datos, explicando un 82,3 % de la varianza según la tabla de porcentaje y autovalores acumulativos. Además, la segunda componente principal, relacionada con el índice NDMI y el NDSI, explica el 9 % de la varianza. En conjunto, las dos primeras componentes principales explican el 91,3 % de la varianza, siendo el porcentaje restante explicado por las demás componentes. No obstante, la matriz de correlación, presentada en la Tabla 2.4 muestra que la mayoría de índices tienen una correlación alta entre sí, a excepción del NDSI, cuya correlación con el resto de índices es muy baja y negativa en algunos casos. Este hecho puede indicar que este índice tiene un comportamiento distinto a los demás, por lo que se debe tener en cuenta a la hora de realizar futuros análisis. Dado que el agua es un buen absorbente de la radiación infrarroja, el NDSI es un buen medidor de la humedad puesto

que es muy sensible a las variaciones de la radiación en el infrarrojo.

- A partir del análisis PCA después de las lluvias se deduce lo siguiente: en este caso, como se observa en la Tabla 5.8, la primera componente principal está formada por el NDVI, MSAVI y GNDVI, explicando el 79,48 % de la variabilidad de los datos, mientras que la segunda componente influenciada por el NDMI y NDSI, explica el 15,2 % de la variabilidad como se puede ver en la Tabla 5.9. Teniendo en cuenta la matriz de correlación de la Tabla 5.7, se puede ver, que a diferencia que en el anterior caso todos los índices muestran una correlación alta a excepción del NDMI, lo que indica que su comportamiento ha variado.
- Por último, en cuanto al análisis PCA de la diferencia pre-post se observa que, la PC1 explica el 82,7 % de la varianza, estando afectada por el NDSI y el NDVI, mientras que la PC2 explica el 12,5 % de la misma, fuertemente condicionada por NDMI y NDSI. En la Tabla 5.12 se ve cuanta variabilidad explica cada componente principal y en la Tabla 5.13 que índices influyen cada componente principal. Teniendo en cuenta la matriz de correlación de la Tabla 5.11, observamos que al igual que en el anterior caso el índice NDMI se comporta de manera diferente a los demás.

Respecto al análisis OLS realizado, se pueden extraer las siguientes implicaciones:

- El análisis OLS antes de las lluvias muestra que manteniendo constantes los demás índices, un aumento en los índices NDMI, PRI, CMI o GNDVI se asocian con un aumento de los deslizamientos de tierra. Sin embargo, un aumento en cualquiera de los demás índices indica una disminución de los deslizamientos. Por otro lado, los valores de Probabilidad asociados a los coeficientes son bajos, indicando que son significativos (Tabla 2.7). A excepción del índice CMI y MSAVI el valor VIF es alto, mayor que 100, indicando que los índices están explicados en su mayoría por otros índices. Este hecho tiene sentido porque los índices de imagen empleados son diferentes combinaciones de las bandas utilizadas. En la Tabla 2.8 se observa que el coeficiente de regresión, R^2 , tiene valor 0,14, lo que indica que el modelo de regresión explica solo un 14 % de la variabilidad de los deslizamientos. Esto plantea que hay otros factores además de los índices que se deben tener en cuenta a la hora de estudiar deslizamientos.
- En cambio el OLS para después de las lluvias muestra que la relación entre los índices NDMI, VARI, CMI y los deslizamientos es positiva, siendo fuerte en el caso del NDMI y VARI. Los demás índices tienen una correlación negativa, cobrando fuerza el índice PRI. Al igual que en el anterior caso, los valores de Probabilidad son bajos llegando a la misma conclusión que antes (Tabla 5.15). De igual modo que en el análisis anterior a las lluvias, los índices VIF son elevados excepto para el CMI y MSAVI. En este caso el coeficiente de regresión es del 8 %, como se observa en la Tabla 5.16, explicando menos variabilidad que antes de las lluvias.
- El análisis para la diferencia entre pre y post lluvias indica que la relación entre los índices NDMI, PRI, CMI y los deslizamientos es positiva, siendo muy fuerte para PRI. La correlación entre el resto de índices y los deslizamientos es negativa, siendo especialmente fuerte en el caso de VARI (Tabla 5.16); obteniéndose valores similares en cuanto al valor VIF y la probabilidad respecto a los casos anteriores. En este caso, el valor de R^2 es del 25,2 % explicado una mayor parte de la variabilidad de los deslizamientos tal y como se ve en la Tabla 5.17.

En vista de lo anterior, el modelo OLS desarrollado antes de las lluvias consigue explicar solo el 14 % de la variabilidad, reduciéndose al 8 % tras las lluvias. Este análisis indica que factores como la altimetría, la vegetación o la geología de la zona pueden influir en la ocurrencia de deslizamientos. No obstante, el análisis de la diferencia pre-post de las lluvias logra explicar el 25,2 % de la variabilidad, lo que sugiere que el cambio en los índices de imagen es otro factor a tener en cuenta para identificar áreas con mayor susceptibilidad de sufrir deslizamientos de tierra, lo que permite ser empleado como un elemento en la cartografía de áreas afectadas por deslizamientos. En términos relativos la eficacia de identificar deslizamientos ha aumentado en un 100 %, no obstante sería deseable llevar a cabo nuevas investigaciones para mejorar como aumentar este porcentaje a nivel absoluto.

En este trabajo se ha visto que la identificación y predicción de estos eventos es un desafío a mejorar. A futuro, la incorporación de datos geoespaciales además de emplear modelos de aprendizaje automático, como machine learning, podría mejorar la capacidad de predicción y análisis de los deslizamientos de tierra. Igualmente, con el objetivo de seguir mejorando la predicción y análisis, validar estos modelos en otras regiones permitirían potenciar su precisión y fiabilidad, contribuyendo a mejorar la gestión en materia de emergencias y prevención es este tipo de riesgos naturales.

En conclusión, los resultados de este trabajo contribuyen a comprender los deslizamientos de tierra. No obstante, queda un largo recorrido para avanzar en el desarrollo de metodologías más precisas y en la integración de nuevas tecnologías para mejorar la predicción y gestión de riesgos de los deslizamientos de tierra.

5

Conclusiones

En el presente trabajo se ha cumplido con los objetivos que se pretendían alcanzar:

- Se ha diseñado un algoritmo para el tratamiento de imágenes que ha permitido extraer simultáneamente los 8 índices de imagen empleados para analizar deslizamientos de tierra, además de su incorporación a un SIG.
- Se ha creado una geodatabase con la información relevante del área de estudio: imágenes del Sentinel-2 anteriores y posteriores al evento de precipitaciones extremas, el DEM el mapa de pendientes, de elevaciones, el mapa de la geología, de la vegetación y el mapa de los deslizamientos ocurridos.
- A partir de las imágenes del Sentinel-2 se ha podido calcular índices de imagen cruciales para el estudio de deslizamientos de tierra.
- Mediante los análisis estadísticos PCA y OLS se ha comprobado la importancia de los índices de imagen para la identificación de áreas afectadas por deslizamientos.
- Se ha analizado el cambio del índice de imagen en la zona de los deslizamientos.
- Este trabajo pone de manifiesto la utilidad de los SIG, los algoritmos y las imágenes satélites en el estudio de fenómenos naturales como los deslizamientos de tierra.
- Se ha comprobado que el uso de un algoritmo en SIG, ArcGIS PRO, facilita enormemente la extracción de los índices además de ahorrar tiempo, alrededor a un 25 % respecto a un proceso normal.
- Se ha visto que las tres variables que aportan más información en orden de mayor a menor son: la altimetría, la orientación del terreno y la vegetación.
- Se ha podido constatar que los índices más relevantes para el estudio de los deslizamientos de tierra han sido por orden de mayor a menor, el NDMI, NDVI, MSAVI, GNDVI y NDSI.
- Los índices que tienen en cuenta la humedad y el vigor de la vegetación son los que más influyen a la hora de estudiar deslizamientos de tierra.

- La diferencia de todos los índices, en general, explican alrededor de un cuarto de la varianza, siendo más del doble de lo que explican individualmente los índices solo anteriores o posteriores a las lluvias.

Referencias

- [1] E. M. Fischer and R. Knutti. Anthropogenic contribution to global occurrence of heavy-precipitation and high-temperature extremes. *Nature Climate Change*, 5:560–564, 6 2015.
- [2] "primero buscas para encontrarlo con vida y luego para poder enterrarlo": la joven que perdió a su padre en la dana de valencia en españa hace casi 5 meses y aún sigue buscándolo - bbc news mundo. <https://www.bbc.com/mundo/articles/cwynd65z56ro> [Accedido: (6 de abril del 2024)].
- [3] J Corominas. El clima y sus consecuencias sobre la actividad de los movimientos de ladera en españa.
- [4] Emilio Chuvieco Salinera. *TELEDETECCIÓN AMBIENTAL. La observación de la Tierra desde el Espacio*. Ariel Ciencias, 3 edition, 2008.
- [5] Física de la tierra - wikipedia, la enciclopedia libre. https://es.wikipedia.org/wiki/F%C3%ADsica_de_la_Tierra [Accedido: (6 de abril del 2024)].
- [6] S. Chakraborty, N. Dey, S. Samanta, A. S. Ashour, and V. E. Balas. *Firefly algorithm for optimized nonrigid demons registration*, pages 221–237. Elsevier Inc., 8 2016.
- [7] Pedro Carrasco García. *Avance en técnicas geofísicas para la caracterización del subsuelo mediante innovación y el uso de herramientas de gestión de información espacial*. PhD thesis, Universidad de Salamanca, 2014.
- [8] Roa José Gregorio. Estimación de áreas susceptibles a deslizamientos mediante datos e imágenes satelitales: cuenca del río mocotíes, estado mérida-venezuela the use of satellite data and imagery for landslide susceptibility mapping in the mocotíes river basin, mérida state-venezuela, 2007.
- [9] Bibliotecas de arcgis python. <https://www.esri.com/es-es/arcgis/products/arcgis-python-libraries/overview#acceder-y-enriquecer-sus-datos> [Accedido: (24 de mayo del 2025)].

- [10] Aumenta a 136 la cifra de muertos por tragedia climática en sur de brasil. <https://spanish.xinhuane.com/20240512/9d162a0aef7c41b78dbb29b03f8f9c90/c.html> [Accedido: (4 de mayo del 2025)].
- [11] Clima rio grande(brasil). <https://es.climate-data.org/america-del-sur/brasil/rio-grande-del-sur/rio-grande-4352/> [Accedido: (16 de abril del 2025)].
- [12] <https://www.embajadadebrasil.org/brasil/estados/region-sur/rio-grande-do-sul.php>[Accedido: (14 de abril del 2025)].
- [13] https://es.wikipedia.org/wiki/R%C3%ADo_Grande_del_Sur [Accedido: (4 de mayo del 2025)].
- [14] Copernicus. About copernicus. <https://www.copernicus.eu/en/about-copernicus> [Accedido: (12 de abril del 2025)].
- [15] Copernicus. Copernicus en pocas palabras. <https://www.copernicus.eu/es/sobre-copernicus/copernicus-en-pocas-palabras> [Accedido: (12 de abril del 2025)].
- [16] La importancia medioambiental del programa copernicus – life amdryc4. <https://lifeamdryc4.eu/la-importancia-medioambiental-del-programa-copernicus/>[Accedido: (12 de abril del 2025)].
- [17] Copernicus: Sentinel-2, 2024. <https://www.eoportal.org/satellite-missions/copernicus-sentinel-2#orbit>[Accedido: (13 de abril del 2025)].
- [18] Lanzamiento del sentinel-2a (vega vv05) - eureka. <https://danielmarin.naukas.com/2015/06/24/lanzamiento-del-sentinel-2a-vega-vv05/>[Accedido: (12 de abril del 2025)].
- [19] Noticias de la Ciencia. Lanzamiento del sentinel 2b. 2017. <https://noticiasdelaciencia.com//art/23314/lanzamiento-del-sentinel-2b> [Accedido: (12 de abril del 2025)].
- [20] ESA. Datos de sentinel, 2017. https://www.esa.int/Space_in_Member_States/Spain/Datos_de_Sentinel[Accedido: (13 de abril del 2025)].
- [21] Copernicus. Sentinel 2, 2015. https://www.esa.int/Space_in_Member_States/Spain/SENTINEL_2 [Accedido: (12 de abril del 2025)].
- [22] El programa copernicus aplicado a la producción y gestión de la información geoespacial. https://www.ign.es/web/resources/docs/IGNCnig/actividades/OBS/Programa_Marco_Copernicus_User_Uptake/3_componente_espacio_Copernicus.pdf [Accedido: (29 de mayo del 2025)].
- [23] David Cerezo Rebé. Identificación de cultivos mediante teledetección y técnicas de machine learning en el ámbito territorial de la comarca de la ribera baja, valencia., 2023.
- [24] Todo lo que deberías saber sobre imágenes sentinel 2, 2019. <https://www.gisandbeers.com/lo-deberias-saber-imagenes-sentinel-2/>[Accedido: (13 de abril del 2025)].
- [25] Alos global digital surface model .alos world 3d - 30m (aw3d30)”. https://www.eorc.jaxa.jp/ALOS/en/dataset/aw3d30/aw3d30_e.htm [Accedido: (29 de mayo del 2025)].
- [26] Prism panchromatic remote-sensing instrument for stereo mapping. https://www.eorc.jaxa.jp/ALOS/en/alos/sensor/prism_e.htm [Accedido: (29 de mayo del 2025)].

- [27] Alos prism. <https://geospatial.com.co/opticas/alos-prism/> [Accedido: (29 de mayo del 2025)].
- [28] https://browser.dataspace.copernicus.eu/?zoom=5&lat=50.16282&lng=20.78613&themeId=DEFAULT-THEME&visualizationUrl=U2FsdGVkX19ZZVYmLhhgwm8WwtVQ3cos7jP21o5DZuuojtX105PEVuAkMR37dAr6o4rfoNS2HexNJqrajnXL8xoLvOs2CMopGGNjhnEIu41Mwq1TyW1F1SuQ%2BSB28Iom&datasetId=S2_L2A_CDAS&demSource3D=%22MAPZEN%22&cloudCoverage=30&dateMode=SINGLE.
- [29] El problema de la corrección atmosférica de sentinel-2. https://www.inta.es/INTA/eu/blogs/copernicus/BlogEntry_1509095468013 [Accedido: (29 de mayo del 2025)].
- [30] <https://www.ibge.gov.br/en/geosciences/downloads-geosciences.html?lang=en-GB> [Accedido: (4 de mayo del 2025)].
- [31] Christopher J Schenk, Roland J Viger, and Christopher P Anderson. Maps showing geology, oil and gas fields and geologic provinces of the south america region, 2000.
- [32] Cómo descargar todos los dem mundiales de forma simultanea. <https://www.gisandbeers.com/descargar-dem-mundiales-forma-simultanea/> [Accedido: (28 de mayo del 2025)].
- [33] NDMI: Índice de humedad de diferencia normalizada, 2023. <https://eos.com/es/make-an-analysis/ndmi/> [Accedido: (15 de abril del 2025)].
- [34] NDSI: Índice diferencial normalizado de nieve, 2023. <https://eos.com/es/make-an-analysis/ndsi/> [Accedido: (15 de abril del 2025)].
- [35] NDVI: Preguntas frecuentes y qué necesita saber, 2025. <https://eos.com/es/blog/ndvi-preguntas-frecuentes/> [Accedido: (15 de abril del 2025)].
- [36] Calculating ndvi using qgis. <https://mapscaping.com/calculating-ndvi-using-qgis/> [Accedido: (30 de abril del 2025)].
- [37] Martín F. Garbulsky, Josep Peñuelas, John Gamon, Yoshio Inoue, and Iolanda Filella. The photochemical reflectance index (pri) and the remote sensing of leaf, canopy and ecosystem radiation use efficiencies. a review and meta-analysis, 2 2011.
- [38] Vari. <https://pro.arcgis.com/es/pro-app/3.3/arcpy/image-analyst/vari.htm> [Accedido: (15 de abril del 2025)].
- [39] Clay minerals. <https://pro.arcgis.com/es/pro-app/latest/arcpy/spatial-analyst/clayminerals.htm> [Accedido: (15 de abril del 2025)].
- [40] Msavi, 2024. <https://eos.com/es/make-an-analysis/msavi/> [Accedido: (15 de abril del 2025)].
- [41] Gndvi. <https://pro.arcgis.com/es/pro-app/3.3/arcpy/image-analyst/gndvi.htm> [Accedido: (15 de abril del 2025)].
- [42] Joaquín Amat Rodrigo. Análisis de componentes principales (principal component analysis, pca) y t-sne, 2017. https://cienciadedatos.net/documentos/35_principal_component_analysis [Accedido: (14 de abril del 2025)].

-
- [43] What is principal component analysis (pca)? <https://www.ibm.com/think/topics/principal-component-analysis> [Accedido: (5 de mayo del 2025)].
- [44] Cómo funciona la regresión ols. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-statistics/how-ols-regression-works.htm> [Accedido: (15 de abril del 2025)].
- [45] Ordinary least squares regression (ols). <https://www.xlstat.com/en/solutions/features/ordinary-least-squares-regression-ols> [Accedido: (5 de mayo del 2025)].
- [46] NASA GSFC. Landslides mapped for the may 2024 brazil floods (planet), 2024. <https://maps.disasters.nasa.gov/arcgis/home/item.html?id=a442900ab36549ffb50cd722307ffa43> [Accedido: (10 de abril del 2025)].
- [47] ¿qué son la erosión y la meteorización? <https://www.nationalgeographic.es/medio-ambiente/que-son-la-erosion-y-la-meteorizacion> [Accedido: (5 de mayo del 2025)].
- [48] Ogbonnaya Igwe. The geotechnical characteristics of landslides on the sedimentary and metamorphic terrains of south-east nigeria, west africa. *Geoenvironmental Disasters*, 2, 12 2015.
- [49] Sentinel (satélite). [https://es.wikipedia.org/wiki/Sentinel_\(sat%C3%A9lite\)](https://es.wikipedia.org/wiki/Sentinel_(sat%C3%A9lite)) [Accedido: (16 de abril del 2025)].
- [50] Estos son nuestros satélites. <https://www.copernicus.eu/es/sobre-copernicus/infraestructura/estos-son-nuestros-satelites> [Accedido: (16 de abril del 2025)].

Anexo

5.1. Imágenes

En la Figura 5.1 se muestra una imagen de los componentes que presenta el satélite Sentinel-2 en su interior.

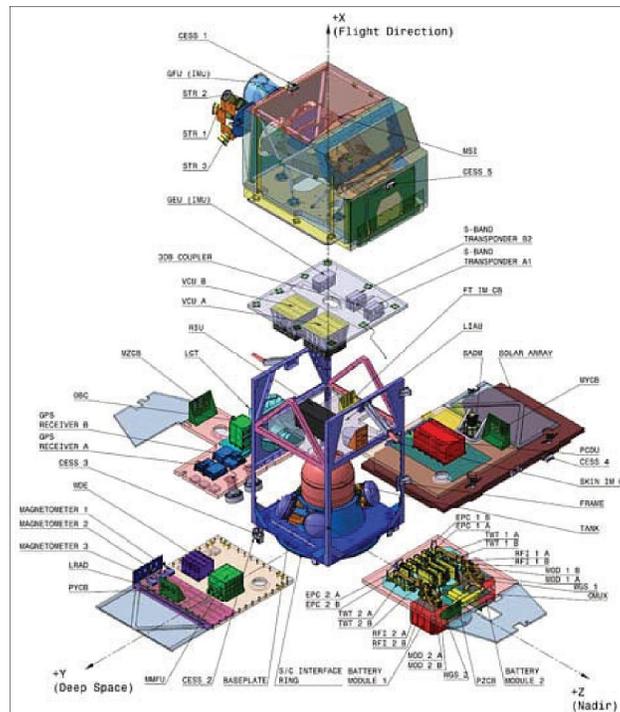


Figura 5.1. Imagen de los componentes del Sentinel-2 [17].

5.2. Tablas

En la Tabla 5.1 se muestra información respecto a la flota completa de satélites Sentinel.

Tabla 5.1. Tabla resumen de los satélites Sentinel, sus objetivos y lanzamientos [49] [50].

Sentinel	Objetivo	Lanzamiento
1	Proporcionar imágenes de radar terrestres y oceánicas.	1A: 3 de abril de 2014 1B: 25 de abril de 2016
2	Proporciona imágenes ópticas terrestres de alta resolución para servicios terrestres, además de ayudar a los servicios de emergencia.	2A: 23 de junio de 2015 2B: 7 de marzo de 2017
3	Facilita datos ópticos, de radar y altimétricos de gran precisión para los servicios marinos y terrestres. Mide variables como la topografía, la temperatura y el color con gran precisión y fiabilidad.	3A: 16 de febrero de 2016 3B: 25 de abril de 2018
4	Proporciona datos de vigilancia de la composición atmosférica. Su objetivo es supervisar en Europa los gases traza y los aerosoles	Previsión de lanzamiento: 2025
5	Proporcionará mediciones precisas de los principales componentes de la atmósfera, como el ozono, el dióxido de nitrógeno, el dióxido de azufre, el monóxido de carbono, el metano y el formaldehído, así como de las características de los aerosoles.	Previsión en 2025
5P	Su objetivo es dar una cobertura complementaria que garantice la continuidad de datos (tras la pérdida del satélite Envisat) hasta el lanzamiento del Sentinel-5.	13 de octubre de 2017
6	Facilitará altimetría de alta precisión para la medición de la altura de la superficie marina mundial, principalmente para la vigilancia del aumento del nivel de los mares, la oceanografía operativa y los estudios climatológicos.	6A: Noviembre de 2020 6B: Previsión en noviembre de 2025

5.3. Algoritmo

El siguiente algoritmo dividido en secciones es el empleado para llegar a los resultados de este trabajo. De forma general, el usuario debe modificar las rutas a los directorios deseados y después ejecutar el código paso a paso como se ha explicado en la sección de desarrollo experimental.

5.3.1. Código para descargar el DEM

Para descargar el DEM se ha empleado el código sugerido por la referencia [32] y que se muestra a continuación.

```

1
2 //DEM PARA ALOS DSM
3
4 var ALOSdsmDEM = ee.Image ('JAXA/ALOS/AW3D30_V1_1');
5 var ALOSdsm = ALOSdsmDEM.select('AVE').clip (geometry);
6 Export.image.toDrive({
7   image: ALOSdsm.select("AVE"),
8   description: 'ALOSdsm_30m',
9   scale: 30,
10  region: geometry});

```

Listing 5.1: Código para descargar el DEM.

5.3.2. Código para cambiar de nombre a los archivos y reescalar las bandas a 10m

Este código accede a las carpetas donde se encuentran las bandas correspondientes a antes y después del evento de lluvias, cambiando su resolución a 10 metros y almacenándolas en una carpeta llamada BANDAS. Almacena las bandas con un nombre más corto como se ha explicado en la sección de desarrollo experimental.

```

1 # CODIGO QUE RENOMBRA LAS BANDAS QUE SE EMPLEAN EN EL TRABAJO
2 # Y CAMBIA LA RESOLUCION A 10 METROS
3
4 import arcpy
5 import os
6
7 # RUTA A LAS IMAGENES DE LAS BANDAS: ESPECIFICAR LA RUTA DESEADA
8 carpetas = [
9     r"D:\TFG\PRUEBA_CODIGO\BANDAS_ANTES", # RUTA A LAS IMAGENES DE LAS
10    BANDAS ANTES
11    r"D:\TFG\PRUEBA_CODIGO\BANDAS_DESPUES" # RUTA A LAS IMAGENES DE LAS
12    BANDAS DESPUES
13 ]
14 carpeta_salida = r"D:\TFG\PRUEBA_CODIGO\BANDAS" # RUTA DE SALIDA: CARPETA
15 DONDE SE ALMACENAN LAS BANDAS
16 arcpy.env.overwriteOutput = True # SE ACTIVA EL ENTORNO ARCPY
17
18 # PARAMETROS DE REPIXELADO
19 resolucion = 10 # METROS (RESOLUCION DESEADA)
20 metodo_resample = "BILINEAR" # METODO ELEGIDO PARA CAMBIAR LA RESOLUCION
21
22 # SE BUSCA TANTO EN LA CARPETA BANDAS_ANTES COMO BANDAS_DESPUES LAS BANDAS
23 for carpeta in carpetas:
24     print(f"\n Procesando carpeta: {carpeta}")
25     arcpy.env.workspace = carpeta
26     lista_rasters = arcpy.ListRasters()
27
28     for raster in lista_rasters:
29         print(f"\nArchivo encontrado: {raster}")
30
31         # PIDE EL NOMBRE QUE SE DESEA PONER A CADA BANDA. NO SE DEBE PONER
32         LA EXTENSION
33         nuevo_nombre = input("Ingresa el nuevo nombre para este archivo (
34         sin extension): ")
35
36         # RUTA DE SALIDA
37         ruta_salida = os.path.join(carpeta_salida, f"{nuevo_nombre}.tif")
38
39         # EJECUTA EL REPIXELADO
40         arcpy.management.Resample(
41             in_raster=raster,
42             out_raster=ruta_salida,
43             cell_size=f"{resolucion} {resolucion}",
44             resampling_type=metodo_resample
45         )

```

```

41
42     print(f" Guardado como: {ruta_salida}")

```

Listing 5.2: Código que repixela las bandas y las guarda con un nuevo nombre.

5.3.3. Código para calcular los índices de imagen

Este código calcula los índices de imagen previos y posteriores al evento de precipitaciones extremas, además calcula también los índices diferencia pre - post.

```

1  # CODIGO QUE CALCULA LOS INDICES DE IMAGEN PREVIOS Y POSTERIORES A LAS
2  # LLUVIAS, ADEMAS DE LA DIFERENCIA ENTRE ELLOS
3  import arcpy
4  import os
5  from arcpy.sa import *
6
7  # Activar Spatial Analyst
8  arcpy.CheckOutExtension("Spatial")
9  arcpy.env.overwriteOutput = True
10
11 # CARPETA DONDE SE ENCUENTRAN LAS BANDAS
12 carpeta = r"D:\TFG\PRUEBA_CODIGO\BANDAS"
13 # CARPETA DE SALIDA
14 carpeta_salida = r"D:\TFG\PRUEBA_CODIGO\INDICES"
15
16 # NOMBRE DE LOS RASTER DE LAS BANDAS
17 # SE DIVIDE ENTRE EL FACTOR DE CONVERSION
18 blue_antes = arcpy.Raster(os.path.join(carpeta, "B2_ANTES.tif"))/10000
19 blue_despues = arcpy.Raster(os.path.join(carpeta, "B2_DESPUES.tif"))/10000
20
21 green_antes = arcpy.Raster(os.path.join(carpeta, "B3_ANTES.tif"))/10000
22 green_despues = arcpy.Raster(os.path.join(carpeta, "B3_DESPUES.tif"))
23                 /10000
24
25 red_antes = arcpy.Raster(os.path.join(carpeta, "B4_ANTES.tif"))/10000
26 red_despues = arcpy.Raster(os.path.join(carpeta, "B4_DESPUES.tif"))/10000
27
28 nir_antes = arcpy.Raster(os.path.join(carpeta, "B8_ANTES.tif"))/10000
29 nir_despues = arcpy.Raster(os.path.join(carpeta, "B8_DESPUES.tif"))/10000
30
31 swir1_antes = arcpy.Raster(os.path.join(carpeta, "B11_ANTES.tif"))/10000
32 swir1_despues = arcpy.Raster(os.path.join(carpeta, "B11_DESPUES.tif"))
33                 /10000
34
35 swir2_antes = arcpy.Raster(os.path.join(carpeta, "B12_ANTES.tif"))/10000
36 swir2_despues = arcpy.Raster(os.path.join(carpeta, "B12_DESPUES.tif"))
37                 /10000
38
39 # ECUACIONES PARA CALCULAR LOS INDICES
40 def calcular_NDMI(nir, swir1):
41     return (nir - swir1) / (nir + swir1)
42
43 def calcular_NDSI(green, swir1):

```

```

41     return (green - swir1) / (green + swir1)
42
43 def calcular_NDVI(nir, red):
44     return (nir - red) / (nir + red)
45
46 def calcular_PRI(green, red):
47     return (green - red) / (green + red)
48
49 def calcular_VARI(green, red, blue):
50     return (green - red) / (green + red + blue)
51
52 def calcular_MIN(swir1, swir2):
53     return swir1 / swir2
54
55 def calcular_MSAVI(nir, red):
56     return ((2 * nir + 1) - ((2 * nir + 1)**2 - 8 * (nir - red))**0.5) / 2
57
58 def calcular_NDGI(nir, green):
59     return (nir - green) / (green + nir)
60
61 # FUNCION PARA GUARDAR RESULTADOS
62 def guardar_resultado(raster, indice, momento):
63     salida = os.path.join(carpeta_salida, f"{indice}_{momento}.tif") #
64     raster.save(salida)
65     print(f" {indice} calculado y guardado en: {salida}")
66
67 # FUNCION PARA CALCULAR TODOS LOS INDICES
68 def calcular_indices(momento):
69     if momento == "ANTES":
70         ndmi = calcular_NDMI(nir_antes, swir1_antes)
71         ndsi = calcular_NDSI(green_antes, swir1_antes)
72         ndvi = calcular_NDVI(nir_antes, red_antes)
73         pri = calcular_PRI(green_antes, red_antes)
74         vari = calcular_VARI(green_antes, red_antes, blue_antes)
75         min_index = calcular_MIN(swir1_antes, swir2_antes)
76         msavi = calcular_MSAVI(nir_antes, red_antes)
77         ndgi = calcular_NDGI(nir_antes, green_antes)
78     elif momento == "DESPUES":
79         ndmi = calcular_NDMI(nir_despues, swir1_despues)
80         ndsi = calcular_NDSI(green_despues, swir1_despues)
81         ndvi = calcular_NDVI(nir_despues, red_despues)
82         pri = calcular_PRI(green_despues, red_despues)
83         vari = calcular_VARI(green_despues, red_despues, blue_despues)
84         min_index = calcular_MIN(swir1_despues, swir2_despues)
85         msavi = calcular_MSAVI(nir_despues, red_despues)
86         ndgi = calcular_NDGI(nir_despues, green_despues)
87
88 # SE GUARDAN LOS INDICES
89     guardar_resultado(ndmi, "NDMI", momento)
90     guardar_resultado(ndsi, "NDSI", momento)
91     guardar_resultado(ndvi, "NDVI", momento)
92     guardar_resultado(pri, "PRI", momento)
93     guardar_resultado(vari, "VARI", momento)

```

```

94     guardar_resultado(min_index, "MIN", momento)
95     guardar_resultado(msavi, "MSAVI", momento)
96     guardar_resultado(ndgi, "NDGI", momento)
97
98     # SE CALCULAN ANTES DE LAS LLUVIAS
99     calcular_indices("ANTES")
100
101     # SE CALCULAN DESPUES DE LAS LLUVIAS
102     calcular_indices("DESPUES")
103
104     print("El calculo de todos los indices ha finalizado correctamente.")
105
106     # LISTA DE INDICES CALCULADOS
107     indices = ["NDVI", "NDMI", "NDSI", "PRI", "VARI", "MIN", "MSAVI", "
108             NDGI"]
109
110     # CARPETA SALIDA DIFERENCIAS
111     carpeta_salida = os.path.join(carpeta, "DIFERENCIAS")
112     if not os.path.exists(carpeta_salida):
113         os.makedirs(carpeta_salida)
114
115     # RESTAR INDICES
116     def restar_indices(indice):
117         path_antes = os.path.join(carpeta, f"{indice}_ANTES.tif")
118         path_despues = os.path.join(carpeta, f"{indice}_DESPUES.tif")
119         # SI NO SE ENCUENTRAN LOS ARCHIVOS NECESARIOS SE PASA AL SIGUIENTE
120         # INDICE
121         if not (os.path.exists(path_antes) and os.path.exists(path_despues
122             )):
123             print(f"Faltan archivos para el indice {indice}. Se omite.")
124             return
125
126         raster_antes = arcpy.Raster(path_antes)
127         raster_despues = arcpy.Raster(path_despues)
128
129         diferencia = raster_antes - raster_despues
130         salida = os.path.join(carpeta_salida, f"{indice}_DIF.tif")
131         diferencia.save(salida)
132
133         print(f"Diferencia {indice} guardada en: {salida}")
134
135     # EJECUTAR PARA TODOS LOS INDICES
136     for indice in indices:
137         restar_indices(indice)
138
139     print("Calculo de diferencias completado.")

```

Listing 5.3: Código que calcula los índices de imagen previos y posteriores además de la diferencia.

5.3.4. Código para almacenar valores de los índices en el mapa

Previamente a utilizar este código se debe crear manualmente el mapa de deslizamientos a partir del *groundtruth* y añadir la malla de puntos de no deslizamientos. Además, en la tabla de atributos se debe crear una columna denominada DESLIZAMIENTOS, donde los puntos en los que hay desli-

zamiento valdrán 1 y en los que no 0.

```

1 import arcpy
2 import os
3
4 # SE DEFINE LA RUTA A LOS MAPAS DE DESLIZAMIENTOS
5 ruta_mapa_deslizamientos = r"D:\TFG\PRUEBA_CODIGO\PRUEBA_CODIGO.gdb"
6 # SE DEFINE LA RUTA A LOS INDICES
7 ruta_indices = r"D:\TFG\PRUEBA_CODIGO\INDICES"
8
9 # SE ALMACENAN LOS INDICES
10 indices_antes = [os.path.join(ruta_indices, f"{indice}_ANTES.tif") for
    indice in ["NDMI", "NDSI", "NDVI", "PRI", "VARI", "CMI", "MSAVI", "
    GNDVI"]]
11 indices_despues = [os.path.join(ruta_indices, f"{indice}_DESPUES.tif") for
    indice in ["NDMI", "NDSI", "NDVI", "PRI", "VARI", "CMI", "MSAVI", "
    GNDVI"]]
12 indices_dif = [os.path.join(ruta_indices, f"{indice}_DIF.tif") for indice
    in ["NDMI", "NDSI", "NDVI", "PRI", "VARI", "CMI", "MSAVI", "GNDVI"]]
13
14 # MAPAS DE DESLIZAMIENTOS
15 mapas_puntos = {
16     "ANTES": os.path.join(ruta_mapa_deslizamientos, "
    DESLIZAMIENTOS_MUESTREO_ANTES"),
17     "DESPUES": os.path.join(ruta_mapa_deslizamientos, "
    DESLIZAMIENTOS_MUESTREO_DESPUES"),
18     "DIF": os.path.join(ruta_mapa_deslizamientos, "
    DESLIZAMIENTOS_MUESTREO_DIF")
19 }
20
21 # SE VERIFICA SI LOS MAPAS EXISTEN
22 for periodo, mapa in mapas_puntos.items():
23     if not arcpy.Exists(mapa):
24         raise FileNotFoundError(f"La capa de puntos no existe: {mapa}")
25
26 # EXTRACT MULTI VALUES TO POINTS
27 for periodo, mapa in mapas_puntos.items():
28     indices = indices_antes if periodo == "ANTES" else indices_despues if
    periodo == "DESPUES" else indices_dif
29     arcpy.sa.ExtractMultiValuesToPoints(mapa, indices, "BILINEAR")
30     print(f"Extraccion completada para {mapa} ({periodo})")

```

Listing 5.4: Código que almacena los valores de los índices en el mapa.

5.3.5. Código para realizar OLS

Ejecutando este código se realizan todos los análisis OLS simultáneamente.

```

1 #ANALSIIS OLS
2 arcpy.env.workspace = r"D:\TFG\PRUEBA_CODIGO\PRUEBA_CODIGO.gdb"
3 print("Realizando ANALISIS OLS antes de las lluvias")
4 arcpy.stats.OrdinaryLeastSquares("DESLIZAMIENTOS_MUESTREO_ANTES", "Id", "
    antes_OLS.shp", "DESLIZAMIENTOS",

```

```

5         "NDMI_ANTES;NDSI_ANTES;NDVI_ANTES;
        PRI_ANTES;VARI_ANTES;CMI_ANTES;MSAVI_ANTES;GNDVI_ANTES",
6         "antes_olsCoefTab.dbf", "antes_olsDiagTab
        .dbf","antes_report")
7 print("Realizando ANALISIS OLS despues de las lluvias")
8 arcpy.stats.OrdinaryLeastSquares("DESLIZAMIENTOS_MUESTREO_DESPUES", "Id",
        "despues_OLS.shp", "DESLIZAMIENTOS",
9         "NDMI_despues;NDSI_despues;NDVI_despues;
        PRI_despues;VARI_despues;CMI_despues;MSAVI_despues;GNDVI_despues",
10        "despues_olsCoefTab.dbf", "
        despues_olsDiagTab.dbf", "antes_report")
11 print("Realizando ANALISIS OLS diferencia")
12 arcpy.stats.OrdinaryLeastSquares("DESLIZAMIENTOS_MUESTREO_DIF", "Id", "
        dif_OLS.shp", "DESLIZAMIENTOS",
13        "NDMI_dif;NDSI_dif;NDVI_dif;PRI_dif;
        VARI_dif;CMI_dif;MSAVI_dif;GNDVI_dif",
14        "dif_olsCoefTab.dbf", "dif_olsDiagTab.dbf
        ", "antes_report")

```

Listing 5.5: Código que realiza el análisis OLS.

5.3.6. Código para realizar PCA

El siguiente código calcula los análisis PCA que se han empleado en este trabajo. Aunque se presentan en el mismo código, se recomienda ejecutar cada análisis por separado, ya que llevan mucho tiempo de ejecución.

```

1 #ANALISIS PCA
2 import arcpy
3 from arcpy import env
4 from arcpy.sa import *
5
6 arcpy.env.workspace = r"D:\TFG\PRUEBA_CODIGO\INDICES"
7 print("Realizando ANALISIS PCA antes de las lluvias")
8 PCA_antes = PrincipalComponents(["NDMI_antes.tif", "NDSI_antes.tif", "
        NDVI_antes.tif", "PRI_antes.tif", "VARI_antes.tif", "CMI_antes.tif",
9 "MSAVI_antes.tif", "GNDVI_antes.tif"], 8,"antes_PCA.txt")
10 PCA_antes.save(r"D:\TFG\PRUEBA_CODIGO\antes_PCA_output.tif")
11
12
13 print("Realizando ANALISIS PCA despues de las lluvias")
14 PCA_despues = PrincipalComponents(["NDMI_despues.tif", "NDSI_despues.tif",
        "NDVI_despues.tif", "PRI_despues.tif", "VARI_despues.tif", "
        CMI_despues.tif",
15 "MSAVI_despues.tif", "GNDVI_despues.tif"], 8,"despues_PCA.txt")
16 PCA_despues.save(r"D:\TFG\PRUEBA_CODIGO\despues_PCA_output.tif")
17
18
19 print("Realizando ANALISIS PCA diferencia")
20 PCA_dif = PrincipalComponents(["NDMI_dif.tif", "NDSI_dif.tif", "NDVI_dif.
        tif", "PRI_dif.tif", "VARI_dif.tif", "CMI_dif.tif",
21 "MSAVI_dif.tif", "GNDVI_dif.tif"], 8,"dif_PCA.txt")
22 PCA_dif.save(r"D:\TFG\PRUEBA_CODIGO\dif_PCA_output.tif")

```

```

23
24 print("Realizando ANALISIS PCA topografico")
25 PCA_topografico = PrincipalComponents(["geo6ag_Clip_Po_Proj_Resample", "
      ALOSDSM_30m_Project_Resample_10m", "VG_REG_FITO_Cl_Proj_Resample", "
26      "Aspect_ALOSDSM", "Slope_ALOSDSM" ], 5, "
      topografico_PCA.txt")
27 PCA_topografico.save(r"D:\TFG\PRUEBA_CODIGO\topografico_PCA_output.tif")
28 print("Análisis PCA finalizado")

```

Listing 5.6: Código de análisis PCA.

5.4. Análisis PCA

Tabla 5.2. Matriz de Covarianza de las variables topográficas.

Capa	GEO	DEM	VEG	ASPECT	SLOPE
GEO	-0,88945	-264,85642	-1,27406	-63,49532	-8,24622
DEM	-264,85642	78717,28183	98,20471	3943,80547	926,36395
VEG	-1,27406	98,20471	2,81600	-8,91533	-1,87859
ASPECT	-63,49532	3943,80547	-8,91533	12855,31041	464,16192
SLOPE	-8,24622	926,36395	-1,87859	464,16192	158,25989

Tabla 5.3. Matriz de Correlación de las variables topográficas.

Capa	GEO	DEM	VEG	ASPECT	SLOPE
GEO	1,00000	-1,00095	-0,80503	-0,59380	-0,69504
DEM	-1,00095	1,00000	0,20858	0,12398	0,26246
VEG	-0,80503	0,20858	1,00000	-0,04686	-0,08899
ASPECT	-0,59380	0,12398	-0,04686	1,00000	0,32542
SLOPE	-0,69504	0,26246	-0,08899	0,32542	1,00000

Tabla 5.4. Matriz de autovalores y autovectores correspondiente a la topografía de la zona

PC	1	2	3	4	5
Autovalores	78965,13685	12633,53411	133,54777	2,85842	-2,29847
Autovectores					
Capa					
GEO	-0,00340	-0,00378	-0,02528	-0,21149	0,97704
DEM	0,99814	-0,06001	-0,01016	-0,00208	0,00253
VEG	0,00123	-0,00118	-0,01946	0,97728	0,21104
ASPECT	0,05963	0,99766	-0,03344	-0,00022	0,00315
SLOPE	0,01208	0,03267	0,99888	0,01366	0,02897

Tabla 5.5. Tabla de porcentaje y acumulación de autovalores correspondiente a la topografía de la zona de estudio.

PC	Autovalor	% de Autovalores	Acumulación
1	78965,13685	86,0817	86,0817
2	12633,53411	13,7721	99,8538
3	133,54777	0,1456	99,9994
4	2,85842	0,0031	100,0025
5	-2,29847	-0,0025	100,0000

Tabla 5.6. Matriz de Covarianza del análisis PCA posterior de las lluvias.

Capa (índice)	NDMI	NDSI	NDVI	PRI	VARI	CMI	MSAVI	GNDVI
NDMI	0,01498	0,00369	0,01123	0,00229	0,00153	0,00670	0,00995	0,00955
NDSI	0,00369	0,01648	-0,01628	-0,00437	-0,00322	-0,01146	-0,01149	-0,01215
NDVI	0,01123	-0,01628	0,03243	0,00846	0,00607	0,02137	0,02480	0,02493
PRI	0,00229	-0,00437	0,00846	0,00272	0,00195	0,00556	0,00640	0,00602
VARI	0,00153	-0,00322	0,00607	0,00195	0,00141	0,00399	0,00457	0,00431
CMI	0,00670	-0,01146	0,02137	0,00556	0,00399	0,01744	0,01651	0,01646
MSAVI	0,00995	-0,01149	0,02480	0,00640	0,00457	0,01651	0,02263	0,01925
GNDVI	0,00955	-0,01215	0,02493	0,00602	0,00431	0,01646	0,01925	0,01965

Tabla 5.7. Matriz de Correlación del análisis PCA posterior a las lluvias.

Capa (índice)	NDMI	NDSI	NDVI	PRI	VARI	CMI	MSAVI	GNDVI
NDMI	1,00000	0,23476	0,50960	0,35891	0,33411	0,41464	0,54014	0,55692
NDSI	0,23476	1,00000	-0,70436	-0,65227	-0,66950	-0,67577	-0,59505	-0,67512
NDVI	0,50960	-0,70436	1,00000	0,90076	0,89800	0,89865	0,91556	0,98786
PRI	0,35891	-0,65227	0,90076	1,00000	0,99937	0,80816	0,81534	0,82409
VARI	0,33411	-0,66950	0,89800	0,99937	1,00000	0,80479	0,81061	0,81983
CMI	0,41464	-0,67577	0,89865	0,80816	0,80479	1,00000	0,83103	0,88921
MSAVI	0,54014	-0,59505	0,91556	0,81534	0,81061	0,83103	1,00000	0,91268
GNDVI	0,55692	-0,67512	0,98786	0,82409	0,81983	0,88921	0,91268	1,00000

Tabla 5.8. Matriz de autovalores y autovectores correspondiente al análisis PCA después de las lluvias.

PC	1	2	3	4	5	6	7	8
Autovalores	0,10152	0,01945	0,00311	0,00237	0,00125	0,00003	0,00000	0,00000
Autovectores Capa (índice)								
NDMI	0,19528	-0,75158	0,09029	-0,17213	0,12899	-0,56495	0,14992	-0,03047
NDSI	-0,28427	-0,64513	0,06889	0,18748	-0,24222	0,61784	-0,14561	0,03878
NDVI	0,56099	0,00065	0,02255	-0,39886	-0,27149	0,40209	0,52733	-0,11054
PRI	0,14411	0,03185	-0,00829	-0,02121	-0,68463	-0,23536	-0,44755	-0,50328
VARI	0,10331	0,03021	-0,00956	-0,01743	-0,49247	-0,17595	-0,06542	0,84277
CMI	0,38393	0,06114	0,72950	0,56040	0,05035	0,00947	0,00335	0,00228
MSAVI	0,44630	-0,10341	-0,67343	0,57555	0,06829	0,02576	0,00475	-0,00108
GNDVI	0,43395	-0,05074	0,02757	-0,36064	0,36407	0,22432	-0,68821	0,14763

Tabla 5.9. Porcentaje y Acumulación de Autovalores después de las lluvias.

PC	Autovalor	% de Autovalores	Acumulación
1	0,10152	79,4795	79,4795
2	0,01945	15,2249	94,7044
3	0,00311	2,4381	97,1424
4	0,00237	1,8547	98,9971
5	0,00125	0,9800	99,9771
6	0,00003	0,0199	99,9970
7	0,00000	0,0028	99,9998
8	0,00000	0,0002	100,0000

En último lugar, se muestran los resultados del análisis PCA de la diferencia pre-post.

Tabla 5.10. Matriz de covarianza diferencia.

Capa (índice)	NDMI	NDSI	NDVI	PRI	VARI	CMI	MSAVI	GNDVI
NDMI	0,00455	0,00456	-0,00096	-0,00054	-0,00044	-0,00121	-0,00015	-0,00028
NDSI	0,00456	0,01296	-0,01147	-0,00340	-0,00253	-0,00795	-0,00797	-0,00816
NDVI	-0,00096	-0,01147	0,01390	0,00428	0,00314	0,00900	0,01021	0,00992
PRI	-0,00054	-0,00340	0,00428	0,00175	0,00128	0,00285	0,00318	0,00267
VARI	-0,00044	-0,00253	0,00314	0,00128	0,00094	0,00209	0,00233	0,00195
CMI	-0,00121	-0,00795	0,00900	0,00285	0,00209	0,00735	0,00665	0,00634
MSAVI	-0,00015	-0,00797	0,01021	0,00318	0,00233	0,00665	0,00805	0,00729
GNDVI	-0,00028	-0,00816	0,00992	0,00267	0,00195	0,00634	0,00729	0,00744

Tabla 5.11. Matriz de correlación diferencia

Capa (índice)	NDMI	NDSI	NDVI	PRI	VARI	CMI	MSAVI	GNDVI
NDMI	1,00000	0,59353	-0,12046	-0,19236	-0,21408	-0,20989	-0,02464	-0,04891
NDSI	0,59353	1,00000	-0,85442	-0,71360	-0,72765	-0,81428	-0,78053	-0,83050
NDVI	-0,12046	-0,85442	1,00000	0,86786	0,86988	0,89006	0,96529	0,97483
PRI	-0,19236	-0,71360	0,86786	1,00000	0,99930	0,79443	0,84678	0,73778
VARI	-0,21408	-0,72765	0,86988	0,99930	1,00000	0,79862	0,84747	0,73979
CMI	-0,20989	-0,81428	0,89006	0,79443	0,79862	1,00000	0,86432	0,85669
MSAVI	-0,02464	-0,78053	0,96529	0,84678	0,84747	0,86432	1,00000	0,94180
GNDVI	-0,04891	-0,83050	0,97483	0,73778	0,73979	0,85669	0,94180	1,00000

Tabla 5.12. Porcentaje y Acumulación de Autovalores diferencia.

PC	Autovalor	% de Autovalores	Acumulación
1	0,04711	82,7313	82,7313
2	0,00709	12,4517	95,1829
3	0,00136	2,3970	97,5799
4	0,00102	1,7993	99,3793
5	0,00033	0,5859	99,9652
6	0,00002	0,0282	99,9934
7	0,00000	0,0059	99,9992
8	0,00000	0,0008	100,0000

Tabla 5.13. Matriz de autovalores y autovectores correspondiente a la diferencia de índices pre-post.

PC	1	2	3	4	5	6	7	8
Autovalores	0,04711	0,00709	0,00136	0,00102	0,00033	0,00002	0,00000	0,00000
Autovectores Capa (índice)								
NDMI	-0,08148	0,76872	0,10227	0,16124	-0,09860	0,58968	-0,08778	-0,02874
NDSI	-0,48323	0,50773	-0,28103	-0,11713	-0,02414	-0,63938	0,07178	0,03814
NDVI	0,53499	0,20218	0,12350	-0,21059	-0,41710	-0,31288	-0,58051	-0,06665
PRI	0,16401	0,03909	-0,32672	-0,54957	-0,23876	0,17695	0,43237	-0,53623
VARI	0,12060	0,02067	-0,23558	-0,39726	-0,16442	0,17338	0,14134	0,83345
CMI	0,36466	0,03661	-0,75026	0,54998	0,00069	-0,01766	-0,00135	0,00044
MSAVI	0,39252	0,26194	0,01262	-0,26407	0,83738	-0,07846	-0,00760	-0,00278
GNDVI	0,38099	0,19621	0,41232	0,28963	-0,17457	-0,27880	0,66571	0,10527

5.5. Análisis OLS

Tabla 5.14. Resultados estadísticos de las variables del análisis OLS después del evento de lluvias.

Variable	Coficiente	StdError	t-Statistic	Probabilidad	VIF
Ordenada	-0,536104	0,064960	-8,252776	0,000000	-
NDMI	10,210486	0,713125	14,317947	0,000000	787,18
NDSI	-10,108060	0,768104	-13,159747	0,000000	366,18
NDVI	-2,765622	1,441003	-1,919233	0,054974	>1000,0
PRI	-61,575310	4,826873	-12,756771	0,000000	>1000,0
VARI	90,861066	7,752622	11,720043	0,000000	>1000,0
CMI	0,450320	0,058335	7,719598	0,000000	5,08
MSAVI	-4,036229	0,182060	-22,169816	0,000000	55,11
GNDVI	-4,750928	1,856530	-2,559036	0,010499	>1000,0

Tabla 5.15. Resultados estadísticos del modelo OLS para despues del evento de lluvias.

Parámetro	Valor
Número de Observaciones	12420
R cuadrado	0,080935
R cuadrado ajustado	0,080342

Por último, se muestran los resultados obtenidos para la diferencia.

Tabla 5.16. Resultados del análisis OLS para diferencias de imagen.

Variable	Coficiente	StdError	t-Statistic	Probabilidad	VIF
Ordenada	0,086879	0,004196	20,7050	0,000000	-
NDMI	17,212140	0,910921	18,8953	0,000000	365,1575
NDSI	-16,812406	0,972072	-17,2954	0,000000	150,8465
NDVI	-10,850379	1,054871	-10,2860	0,000000	782,5045
PRI	101,741023	3,491580	29,1390	0,000000	>1000,0
VARI	-124,838811	5,201535	-24,0004	0,000000	>1000,0
CMI	1,249794	0,074403	16,7975	0,000000	2,6073
MSAVI	-4,499989	0,307909	-14,6147	0,000000	46,9639
GNDVI	-5,024257	1,614860	-3,1113	0,001882	>1000,0

Tabla 5.17. Resultados estadísticos del modelo OLS para la diferencia.

Parámetro	Valor
Número de Observaciones	12420
R cuadrado	0,2525
R cuadrado ajustado	0,2521