

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO FIN DE GRADO

PROCESADO DE DATOS MULTIESPECTRALES PARA EL ANÁLISIS DE LA CUBIERTA FORESTAL DE LA PALMA

Titulación: Grado en Ingeniería en Tecnologías de Telecomunicación

Mención: Sistemas de Telecomunicación

Autor: Jerónimo Trujillo Metsola

Tutores: Dionisio Rodríguez Esparragón
Francisco Javier Marcello Ruiz

Fecha: Junio 2025

Agradecimientos

Quiero expresar mi agradecimiento a mi familia, por apoyarme incondicionalmente y estar a mi lado durante todo el camino. También me gustaría agradecer especialmente a mis tutores, Javier y Dionisio, por haberme orientado de la mejor manera posible y brindarme todos los conocimientos necesarios para poder llevar a cabo este Trabajo de Fin de Grado con éxito. Por último y no por ello menos importante, a mis amigos y compañeros por el apoyo en momentos complicados y los momentos de desconexión que me han permitido mantener un equilibrio.

Reconocimientos

Las imágenes PlanetScope se han utilizado en el marco del acuerdo de Education and Research Licensing de la University of Pavia, a la que se le reconoce su apoyo.

Parte de este trabajo se ha desarrollado en el contexto del proyecto SPIP2022-02897, “Análisis del cambio global en los parques nacionales macaronésicos mediante teledetección multiplataforma y nuevas metodologías de procesado de datos”, financiado por el Organismo Autónomo Parques Nacionales.

Resumen

La Isla de La Palma ha sufrido dos eventos extremos que han causado daños importantes en su cubierta forestal: la erupción volcánica de 2021 y el incendio forestal de 2023. Debido a esto, se hace imprescindible realizar una monitorización del estado de la cubierta forestal de la isla. La teledetección se ha consolidado como una herramienta esencial para la monitorización del medio ambiente presentándose como herramienta fundamental para este propósito, gracias a su capacidad para captar variaciones espectrales asociadas al estado de salud de la vegetación.

En el presente Trabajo de Fin de Grado se lleva a cabo un análisis de datos multiespectrales a través del uso de las imágenes proporcionadas por el satélite Sentinel-2. Para analizar la evolución de la vigorosidad de la vegetación a lo largo de los años, se han empleado combinaciones de bandas espectrales que permiten cuantificar el vigor y la densidad de la cubierta vegetal. Estos índices de vegetación son esenciales para evaluar el estado de los ecosistemas utilizando datos satelitales.

A través del análisis multitemporal de estos índices se ha logrado identificar áreas con signos de deterioro o pérdida de vegetación, así como zonas de regeneración de la vegetación. Este Trabajo de Fin de grado demuestra el potencial de la teledetección como herramienta clave a la hora de realizar un seguimiento de la cubierta forestal y proporcionar respuestas antes catástrofes naturales.

Abstract

The island of La Palma has suffered two extreme events that have caused significant damage to its forest cover: the 2021 volcanic eruption and the 2023 forest fire. Because of this, monitoring the state of the island's forest cover is essential. Remote sensing has established itself as an essential tool for environmental monitoring, presenting itself as a fundamental tool for this purpose, thanks to its ability to capture spectral variations associated with the health of vegetation.

In this Final Degree Project, a multispectral data analysis is carried out using data provided by the Sentinel-2 satellite. To analyze the evolution of vegetation vigor over the years, combinations of spectral bands were used to quantify the vigor and density of vegetation cover. These vegetation indices are essential for assessing the state of ecosystems using satellite data.

Through the multitemporal analysis of these indices, it has been possible to identify areas with signs of vegetation deterioration or loss, as well as areas of vegetation regeneration. This Final Degree Project demonstrates the potential of remote sensing as a key tool for monitoring forest cover and providing responses to natural disasters.

Índice

1. Introducción.....	1
1.1. Antecedentes	1
1.2. Objetivos.....	2
2. Sistemas de Teledetección	5
2.1. Introducción a la Teledetección.....	5
2.2. Firma espectral.....	6
2.3. Sistema satelital Sentinel-2.....	8
3. Índices de vegetación.....	11
3.1. Índices de banda ancha	11
3.1.1. Normalized Difference Vegetation Index.....	11
3.1.2. Enhanced Vegetation Index.....	12
3.1.3. Soil Adjusted Vegetation Index	12
3.1.4. Modified Soil Adjusted Vegetation Index 2	12
3.1.5. Green Normalized Difference Vegetation Index.....	13
3.1.6. Simple Ratio.....	13
3.1.7. Modified Simple Ratio.....	13
3.1.8. Global Environmental Monitoring Index	14
3.1.9. Wide Dynamic Range Vegetation Index.....	14
3.1.10. WorldView Improved Vegetative Index	14
3.2. Índices de banda estrecha	15
3.2.1. Atmospherically Resistant Vegetation Index	15
3.2.2. Modified Chlorophyll Absorption in Reflectance Index 2.....	15
3.2.3. Transformed Chlorophyll Absorption in Reflectance Index	16
3.2.4. Modified Triangular Vegetation Index 2	16
3.2.5. Red Edge Normalized Difference Vegetation Index	17
3.2.6. Red Edge Position Index.....	17
3.3. Índices de Pigmentos y Eficiencia de Uso de la Luz	18

3.3.1. Structure Insensitive Pigment Index	18
3.3.2. Carotenoid Chlorophyll Index	18
3.3.3. Anthocyanin Reflectance Index 2.....	19
3.3.4. Carotenoid Reflectance Index 2.....	19
3.4. Índices de senescencia y estrés vegetal	20
3.4.1. Plant Senescence Reflectance Index	20
3.4.2. Normalized Pigment Chlorophyll Ratio Index.....	20
3.5. Índices de humedad y estrés hídrico	21
3.5.1. Disease Water Stress Index	21
3.5.2. Normalized Burn Ratio	21
3.5.3. Moisture Stress Index.....	21
3.6. Índices específicos de cobertura forestal	22
3.6.1. Forest Condition Index 1.....	22
3.6.2. Forest Condition Index 2.....	22
4. Estudio y análisis de cubierta forestal de La Palma	23
4.1. Zona de estudio	23
4.2. Datos utilizados	25
4.2.1. Generación de la máscara de nubes	28
4.2.2. Fusión de imágenes	32
4.3. Análisis de índices y propuesta de nuevo índice espectral compuesto	33
4.3.1. Análisis estadístico de Índices de Vegetación	34
4.3.2. Propuesta de Índice de Salud Forestal Sentinel-2.....	47
4.4. Análisis de la cubierta forestal	48
4.4.1. Creación del Índice de Salud Forestal Sentinel-2.....	48
4.4.2. Evaluación de la salud forestal durante el transcurso de la serie temporal	53
4.4.3. Mapas de cambio	57
4.4.4. Análisis con respecto a la distancia y orientación al foco eruptivo	67
5. Conclusiones	71

5.1. Revisión de los objetivos	71
5.2. Conclusiones del análisis de los resultados.....	72
5.3. Líneas futuras.....	74
Bibliografía	I
Presupuesto	V
P.1. Recursos humanos	V
P.2. Recursos materiales	V
P.2.1. Recursos hardware.....	V
P.2.2. Recursos software.....	VI
P.3. Imágenes satelitales	VII
P.4. Redacción del documento	VII
P.5. Material fungible	VIII
P.6. Derechos por el visado del COITT	VIII
P.7. Gastos de tramitación y de envío	VIII
P.8. Impuestos	VIII
Anexos	X
A.1. Anexo 1: Selección de imágenes Sentinel-2.....	XI
A.2. Anexo 2: Fusión de imágenes Sentinel-2.....	XL
A.2.1. Código desarrollado.....	XL
A.2.2. Fusiones de imágenes.....	XLIII
A.3. Anexo 3: Índices de vegetación	LXXII
A.3.1. Generación de los índices de vegetación.....	LXXII
A.3.2. Extracción de datos de índices de vegetación para cada ROI	LXXVI
A.4. Anexo 4: Análisis de índices de vegetación	LXXVII
A.4.1. Diagramas correspondientes a la imagen del 2022.....	LXXVII
A.4.2. Diagramas correspondientes a la imagen del 2023.....	LXXIX
A.5. Anexo 5: Serie temporal de los mejores índices de vegetación.....	LXXXII
A.5.1. Wide Dynamic Range Vegetation Index	LXXXII

A.5.2. Red Edge Normalized Difference Vegetation Index	LXXXVIII
A.5.3. Chlorophyll Carotenoid Index.....	XCIV
A.5.4. Disease Water Stress Index	C
A.5.5. Normalized Burn Ratio	CVI

Índice de figuras

Figura 1: Sistema de Teledetección [16].....	6
Figura 2: Reflectancia espectral de diferentes tipos de vegetación verde [19].....	7
Figura 3: Introducción sobre el programa Copernicus.	9
Figura 4: Bandas Sentinel-2 [24].	10
Figura 5: Diagrama de bloques general.	23
Figura 6: Cartografía de con la vegetación forestal mayoritaria de La Palma: (a) foto de pinares y laurisilvas, (b) Gobierno de Canarias (2021), (c) Cabildo de la Palma (PIOLP 2020), (d) Mapa Forestal Español (2018), (e) SIOSE de Alta Resolución (2017), y (f) Corine Land Cover + BackBone (2021).	25
Figura 7: Gráfico representando la diferencia de días entre las imágenes.....	28
Figura 8: Diagrama de flujo general.....	28
Figura 9: Máscara de nubes SCL: (a) 15/10/2020 y (b) 16/08/2020.....	29
Figura 10: Comparación entre máscaras: (a) Máscara SCL 16/08/2020 y (b) Máscara final 16/08/2020.	31
Figura 11: Diagrama de flujo de la estructura if-else.	32
Figura 12: Análisis de índices de vegetación y creación del ISF-S2.	33
Figura 13: ROIs de vegetación sana de 2022: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.	34
Figura 14: ROIs de vegetación quemada de 2022: (a) ROIs en RGB y (b) ROIs en gris monobanda.	35
Figura 15: ROIs de suelo desnudo de 2022: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.	35
Figura 16: ROIs de suelo construido de 2022: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.	36
Figura 17: ROIs de vegetación sana de 2023: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.	36

Figura 18: ROIs de vegetación quemada de 2023: (a) ROIs en RGB y (b) ROIs en gris monobanda.....	37
Figura 19: ROIs de suelo desnudo de 2023: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.....	37
Figura 20: ROIs de suelo construido de 2023: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.....	37
Figura 21: Índices de vegetación aplicados a la imagen del 2023.....	41
Figura 22: Diagrama de caja y bigote del NDVI para 2022.	42
Figura 23: Diagrama de caja y bigote del NPCR para 2022.	42
Figura 24: Gráfico que muestra la separabilidad entre vegetación sana y quemada para cada índice.	42
Figura 25: Diagrama de caja y bigote del WDRVI para 2022.	43
Figura 26: Diagrama de caja y bigote del RENDVI para 2022.	44
Figura 27: Diagrama de caja y bigote del CCI para 2022.	44
Figura 28: Diagrama de caja y bigote del DWSI para 2022.....	44
Figura 29: Diagrama de caja y bigote del NBR para 2022.	45
Figura 30: Diagrama de caja y bigote del WDRVI para 2023.	45
Figura 31: Diagrama de caja y bigote del RENDVI para 2023.	45
Figura 32: Diagrama de caja y bigote del CCI para 2023.	46
Figura 33: Diagrama de caja y bigote del DWSI para 2023.....	46
Figura 34: Diagrama de caja y bigote del NBR para 2023.	46
Figura 35: Parcelas seleccionadas para evaluar los índices: a) píxeles elegidos y b) mapa de vegetación del Gobierno de Canarias de 2021.....	47
Figura 36: Parcelas seleccionadas para el análisis detallado.	49
Figura 37: Píxel elegido para la parcela 32.	49
Figura 38: Píxel elegido de la parcela 28.	50
Figura 39: Píxel elegido de la parcela 34.	50
Figura 40: Píxel elegido de la parcela 35.	51
Figura 41: Píxel elegido de la parcela 41.	51
Figura 42: Píxel elegido de la parcela 42.	52
Figura 43: ISF-S2 para parcela 28 (Incendio).....	52
Figura 44: ISF-S2 para parcela 32 (Castaño).	52
Figura 45: ISF-S2 para parcela 34 (Fayal-brezal).....	53
Figura 46: ISF-S2 para parcela 35 (Pinares).....	53
Figura 47: ISF-S2 para parcela 41 (Laurisilva).	53

Figura 48: ISF-S2 para parcela 42 (Volcán).	53
Figura 49: Evolución de la vegetación en la zona del incendio.....	54
Figura 50: Evolución de la vegetación post-incendio.	54
Figura 51: Evolución del castaño (zona este).....	54
Figura 52: Evolución del fayal-brezal (zona norte).....	54
Figura 53: Evolución de los pinares (zona sur).	54
Figura 54: Evolución de la laurisilva (zona noreste).....	54
Figura 55: Evolución de la vegetación en la zona de la erupción volcánica.	55
Figura 56: Evolución de la vegetación post-erupción.....	55
Figura 57: Paleta de colores ISF-S2.....	57
Figura 58: ISF-S2 para los meses seleccionados.	59
Figura 59: Procedimiento para generar mapas de cambio: (a) Febrero, (b) Junio y (c) Diciembre	61
Figura 60: Mapas de cambio del mes de febrero: (a) Promedio febrero 2019, 2020 y 2021, (b) Cambio en febrero 2022, (c) Cambio en febrero 2023 y (d) Cambio en febrero 2024.	61
Figura 61: Mapas de cambio del mes de junio: (a) Promedio junio 2019, 2020 y 2021, (b) Cambio en junio 2022, (c) Cambio en junio 2023 y (d) Cambio en junio 2024.	62
Figura 62: Mapas de cambio del mes de diciembre: (a) Promedio diciembre 2019 y 2020, (b) Cambio en diciembre 2022, (c) Cambio en diciembre 2023 y (d) Cambio en diciembre 2024.	63
Figura 63: Zona central degradación de salud forestal: (a) Mapa de cambios 02/2024, (b) Imagen satelital pre-erupción Sentinel-2 en RGB y (c) Imagen satelital post-erupción Sentinel-2 en RGB.	64
Figura 64: Zona sur degradación de salud forestal: (a) Mapa de cambios 12/2024, (b) Imagen satelital pre-erupción Sentinel-2 en RGB y (c) Imagen satelital post-erupción Sentinel-2 en RGB.	65
Figura 65: Imagen satelital Snetinel-2 de diciembre de 2024.	65
Figura 66: Paleta de colores para mapa de cambios de junio de 2024: (a) Paleta de colores y (b) Histograma.	66
Figura 67: Mapa de cambios: (a) Cambio en junio 2024 con paleta de colores y (b) Mapa de vegetación del Gobierno de Canarias 2021.....	66
Figura 68: Análisis de los efectos de la erupción volcánica: (a) Mapa de cambios de junio de 2024 y (b) Parcelas elegidas a diferentes distancias y orientaciones.	67
Figura 69: Análisis de los efectos de la erupción en la zona Este alejada del volcán.....	67
Figura 70: Análisis de los efectos de la erupción en la zona Norte cercana del volcán.	68

Figura 71: Análisis de los efectos de la erupción en la zona Sur cercana del volcán.	68
Figura 72: Análisis de los efectos de la erupción en la zona Sur alejada del volcán.....	68

Índice de tablas

Tabla 1: Bandas Sentinel-2 [23].	9
Tabla 2: Fechas de captura de imágenes.	27
Tabla 3: Diferencia de días entre las imágenes con respecto al mes anterior.	27
Tabla 4: Banda Scene Classification Layer (SCL).	29
Tabla P.1: Coste de recursos humanos en función del número de horas invertidas	V
Tabla P.2: Coste total de recursos hardware.	VI
Tabla P.3: Coste de amortización de recursos hardware.	VI
Tabla P.4: Coste total de recursos software.	VII
Tabla P.5: Bandas Sentinel-2 [23].	VII
Tabla P.6: Coste total de las imágenes satelitales.	VII
Tabla P.7: Coste total previo al visado del COITT.	VIII
Tabla P.8: Presupuesto total del Trabajo de Fin de Grado.	IX

Lista de acrónimos

IV: *Índices de Vegetación*

SWIR: *Short-Wave Infrared*

NIR: *Near Infrared*

NDVI: *Normalized Difference Vegetation Index*

EVI: *Enhanced Vegetation Index*

SAVI: *Soil Adjusted Vegetation Index*

MSAVI2: *Modified Soil Adjusted Vegetation Index 2*

GNDVI: *Green Normalized Difference Vegetation Index*

SR: *Simple Ratio*

MSR: *Modified Simple Ratio*

GEMI: *Global Environmental Monitoring Index*

WDRVI: *Wide Dynamic Range Vegetation Index*

WVVI: *WorldView Improved Vegetative Index*

ARVI: *Atmospherically Resistant Vegetation Index*

MCARI2: *Modified Chlorophyll Absorption in Reflectance Index 2*

TCARI: *Transformed Chlorophyll Absorption in Reflectance Index*

MTVI2: *Modified Triangular Vegetation Index 2*

RENDVI: *Red Edge Normalized Difference Vegetation Index*

REPI: *Red Edge Position Index*

SIPI: *Structure Insensitive Pigment Index*

CCI: *Carotenoid Chlorophyll Index*

ARI2: *Anthocyanin Reflectance Index 2*

CRI2: *Carotenoid Reflectance Index 2*

PSRI: *Plant Senescence Reflectance Index*

NPCI: *Normalized Pigment Chlorophyll Ratio Index*

DSWI: *Disease Water Stress Index*

NBR: *Normalized Burn Ratio*

MSI: *Moisture Stress Index*

FCI1: *Forest Condition Index 1*

FCI2: *Forest Condition Index 2*

PIOLP: *Plan Insular de Ordenación de La Palma*

SIOSE: *Sistema de Información sobre la Ocupación del Suelo en España*

SCL: *Scene Classification Layer*

AOI: *Area of Interest*

ROI: *Region of Interest*

QGIS: *Quantum Geographic Information System*

RGB: *Red Green Blue*

ISF-S2: *Índice de Salud Forestal Sentinel-2*

1. Introducción

1.1. Antecedentes

El 19 de septiembre de 2021 comenzó en la isla de La Palma una de las erupciones volcánicas más devastadoras de su historia reciente con graves impactos en su ecosistema. Aproximadamente dos años más tarde, el 15 de julio de 2023, un importante incendio forestal arrasó una parte importante de sus bosques. Es de esperar que estos eventos hayan afectado la cubierta forestal de la isla, surgiendo así, la necesidad de monitorizar el estado de los ecosistemas locales, tarea que puede abordarse eficazmente con herramientas avanzadas como la teledetección.

La teledetección es una técnica aeroespacial que permite captar datos de la superficie terrestre y la atmósfera circundante mediante sensores remotos, aprovechando la interacción de los materiales con la radiación electromagnética para obtener propiedades espectrales únicas de los objetos observados. Es decir, diferentes tipos de superficies reflejan la radiación de una manera distinta en función de la longitud de onda. Estas firmas espectrales nos permiten analizar las propiedades físicas, químicas o biológicas de la superficie terrestre a través de las imágenes obtenidas por sensores remotos. Gracias a su capacidad para recopilar información en múltiples bandas del espectro electromagnético y monitorear grandes áreas de forma repetitiva, la teledetección se ha consagrado como una herramienta clave en ámbitos como el medioambiente, la agricultura y la gestión de desastres [1, 2].

De forma general, los sensores pasivos capturan imágenes multi o hiperespectrales, cuya principal diferencia es el número de bandas adyacentes, permitiendo obtener el espectro continuo de un objeto, mientras que las multiespectrales ofrecen un menor número de bandas no necesariamente contiguas, permitiendo obtener únicamente los valores de intensidad en las longitudes de onda que la forman. A pesar de que las imágenes hiperespectrales puedan parecer una mejor opción, cabe destacar que, en el contexto de datos extraídos a través de satélites de observación, los sensores hiperespectrales embarcados en satélites no alcanzan una resolución espacial adecuada para su utilización en zonas complejas donde se precisen resoluciones espaciales que cubran pocos metros cuadrados de la superficie [3, 4].

Existen diversas plataformas y programas que permiten la recopilación de datos multiespectrales. En este trabajo utilizaremos los datos derivados del programa *Copernicus*,

una iniciativa de observación de la Tierra liderada por la Unión Europea, que proporciona acceso gratuito a datos satelitales de alta calidad. Dentro de este programa, seleccionaremos el satélite Sentinel-2 debido a su excelente resolución espacial (10-20 metros para las bandas de interés) y una elevada frecuencia temporal, lo que permite un monitoreo detallado y continuo de los cambios en la vegetación [5, 6].

El análisis de la vegetación se realiza habitualmente mediante el estudio de los índices de vegetación (IV), que nos proporcionan información de la salud vegetal mediante operaciones algebraicas entre valores de reflectancia en diferentes longitudes de onda. Específicamente, estos índices facilitan la obtención de información sobre la vegetación como el pigmento, la estructura de la célula o el contenido de humedad incluso pudiendo minimizar las interferencias en las medidas [7 - 9]. Además, los índices generados a partir de datos del satélite Sentinel-2 desempeñan un papel fundamental en la evaluación del impacto de los eventos mencionados, complementados con cartografías forestales detalladas como las disponibles a nivel insular, regional, nacional o europeo.

La biodiversidad de La Palma, con su riqueza en especies únicas y ecosistemas diversos, representa un valor ecológico y científico incalculable. Sin embargo, esta biodiversidad se ha visto altamente afectada por los fenómenos ya descritos unidos al calentamiento global, subrayando así la importancia de este Trabajo de Fin de Grado. Mediante el análisis de datos multiespectrales mensuales del Sentinel-2 entre 2019 y 2024, junto con cartografías forestales existentes, se buscará aportar una evaluación precisa del estado de la cubierta forestal.

1.2. Objetivos

El objetivo principal de este Trabajo Fin de Grado es hacer un análisis multitemporal de los efectos del incendio 2023 y volcán 2021 en la cubierta forestal de la isla de La Palma. Este análisis se ha realizado mediante el uso de datos multiespectrales mensuales del satélite Sentinel-2 y cartografías forestales existentes, buscando evaluar los cambios en el estado de la vegetación y sus características específicas a lo largo del tiempo. Para ello, se han abordado los siguientes objetivos específicos:

O1: Análisis de datos multiespectrales entre 2019 y 2024. Una vez realizado el procesado y el análisis de las imágenes satelitales Sentinel-2 adecuadas, se ha estudiado la evolución de la vegetación. Para ello se han seleccionado índices de vegetación específicos para evaluar la

pigmentación foliar (relacionada con la clorofila y la actividad fotosintética), el estado celular y la vitalidad de las plantas, así como el contenido de agua en la vegetación.

O2: Análisis de cartografías forestales. Estas cartografías han servido como apoyo para el estudio de la cubierta forestal. Se han utilizado para delimitar según zonas de interés, clasificar los distintos tipos de vegetación y evaluar la evolución de los ecosistemas.

O3: Analizar el impacto del incendio de 2023 y la erupción volcánica de 2021 en las especies forestales para identificar cambios en la estructura y el estado de la vegetación: Se han estudiado los efectos ocasionados por estos eventos en la vegetación por medio de la serie de imágenes y datos multiespectrales previos y posteriores. Asimismo, se analizaron las especies forestales para evaluar cómo han cambiado a lo largo del período de estudio, proporcionando información para la identificación de patrones sobre el impacto sufrido y el proceso de recuperación según cada especie y en diferentes ubicaciones.

2. Sistemas de Teledetección

2.1. Introducción a la Teledetección

La teledetección es una técnica aeroespacial que permite captar datos de la superficie terrestre y la atmósfera circundante, mediante sensores remotos, aprovechando la interacción de los materiales con la radiación electromagnética para obtener propiedades espectrales únicas de los objetos observados [10, 11]. Hay tres tipos de interacciones entre el objetivo y el sensor: la radiación solar reflejada, que se encuentra en el espectro visible e infrarrojo; la radiación emitida por los objetos en la superficie terrestre; y la radiación emitida por el sensor, como ocurre con los radares, que reflejan los objetos en la superficie [12, 13]. En este Trabajo de Fin de Grado se han utilizado sensores que capturan la radiación solar reflejada.

La teledetección satelital ofrece una serie de ventajas:

- Proporciona una cobertura global sobre la superficie de la Tierra, ya que dispone de satélites que se encargan de hacer la cobertura de manera homogénea a toda la superficie.
- Permite la observación de fenómenos que se encuentran fuera del espectro visible gracias a la existencia de sensores que adquieren datos en longitudes de onda que no percibe el ojo humano.
- La programación de las órbitas de las plataformas espaciales da la posibilidad de poseer observación periódica, que facilita el seguimiento de cambios en el tiempo, como la dinámica de la vegetación, el clima o el uso del suelo.
- El uso simultáneo de distintas plataformas con diferentes resoluciones permite extraer información a diferentes escalas para hacer desde estudios planetarios hasta estudios a escala local.

Las plataformas utilizadas para la Teledetección pueden ser aéreas o espaciales. Las plataformas aéreas incluyen sensores aeroportados en aviones, helicópteros, drones o globos, que proporcionan una observación más detallada, pero abarcando áreas pequeñas. Las plataformas espaciales se basan en plataformas orbitales equipadas con sensores que ofrecen cobertura global a menor resolución. Estas órbitas pueden ser geoestacionarias o polares en órbitas de baja altura, dependiendo de la misión que desempeñen y de las resoluciones espaciales y temporales requeridas. Los sensores a bordo de estas plataformas

pueden ser pasivos, cuando se limitan a captar la radiación reflejada o emitida por los objetos, o activos, como los radares, que emiten radiación hacia la superficie y luego recogen la radiación reflejada [14, 15]. En este Trabajo de Fin de Grado se utilizarán los sensores pasivos.

Un sistema de teledetección cuenta con varios componentes: un sensor que captura la radiación; un objetivo, que corresponde al área de observación; un flujo energético, definido como la radiación que viaja entre el objetivo y el sensor; un sistema de recepción que se encarga de recibir y procesar los datos capturados por el sensor; un intérprete, que analiza la información y extrae los datos relevantes; y un usuario final, que utiliza la información procesada para tomar decisiones informadas. En la Figura 1 se muestra un diagrama de los elementos que conforman un sistema de Teledetección.

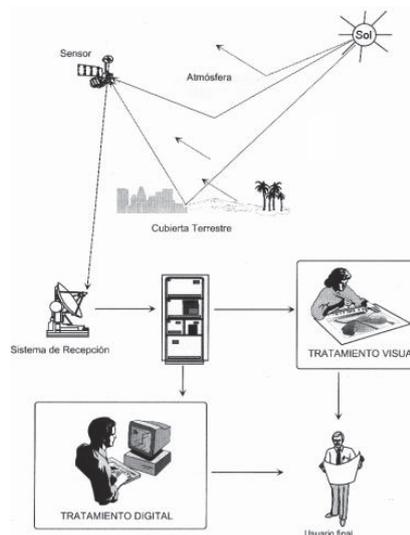


Figura 1: Sistema de Teledetección [16].

2.2. Firma espectral

La firma espectral es la representación de la reflectividad de un objeto en función de la longitud de onda cuando le incide una radiación electromagnética. Cada material reacciona a la energía incidente de una manera distinta, reflejando, absorbiendo o emitiendo la radiación en distintas proporciones a lo largo del espectro electromagnético. Por lo tanto, esta respuesta espectral actúa como huella distintiva que permite la identificación, diferenciación y el análisis de materiales mediante técnicas de teledetección [17].

En cuanto a la vegetación, se puede apreciar en su curva de reflectancia representada en la Figura 2, que la región del visible tiene dos valles alrededor de $0,45 \mu\text{m}$ y $0,60 \mu\text{m}$ donde se absorbe fuertemente la radiación en las bandas del azul y rojo debido a la demanda de energía

de los pigmentos naturales para llevar a cabo la fotosíntesis, mientras que en la banda verde hay una mayor reflectancia, explicando así su color característico. En la región del infrarrojo cercano, entre 0,7 y 1,3 μm , la reflectancia de la vegetación viene condicionada por la estructura interna de la hoja, lo que se podría emplear para diferenciar distintas especies teniendo en cuenta las respuestas espectrales producidas. Por encima de 1,3 μm hasta 2,5 μm (infrarrojo medio) la reflectancia varía en función del contenido de agua en la planta siendo que, a mayor contenido de agua en la hoja, menor valor de reflectancia [18].

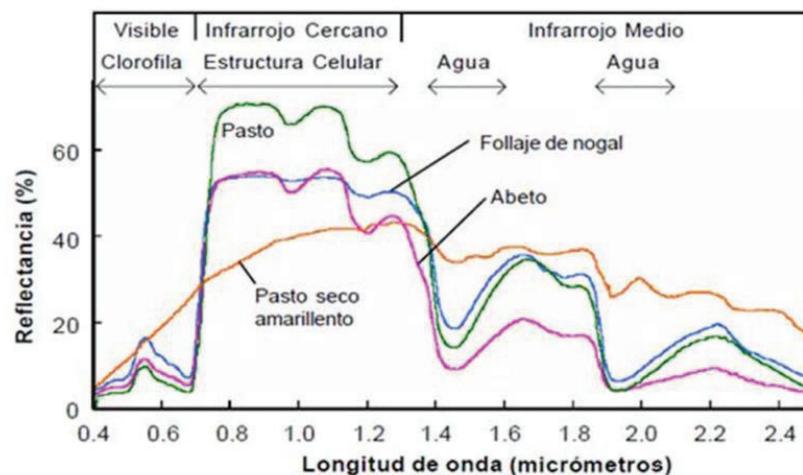


Figura 2: Reflectancia espectral de diferentes tipos de vegetación verde [19].

Cuando la vegetación sufre estrés hídrico ocurren cambios significativos en su firma espectral. Al degradarse los pigmentos como la clorofila disminuye la absorción en las bandas del azul y rojo, produciendo un aumento de la reflectancia en esas longitudes de onda. Sin embargo, en el infrarrojo cercano disminuye la reflectividad a causa del deterioro de la estructura celular interna, que es la responsable de que haya una alta reflectividad en estas longitudes de onda en vegetación sana. Por último, en la zona del infrarrojo medio hay un aumento de la reflectancia ya que el contenido de agua en la planta se reduce.

Los sensores remotos captan las variaciones espectrales específicas de cada material permitiendo representar gráficamente la reflectividad. Gracias a esta capacidad, es posible analizar y clasificar la cobertura terrestre con gran precisión, proporcionando una información esencial para la teledetección con la que evaluar el estado de la vegetación y monitorear fenómenos ambientales.

2.3. Sistema satelital Sentinel-2

Actualmente existen multitud de satélites con sensores multiespectrales que ofrecen distintas resoluciones espaciales y espectrales. La serie Landsat fue la primera en incorporar sensores con el fin de obtener datos científicos sobre recursos naturales, siendo así un proyecto altamente fructífero. A lo largo de 40 años, esta serie ha proporcionado datos de imágenes multiespectrales consolidándose como el registro más prolongado de observaciones de la superficie terrestre [20]. Sin embargo, su resolución espacial es moderada (30 metros).

Por otro lado, la constelación de satélites Sentinel-2, cuyo primer satélite (Sentinel-2A) fue lanzado en 2015, es una misión de observación de la Tierra desarrollada por la Unión Europea como parte del programa Copernicus. Esta constelación consiste en tres satélites, llamados Sentinel-2A, Sentinel-2B y Sentinel-2C, que están posicionados en la misma órbita heliosíncrona a una altitud de 786 kilómetros y con una diferencia de fase de 180° para asegurar una cobertura óptima de la Tierra. La resolución temporal de Sentinel-2 es de diez días por satélite, reduciéndose a cinco días al combinar dos satélites. Las imágenes están disponibles desde 2015, tras el lanzamiento de Sentinel-2A, y la frecuencia de adquisición se duplicó en 2017 con la incorporación de Sentinel-2B. Debido a que el Sentinel-2C fue lanzado en septiembre de 2024 con el propósito de sustituir al Sentinel-2A, puede que al principio aumente momentáneamente la resolución temporal, pero una vez alcanzado el final de su vida útil la frecuencia volverá a ser de 5 días [21, 22]. En la Figura 3 se muestra un resumen de la misión Sentinel-2.

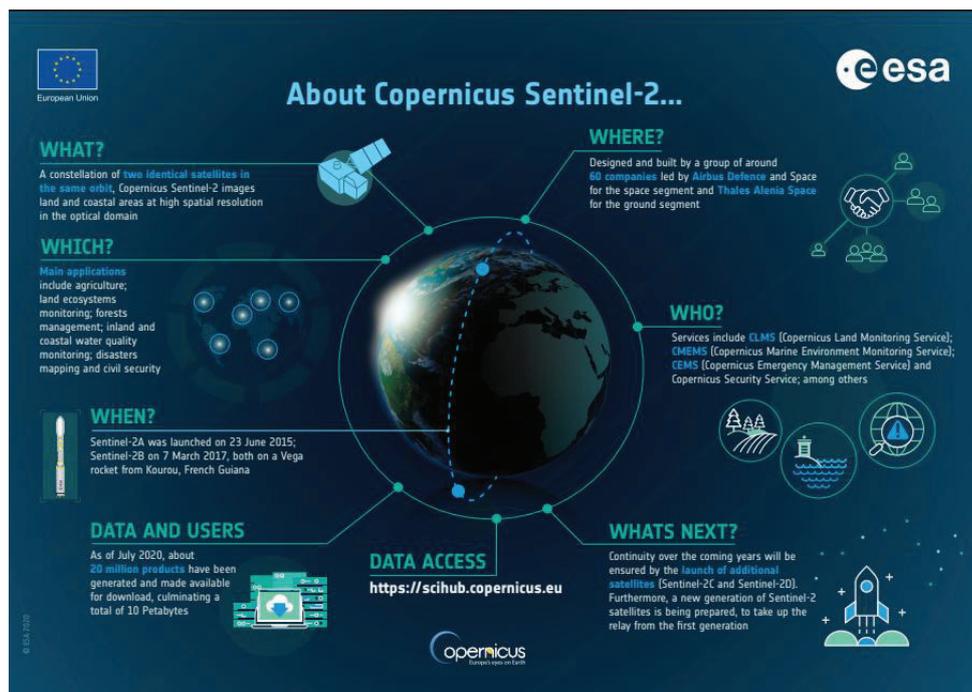


Figura 3: Introducción sobre el programa Copernicus.

Sentinel-2 captura imágenes multispectrales, es decir, contiene información en múltiples bandas del espectro electromagnético. Tal y como se aprecia en la Tabla 1 y en la Figura 4, cada imagen capturada está compuesta por 13 bandas que van desde el espectro visible hasta el infrarrojo de longitud de onda corta (SWIR). Cada banda tiene una resolución espacial específica, por lo que el nivel de detalle para cada banda varía, ya que dependiendo de la longitud de onda que se observe habrá una resolución de 10, 20 o 60 metros. Además, su ancho de exploración ‘swath’ es de 290 kilómetros.

Tabla 1: Bandas Sentinel-2 [23].

	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

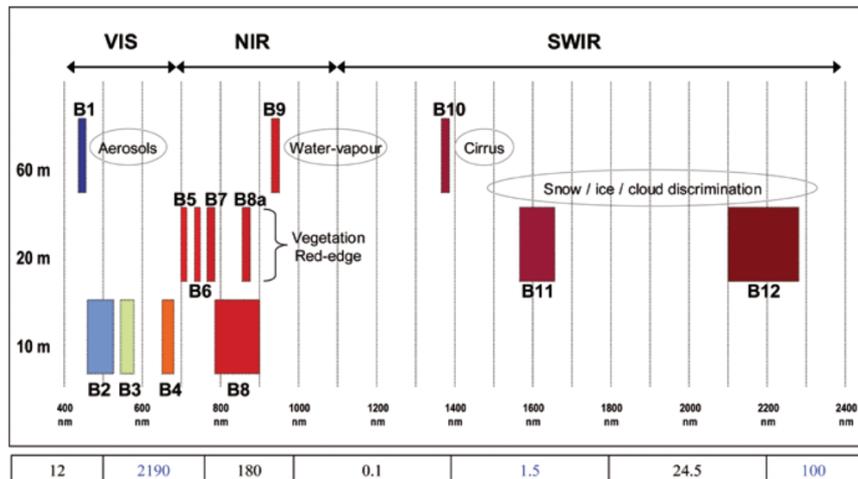


Figura 4: Bandas Sentinel-2 [24].

Esta constelación de satélites se caracteriza por su versatilidad, siendo de utilidad en numerosas aplicaciones convirtiéndolo en una pieza fundamental a la hora de la toma de decisiones en sectores como la agricultura, la gestión del medio ambiente y la planificación urbana. Además, los datos son gratuitos y están accesibles de forma sencilla desde la web de Copernicus [25].

3. Índices de vegetación

Los índices de vegetación son herramientas fundamentales en teledetección para evaluar el estado de la vegetación de la superficie terrestre. Estos índices usan combinaciones de bandas espectrales derivadas de la reflectancia de la radiación solar sobre la vegetación permitiendo una interpretación sobre el vigor vegetal, estrés hídrico y cobertura del suelo [26].

Tras un análisis de los principales índices de vegetación existentes, en este capítulo se describen los utilizados en el análisis de este Trabajo de fin de Grado, con el fin de identificar qué índices son los más adecuados y útiles para el análisis de los efectos del volcán e incendio en la cubierta forestal de La Palma.

3.1. Índices de banda ancha

Los índices de banda ancha usan rangos amplios del espectro electromagnético capturando una gran cantidad de información, pero con menos precisión espectral. A continuación, se presentan los principales índices de banda ancha.

3.1.1. Normalized Difference Vegetation Index

El Normalized Difference Vegetation Index (NDVI) es uno de los índices más usados. Proporciona información para distinguir la vegetación de otros tipos de cubierta terrestre, asimismo, ayuda a determinar el estado general de la vegetación siendo usado en su identificación y monitoreo. Tal y como se aprecia en la ecuación 1, este índice utiliza las bandas del rojo y del infrarrojo cercano.

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

El uso de bandas en las que la cantidad de clorofila y la estructura celular de las hojas tienen una gran trascendencia implica que no siempre se puede obtener resultados óptimos. Esto sucede porque las especies vegetales tienen distintas respuestas espectrales, por lo que un solo valor de NDVI puede referirse a distintos tipos de vegetación con diferente estado fisiológico. Además, en zonas de vegetación densa o con interferencias atmosféricas se tiende a saturar. Cabe destacar que para Sentinel-2 la banda NIR será la NIR-1, ya que tiene mayor

resolución espacial. El NDVI está normalizado entre -1 y 1, significando que cuanto más se acerque a 1 habrá mayor densidad de vegetación saludable [27, 28].

3.1.2. Enhanced Vegetation Index

Este índice es una mejora del NDVI, ya que se añadieron ajustes para contrarrestar los efectos de saturación en zonas de vegetación densa y adecuar el resultado a los ruidos atmosféricos y del suelo. En concreto, se añadieron en el Enhanced Vegetation Index (EVI) los valores 6 y 7.5 para suplir los efectos de la dispersión de los aerosoles presentes en la atmósfera y el +1 en el denominador para eliminar los efectos negativos de la reflectividad del suelo.

$$EVI = 2.5 * \frac{NIR - RED}{(NIR + 6 * RED - 7.5 * BLUE) + 1} \quad (2)$$

Es un índice comúnmente utilizado en zonas de vegetación densa con mucha clorofila y con los mínimos efectos topográficos posibles una vez se han enmascarado las fuentes de brillo antes de procesar la imagen. Está normalizado entre -1 y 1 y para la vegetación saludable varía entre 0.2 y 0.8 [27, 29].

3.1.3. Soil Adjusted Vegetation Index

Es un índice similar al NDVI, cuyo propósito es reducir el ruido introducido por el impacto del brillo del suelo gracias a una constante añadida que puede variar entre 0 y 1, aunque habitualmente se use 0.5, ya que se ajusta a la mayoría de los suelos.

$$SAVI = \frac{1.5 * (NIR - RED)}{NIR + RED + 0.5} \quad (3)$$

Se utiliza en regiones áridas con vegetación escasa lo que requiere un conocimiento previo de la zona de estudio. Al igual que el NDVI, está normalizado entre -1 y 1, donde valores altos significan mayor salud [27].

3.1.4. Modified Soil Adjusted Vegetation Index 2

Modified Soil Adjusted Vegetation Index 2 (MSAVI2) es una versión del SAVI que nos permite diferenciar mejor el suelo desnudo de la vegetación y mejora la detección de la vegetación.

Este índice es ideal para etapas tempranas de la vegetación, cultivos que no cubren el suelo o simplemente para áreas de prominente presencia de suelo desnudo.

$$MSAVI2 = \frac{(2 * NIR + 1 - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - RED)})}{2} \quad (4)$$

Se emplea cuando SAVI no proporciona una diferenciación precisa entre suelo y vegetación. Al igual que los otros índices varía entre -1 y 1, donde valores cercanos a 1 indican buena salud [27, 30].

3.1.5. Green Normalized Difference Vegetation Index

Nuevamente es otra variación del NDVI, pero en este caso se caracteriza por usar la banda verde en lugar de la roja, lo que la hace más sensible a la variación de clorofila en la vegetación. Esto hace que se sature más tarde que el NDVI y sea utilizado en etapas más avanzadas de desarrollo [27, 30].

$$GNDVI = \frac{NIR - GREEN}{NIR + GREEN} \quad (5)$$

Los valores se encuentran entre -1 y 1, indicando que cuanto más cercano de 1 sea mayor contenido de clorofila y, por tanto, se tratará de una vegetación más saludable.

3.1.6. Simple Ratio

Es un índice simple empleado para estimar la cantidad de vegetación. El rango de valores es desde 0 hasta aproximadamente 30, donde valores entre 2 y 8 suelen indicar vegetación saludable [27, 31].

$$SR = \frac{NIR}{RED} \quad (6)$$

3.1.7. Modified Simple Ratio

Es una mejora del SR, donde se mejora la sensibilidad de detección de los parámetros biofísicos a la hora de la monitorización de la degradación de la vegetación.

$$MSR = \frac{SR-1}{\sqrt{SR+1}}, \text{ donde } SR = \frac{NIR}{RED} \quad (7)$$

Este índice cuenta con un rango de valores indefinido, sin embargo, suele estar acotado entre 0 y 4. Valores cercanos a 0 nos indican que se trata de zonas áridas mientras que entre 1 hasta 3 o 4 quiere decir que nos encontramos ante una vegetación densa y saludable [27].

3.1.8. Global Environmental Monitoring Index

Global Environmental Monitoring Index (GEMI) es un índice no lineal diseñado para la supervisión ambiental global con el objetivo de disminuir los efectos atmosféricos. No se recomienda su uso en zonas con poca densidad de población vegetal ya que se ve afectado por los efectos del suelo. Los valores mayores a 0.35 indican áreas con vegetación mientras que los menores indican suelo desnudo [27].

$$GEMI = (n * (1 - 0.25 * n) - \frac{RED - 0.125}{1 - RED}), \quad (8)$$

donde $n = \frac{2*(NIR^2 - RED^2) + 1.5*NIR + 0.5*RED}{NIR + RED + 0.5}$

3.1.9. Wide Dynamic Range Vegetation Index

Se introdujo como una forma de mejorar el rango dinámico del NDVI con la inclusión del factor de ponderación a para disminuir la disparidad entre las contribuciones entre la banda del infrarrojo cercano y la roja. Es de utilidad para realizar estudios de vegetación en zonas con alta densidad [27].

$$WDRVI = \frac{a*NIR - RED}{a*NIR + RED}, \text{ donde } a \text{ va desde } 0.1 \text{ a } 0.2 \quad (9)$$

En este Trabajo de Fin de Grado se utilizará 0.2 para el valor de a .

3.1.10. WorldView Improved Vegetative Index

El WorldView Improved Vegetative Index (WV-VI) [27] tiene la siguiente expresión.

$$WVVI = \frac{NIR2 - RED}{NIR2 + RED} \quad (10)$$

3.2. Índices de banda estrecha

A diferencia de los índices de banda ancha, estos usan rangos pequeños del espectro electromagnético permitiendo detectar características específicas de la vegetación.

3.2.1. Atmospherically Resistant Vegetation Index

Este índice es una mejora del NDVI debido al uso mediciones de la reflectancia de la banda azul para disipar las interferencias producidas por la dispersión atmosférica. Por lo tanto, se usa generalmente para zonas que poseen alto contenido de aerosoles. Al aplicarlo, los valores varían entre -1 y 1 donde valores cercanos a 1 significan buen estado de salud en la vegetación [27].

$$ARVI = \frac{\rho_{800} - [\rho_{680} - \gamma * (\rho_{450} - \rho_{680})]}{\rho_{800} + [\rho_{680} - \gamma * (\rho_{450} - \rho_{680})]}, \text{ donde } \gamma=1 \quad (11)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 11 son las siguientes:

$$\rho_{450} = BLUE$$

$$\rho_{680} = RED$$

$$\rho_{800} = NIR 1$$

3.2.2. Modified Chlorophyll Absorption in Reflectance Index 2

Modified Chlorophyll Absorption in Reflectance Index 2 (MCARI2) es una modificación del índice MCARI, hecho para determinar la cantidad de clorofila en la vegetación minimizando la interferencia producida por la reflectancia del fondo. Se aplica en cultivos agrícolas y bosques para evaluar la salud de la vegetación, donde los valores resultantes más cercanos a 1 indican mayor contenido de clorofila [27, 32].

$$MCARI2 = \frac{1.5 * [2.5 * (\rho_{800} - \rho_{670}) - 1.3 * (\rho_{800} - \rho_{550})]}{\sqrt{(2 * \rho_{800} + 1)^2 - (6 * \rho_{800} - 5 * \sqrt{\rho_{670}}) - 0.5}} \quad (12)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 12 son las siguientes:

$$\rho_{550} = GREEN$$

$$\rho_{670} = RED$$

$$\rho_{800} = NIR\ 1$$

3.2.3. Transformed Chlorophyll Absorption in Reflectance Index

Este índice mide la cantidad de clorofila que se absorbe en la banda del rojo con respecto a los máximos de reflectancia en los bordes verde y rojo. Es sensible a la reflectividad del suelo por lo que se dificulta su uso en zonas con poca densidad vegetal. Sus valores se encuentran entre .1 y 1, donde valores cercanos a 1 indica mayor absorción de clorofila [27].

$$TCARI = 3 * \left[(\rho_{700} - \rho_{670}) - 0.2 * (\rho_{700} - \rho_{550}) * \left(\frac{\rho_{700}}{\rho_{670}} \right) \right] \quad (13)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 13 son las siguientes:

$$\rho_{550} = GREEN$$

$$\rho_{670} = RED$$

$$\rho_{700} = Red\ Edge\ 1$$

3.2.4. Modified Triangular Vegetation Index 2

Aplicando este índice se puede detectar el contenido de clorofila reduciendo la influencia del área foliar. También reduce las interferencias introducidas por la reflectancia del suelo y conserva su capacidad de detección en zonas densas. Por ello, se emplea en zonas con poca densidad vegetal. Al igual que los anteriores índices, cuanto más se acerque a 1 significa que la vegetación se encuentra en mejor estado de salud [27, 33].

$$MTVI2 = \frac{1.5 * [1.2 * (\rho_{800} - \rho_{550}) - 2.5 * (\rho_{670} - \rho_{550})]}{\sqrt{(2 * \rho_{800} + 1)^2 - (6 * \rho_{800} - 5 * \sqrt{\rho_{670}}) - 0.5}} \quad (14)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 14 son las siguientes:

$$\rho_{550} = GREEN$$

$$\rho_{670} = RED$$

$$\rho_{800} = NIR\ 1$$

3.2.5. Red Edge Normalized Difference Vegetation Index

Es un índice parecido al NDVI, pero se diferencia por el empleo de bandas del borde rojo en lugar de los picos principales de absorción y reflectancia. De este modo se utiliza la sensibilidad del borde rojo de la vegetación para detectar el contenido de clorofila [27].

$$RENDVI = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}} \quad (15)$$

Los resultados fluctúan entre -1 y 1, siendo en el rango de 0.2 a 0.9 donde generalmente se encuentra la vegetación sana.

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 15 son las siguientes:

$$\rho_{705} = \text{Red Edge 1}$$

$$\rho_{750} = \text{Red Edge 2}$$

3.2.6. Red Edge Position Index

REPI permite medir variaciones en la concentración de clorofila de la vegetación ya que a medida que aumenta el contenido de clorofila, la absorción en el rojo se intensifica haciendo que se desplace el borde rojo hacia longitudes onda mayores. Sirve de utilidad para analizar posibles cambios en la vegetación a causa del estrés vegetal. Los valores resultantes una vez se ha aplicado este índice dependen del tipo de vegetación [27].

$$REPI = \frac{[\rho_{690} : \rho_{740}] - [\rho_{700} : \rho_{730}]}{[\rho_{690} : \rho_{740}] + [\rho_{700} : \rho_{730}]} \quad (16)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 16 son las siguientes:

$$[\rho_{690} : \rho_{740}] = \text{Red Edge 1, Red Edge 2}$$

$$[\rho_{700} : \rho_{730}] = \text{Red Edge 1}$$

Para que la fórmula tenga sentido, hay que determinar que el rango $[\rho_{690} : \rho_{740}]$ sea *Red Edge 2*. Sin embargo, la fórmula del REPI acaba siendo la equivalente a la del RENDVI.

3.3. Índices de Pigmentos y Eficiencia de Uso de la Luz

Estos índices detectan la cantidad de pigmentos tales como la clorofila o los carotenoides en la vegetación. Esto los hace útiles para evaluar la actividad fotosintética de la vegetación.

3.3.1. Structure Insensitive Pigment Index

Este índice relaciona la presencia de carotenoides con la cantidad de clorofila. Es útil puesto que valores altos de este índice suele señalar estrés en la vegetación. Esto se debe a que los carotenoides, como alfacaroteno y betacaroteno, están asociados a mecanismos de defensa de la vegetación ante condiciones adversas [27].

$$SIP I = \frac{\rho_{800} - \rho_{445}}{\rho_{800} + \rho_{680}} \quad (17)$$

El resultado varía entre -1 y 1. Valores altos se traducen en vegetación con estrés hídrico o senescencia y valores bajos en mayor cantidad de clorofila que carotenoides.

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 17 son las siguientes:

$$\rho_{445} = \textit{Aerosol}$$

$$\rho_{680} = \textit{RED}$$

$$\rho_{800} = \textit{NIR 1}$$

3.3.2. Carotenoid Chlorophyll Index

Carotenoid Chlorophyll Index (CCI) está diseñado para evaluar la relación entre los carotenoides y la clorofila de una manera más específica que el SIPI. Sin embargo, es más sensible a la estructura de la hoja. Valores bajos muestran predominancia de la clorofila frente a los carotenoides mientras que valores altos quieren decir que hay una significativa reducción de clorofila relativa, es decir, vegetación en estado de estrés, senescencia o envejecimiento [27].

$$CCI = \frac{GREEN - RED}{GREEN + RED} \quad (18)$$

3.3.3. Anthocyanin Reflectance Index 2

Es un índice ideado para detectar antocianinas, pigmentos que se encuentran en el agua de la vegetación. Aparecen tanto en hojas jóvenes como en hojas bajo estrés o envejecimiento. Un valor alto de este índice puede indicar nuevo crecimiento o deterioro de la vegetación, lo cual requiere un conocimiento previo de la zona de estudio [27].

$$ARI2 = \rho_{800} \left[\frac{1}{\rho_{510}} - \frac{1}{\rho_{550}} \right] \quad (19)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 19 son las siguientes:

$$\rho_{510} = BLUE$$

$$\rho_{550} = GREEN$$

$$\rho_{800} = NIR 1$$

3.3.4. Carotenoid Reflectance Index 2

Este índice proporciona mejores resultados en áreas con bastante concentración de carotenoides. Usa la reflectancia en la banda del espectro visible para aprovechar la absorción de aquellos pigmentos relacionados con el estrés y su valor varía entre 0 y más de 15. El rango para vegetación verde se suele encontrar entre 1 y 11 [27].

$$CRI2 = \left[\frac{1}{\rho_{510}} - \frac{1}{\rho_{700}} \right] \quad (20)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 20 son las siguientes:

$$\rho_{510} = BLUE$$

$$\rho_{700} = Red Edge 1$$

3.4. Índices de senescencia y estrés vegetal

Estos índices evalúan la degradación en la vegetación, detectando pérdida de clorofila o cambios en los pigmentos. Esto los hace útiles para detectar enfermedades, sequías o contaminación.

3.4.1. Plant Senescence Reflectance Index

Maximiza la sensibilidad a la hora de detectar la relación entre la clorofila y los carotenoides. Un valor alto de este índice resalta el inicio de la senescencia por lo que es útil para monitorear la salud vegetal y detectar el estrés fisiológico a tiempo [27].

$$PSRI = \frac{\rho_{680} - \rho_{500}}{\rho_{750}} \quad (21)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 21 son las siguientes:

$$\rho_{500} = BLUE$$

$$\rho_{680} = RED$$

$$\rho_{750} = Red\ Edge\ 2$$

3.4.2. Normalized Pigment Chlorophyll Ratio Index

Se enfoca en la estimación de la cantidad de clorofila en la vegetación y su relación con el nitrógeno. Es útil ya que una escasez de nitrógeno se traduciría en clorosis (hojas amarillas) y en un crecimiento lento y débil debido a tallos delgados y con menor producción de hojas [27].

$$NPCR = \frac{\rho_{680} - \rho_{430}}{\rho_{680} + \rho_{430}} \quad (22)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 22 son las siguientes:

$$\rho_{430} = Aerosol$$

$$\rho_{680} = RED$$

3.5. Índices de humedad y estrés hídrico

Evalúan el contenido de agua de la vegetación siendo útiles para identificar zonas con falta de agua o afectadas por sequía. Además, utilizan alguna banda del infrarrojo medio para medir el contenido de agua de la planta.

3.5.1. Disease Water Stress Index

Disease Water Stress Index (DWSI) se centra en evaluar el estrés hídrico en la vegetación diferenciando entre zonas secas y húmedas [27].

$$DWSI = \frac{\rho_{802} - \rho_{547}}{\rho_{1657} + \rho_{682}} \quad (23)$$

Las correspondencias de las bandas Sentinel-2 con las reflectividades de la ecuación 23 son las siguientes:

$$\rho_{547} = GREEN$$

$$\rho_{682} = RED$$

$$\rho_{802} = NIR 1$$

$$\rho_{1657} = SWIR 1$$

3.5.2. Normalized Burn Ratio

Normalized Burn Ratio (NBR) detecta áreas quemadas por incendios forestales. Esto se lleva a cabo usando las bandas NIR y SWIR, indicando que cuando haya una alta reflectancia en NIR y baja en SWIR signifique que se trata de una vegetación sana. Valores pequeños como resultado de la operación indican áreas quemadas [27, 34].

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} \quad (24)$$

3.5.3. Moisture Stress Index

Moisture Stress Index (MSI) evalúa el estrés hídrico teniendo en cuenta la cantidad de agua disponible en el dosel de la vegetación. A diferencia de otros índices de humedad, la operación está invertida por lo que valores altos indican menor contenido de agua [27].

$$MSI = \frac{SWIR}{NIR} \quad (25)$$

3.6. Índices específicos de cobertura forestal

Están diseñados para estimar la densidad de la vegetación o detectar cambios por deforestación o incendios.

3.6.1. Forest Condition Index 1

Índice diseñado para analizar los doseles forestales y diferenciarlos de otro tipo de vegetación. Los bosques presentan un valor más bajo mientras que vegetación más baja representa un valor más alto debido a su mayor reflectancia en el NIR [27, 35].

$$FCI1 = RED * RED\ EDGE \quad (26)$$

3.6.2. Forest Condition Index 2

A diferencia del FC1, este índice no utiliza la banda del borde rojo en el cálculo. Esto lo hace más útil para sensores que no tengan el borde rojo o simplemente en análisis donde otras longitudes de onda sean de más valor [27, 35].

$$FCI2 = RED * NIR \quad (27)$$

4. Estudio y análisis de cubierta forestal de La Palma

En este capítulo se detallan los datos empleados y el procesado de las imágenes para crear una serie temporal de imágenes satelitales de La Palma con el objetivo de analizar los cambios sufridos en la cubierta forestal. La metodología principal se muestra en la Figura 5.

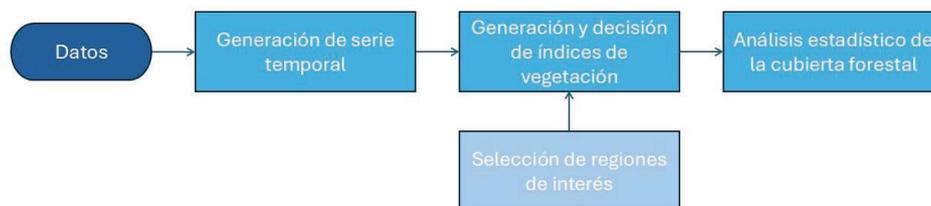


Figura 5: Diagrama de bloques general.

4.1. Zona de estudio

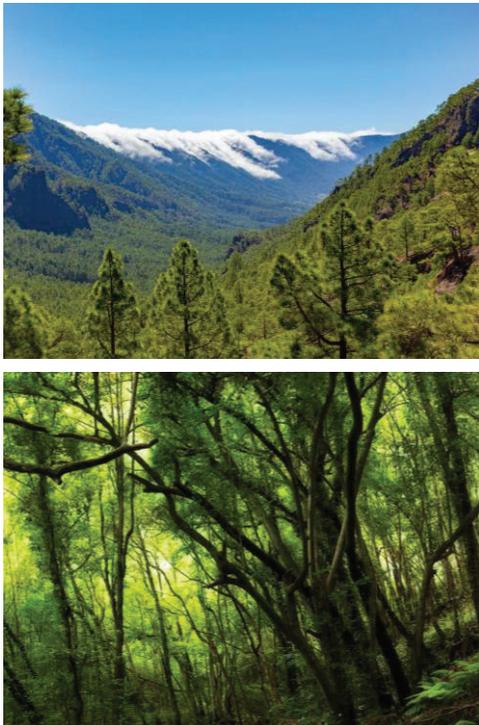
La cubierta forestal de La Palma destaca por su riqueza y diversidad altitudinal, favoreciendo así a la aparición de diferentes especies predominantes vegetales. Las destacadas son los pinares de pino canario, el fayal-brezal y la laurisilva. Estas masas forestales han sido objeto de análisis multiespectral y cartográfico [36].

En particular, los pinares de *Pinus Canariensis* son la formación más extensa de la isla, con una superficie aproximada de 18.309,07 hectáreas. Se localizan principalmente en el Parque Natural Cumbre Vieja, el Parque Nacional de la Caldera de Taburiente, el Pinar de Garafía y en la zona suroeste de la isla. El faya-brezal es otra de las especies dominantes. Ocupa unas 8.043,77 hectáreas, distribuidas por las zonas norte y este de la isla. Se sitúan en áreas de barrancos entre los 200 y 1.600 metros de altitud y posee una cubierta densa. Por último, la laurisilva es una de las formaciones más endémicas de canarias con una extensión de 635,43 hectáreas en La Palma. Principalmente se encuentra en zonas húmedas y elevadas y junto al fayal-brezal componen el llamado “monte verde”.

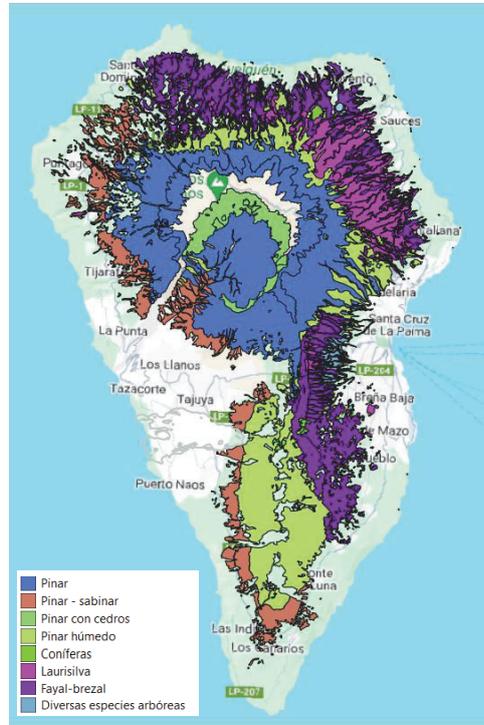
A pesar de que el análisis se ha centrado en estos tipos de vegetación, también están presentes otras formaciones vegetales como zonas de pastos, formaciones arbustivas y bosquetes de castaños (*Castanea sativa*).

Para la delimitación de estas zonas se han empleado diferentes fuentes cartográficas, tal y como se muestra en la Figura 6. Estas son básicamente los mapas de vegetación del Gobierno de Canarias de 2021, del Plan Insular de Ordenación de la Palma (PIOLP) de 2020, del Mapa

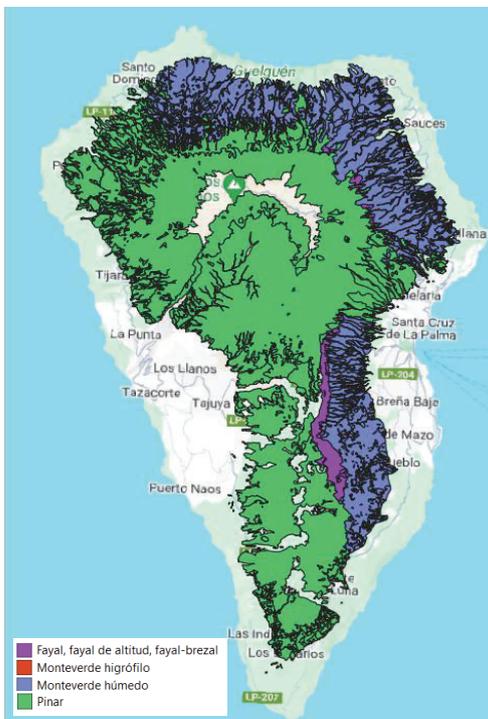
Forestal Español de 2018, del Sistema de Información sobre la Ocupación del Suelo en España (SIOSE) de 2017 y el Corine Land Cover junto al Backbone de 2021. Tras analizar las diferentes fuentes presentadas, se ha considerado la del Gobierno de Canarias como la más fiable para el análisis a realizar en este Trabajo de Fin de Grado.



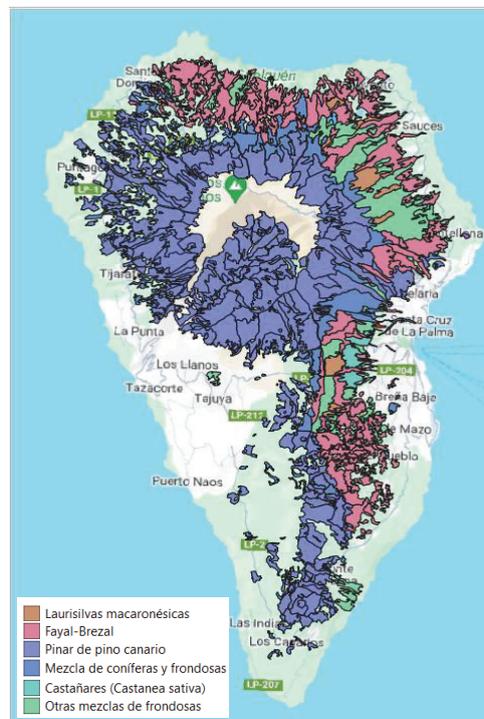
(a)



(b)



(c)



(d)

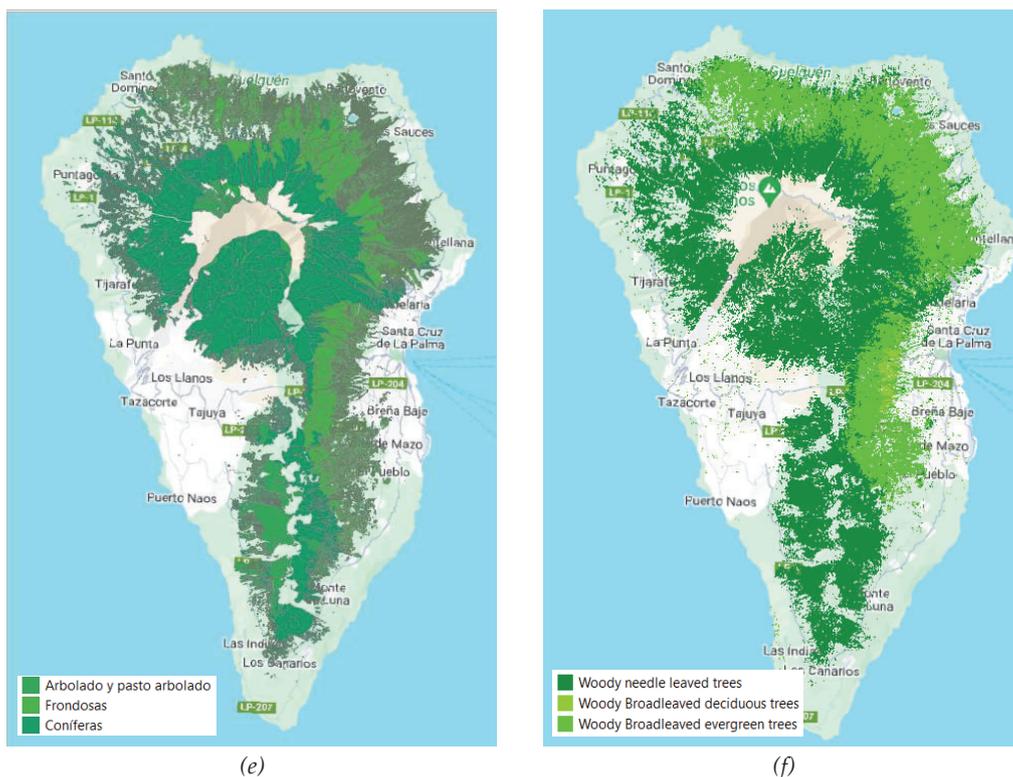


Figura 6: Cartografía de con la vegetación forestal mayoritaria de La Palma: (a) foto de pinares y laurisilvas, (b) Gobierno de Canarias (2021), (c) Cabildo de la Palma (PIOLP 2020), (d) Mapa Forestal Español (2018), (e) SIOSE de Alta Resolución (2017), y (f) Corine Land Cover + BackBone (2021).

4.2. Datos utilizados

Para realizar el análisis de la cubierta forestal de La Palma se han utilizado principalmente dos fuentes de datos: imágenes satelitales Sentinel-2 obtenidas a través del programa Copernicus y cartografías forestales existentes de La Palma.

Se ha llevado a cabo un análisis minucioso de cada imagen disponible desde 2019 hasta 2024, seleccionando las imágenes mensuales con la menor nubosidad posible y procurando que mantengan una diferencia temporal constante entre ellas para garantizar la coherencia y la calidad de los datos en el estudio.

Cabe destacar que, a partir del 25 de enero del 2022, la Agencia Europea Espacial introdujo una nueva versión del algoritmo de procesamiento: Processing Baseline 04.00. Con esto realizaron ajustes en la reflectancia para mejorar la precisión de los datos, sin embargo, para efectuar las mejoras se tuvo que hacer desplazamiento de 1000 en los valores digitales de las imágenes a partir de esa fecha, permitiendo una mayor coherencia entre las bandas y facilitando el trabajo para futuras correcciones radiométricas. Esto resulta en que las imágenes anteriores y posteriores a la fecha en la que se realizó el desplazamiento de valores

digitales se encuentran en diferentes escalas, haciendo que los valores de reflectancia sean incompatibles entre ellas. Para solucionar estas inconsistencias en los análisis temporales, Google Earth Engine dispone de la colección de imágenes Sentinel-2 Harmonized [37], que se encarga de hacer un ajuste automático a las imágenes nuevas para que los valores digitales coincidan en la misma escala que los de las antiguas evitando así tener que hacer ajustes manuales.

Además, las imágenes capturadas por Sentinel-2 que se han utilizado son de nivel 2A. Por lo tanto, ya vienen incorporadas con las correcciones geométricas, radiométricas y atmosféricas, que permite eliminar las distorsiones espaciales y las asociadas al sensor y las causadas por la atmósfera como, por ejemplo, la absorción de luz o la dispersión. Gracias a esto, no es necesario hacer una fase de preprocesamiento para las imágenes.

Por otro lado, en el Anexo 1 están recogidas todas las imágenes elegidas para analizar la cubierta forestal de La Palma. A pesar de que de que se hayan elegido las imágenes con menor nubosidad posible, para realmente asegurar que las condiciones atmosféricas interfieran lo menos posible en este estudio, hace falta un paso previo antes de poder analizar la salud forestal con los Índices de Vegetación. Este se basa en eliminar la mayor cantidad de nubes posibles de la imagen de referencia haciendo un fusionado con una o más imágenes que se encuentren temporalmente cerca con el fin de tener la imagen con la menor nubosidad posible. Estas imágenes también se encuentran incluidas en el Anexo 1. En la Tabla 2 se representan las fechas de captura de las imágenes de referencia elegidas, así como las fechas de las imágenes complementarias para realizar la fusión de imágenes. Además, en la Tabla 3 y en la Figura 7 se muestra la diferencia temporal entre las imágenes mensuales seleccionadas.

Tabla 2: Fechas de captura de imágenes.

FECHA DE CAPTURA		2019	2020	2021	2022	2023	2024
Enero		09/01/2019	14/01/2020	28/01/2021	03/01/2022	18/01/2023	23/01/2024
	mosaicado	14/01/2019	19/01/2020			08/01/2023	
Febrero		13/02/2019	03/02/2020	17/02/2021	17/02/2022	12/02/2023	02/02/2024
	mosaicado				07/02/2022	02/02/2023	
Marzo		10/03/2019	04/03/2020	04/03/2021	24/03/2022	29/03/2023	18/03/2024
	mosaicado	30/03/2019		24/03/2021	14/03 + 08/04		18/03/2024
Abril		29/04/2019	08/04/2020	02/04/2021	28/04/2022	28/04/2023	17/04/2024
	mosaicado	14/04/2019	18/04/2020				
Mayo		24/05/2019	23/05/2020	18/05/2021	08/05/2022	08/05/2023	07/05/2024
	mosaicado			23/05/2021	28/04/2022	28/04/2023	
Junio		03/06/2019	22/06/2020	12/06/2021	07/06/2022	27/06/2023	01/06/2024
	mosaicado		02/06/2020				06/06/2024
Julio		23/07/2019	12/07/2020	22/07/2021	27/07/2022	12/07/2023	26/07/2024
	mosaicado						
Agosto		22/08/2019	21/08/2020	21/08/2021	06/08/2022	16/08/2023	10/08/2024
	mosaicado				26/08 + 16/08		
Septiembre		01/09/2019	20/09/2020	10/09/2021	15/09/2022	30/09/2023	24/09/2024
	mosaicado	22/08/2019			05/09/2022		04/10/2024
Octubre		01/10/2019	15/10/2020	15/10/2021	20/10/2022	10/10/2023	04/10/2024
	mosaicado		25/10/2020				
Noviembre		30/11/2019	14/11/2020	09/11/2021	14/11/2022	19/11/2023	28/11/2024
	mosaicado	10/12/2019	29/11/2020	19/11/2021	29/11/2022		03/12/2024
Diciembre		10/12/2019	19/12/2020	14/12/2021	24/12/2022	29/12/2023	18/12/2024
	mosaicado	30/11/2019	29/11/2020	29/12/2021			

* La fecha subrayada indica la fecha de imagen que se ha tomado como referencia.

Tabla 3: Diferencia de días entre las imágenes con respecto al mes anterior.

Diferencia de días con respecto al mes anterior	2019	2020	2021	2022	2023	2024
Enero	COMIENZO	35	40	20	25	25
Febrero	35	20	20	45	25	10
Marzo	25	30	15	35	45	45
Abril	50	35	29	35	30	30
Mayo	25	45	46	10	10	20
Junio	10	30	25	30	50	25
Julio	50	20	40	50	15	55
Agosto	30	40	30	10	35	15
Septiembre	10	30	20	40	45	45
Octubre	30	25	35	35	10	10
Noviembre	60	30	25	25	40	55
Diciembre	10	35	35	40	40	20



Figura 7: Gráfico representando la diferencia de días entre las imágenes.

4.2.1. Generación de la máscara de nubes

Antes de poder llevar a cabo la fusión de imágenes, es necesario hacer una máscara de nubes para poder eliminar los píxeles que correspondan a nubes en la imagen de referencia y sustituirlos por los píxeles libres de nubes de la imagen complementaria. En la Figura 8 se detalla el diagrama de flujo del proceso general que se ha llevado a cabo.

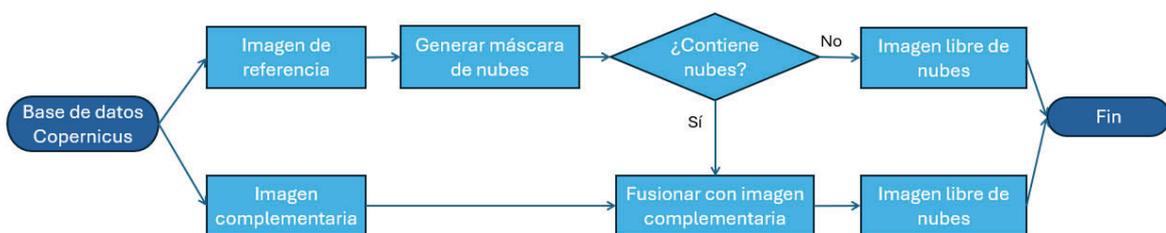


Figura 8: Diagrama de flujo general.

Estas operaciones sobre las imágenes se han realizado en el lenguaje de programación JavaScript en la plataforma de datos satelitales Google Earth Engine, que está compuesta por imágenes satelitales y por conjuntos de datos geoespaciales que permite análisis a escala planetaria [38].

Tal y como está especificado en el catálogo de datos de Google Earth Engine, Sentinel-2 incluye una capa de clasificación de escenas llamada Scene Classification Layer (SCL) [39]. Tal y como se ve en la Tabla 4, esta capa clasifica cada píxel en diferentes categorías.

Tabla 4: Banda Scene Classification Layer (SCL).

SCL	
Class	Pixel value
No Data	0
Saturated Or Defective	1
Dark Area Pixels	2
Cloud Shadows	3
Vegetation	4
Not Vegetated	5
Water	6
Unclassified	7
Cloud Medium Probability	8
Cloud High Probability	9
Thin Cirrus	10
Snow	11

Atendiendo a la Tabla 4, los valores de esta capa que interesan para enmascarar las nubes y sus sombras son el 3 (sombra de nubes), 8 (nubes medias), 9 (Nubes altas) y 10 (cirros).

Al ejecutar este código en Google Earth Engine, se ha apreciado que la máscara de nubes proporcionada por el propio Sentinel-2 usando la banda SCL no es precisa, tal y como se muestra en los ejemplos de la Figura 9.

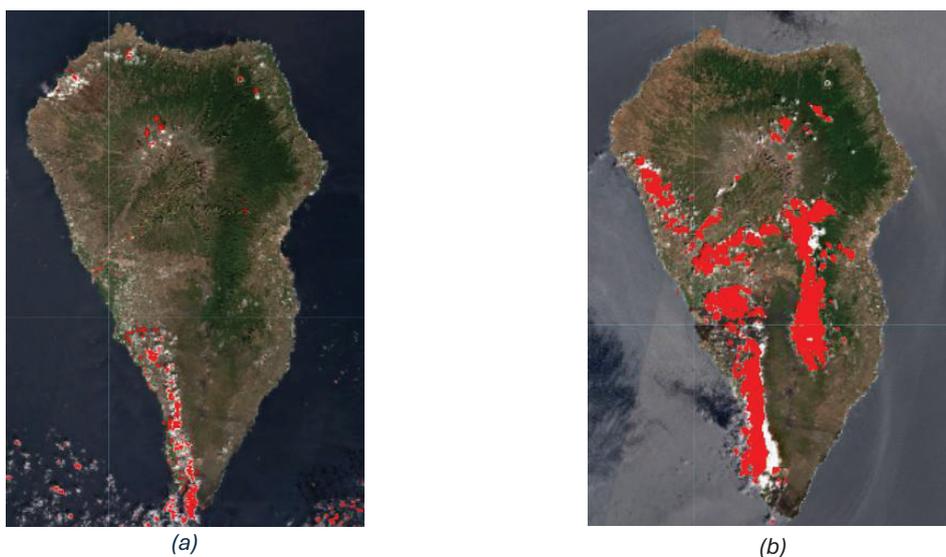


Figura 9: Máscara de nubes SCL: (a) 15/10/2020 y (b) 16/08/2020.

A modo de ejemplo, se presenta el código empleado para realizar esta máscara de nubes.

```
function generarMascaras(image) {
  var scl = image.select("SCL");

  var maskNubes = scl.eq(3).or(scl.eq(8)).or(scl.eq(9)).or(scl.eq(10));
  // Sombra de nubes, nubes medias, nubes altas, cirrus

  return {
    maskNubes: maskNubes,
  };
}
```

Para solucionar esto, se ha usado como referencia un código de enmascaramiento de nubes proporcionado por la comunidad de Google Earth Engine [40]. Concretamente se trata del uso de `s2cloudless`, cuyo objetivo es hacer una máscara de nubes usando datos de probabilidad de nubes y proyecciones de sombras de nubes. Primero se definen los parámetros que se usaran a lo largo del código.

- AOI: área de interés.
- START_DATE_A: Fecha de inicio para búsqueda de imagen de referencia.
- END_DATE_A: Fecha final para búsqueda de imagen de referencia.
- START_DATE_B: Fecha de inicio para búsqueda de imagen complementaria.
- END_DATE_B: Fecha final para búsqueda de imagen complementaria.
- CLOUD_FILTER: Máximo porcentaje de nubes permitido en la imagen.
- CLD_PRB_THRESH: Umbral (en porcentaje) a partir del cual se considera como un píxel cubierto por nubes.
- NIR_DRK_THRESH: Umbral de reflectancia en el infrarrojo cercano con el que se detectan sombras de nubes.
- CLD_PRJ_DIST: Distancia máxima de búsqueda de sombras alrededor de una nube.
- BUFFER: Distancia de dilatación de la máscara de nubes y sombras.

Una vez definidos los parámetros, se procede a hacer un filtrado de imágenes en dos colecciones Sentinel-2: la colección armonizada de Sentinel-2 con las reflectancias de superficie (`S2_SR_HARMONIZED`) y la colección de probabilidad de nubes (`S2_CLOUD_PROBABILITY`). Mediante un sistema de emparejamiento según el identificador de imagen (`system:index`), se combinan ambas colecciones para que cada imagen tenga asociada su respectivo mapa de probabilidades.

El siguiente paso consiste en añadir una banda de probabilidad de nubes usando los valores de `s2cloudless` y otra banda de máscara de nubes en la que en píxel se definirá como nube si

la probabilidad de nubes supera el umbral `CLD_PRB_THRESH`, en este Trabajo de Fin de Grado tras diferentes pruebas, se estableció un valor de 35%.

También se añaden tres bandas para poder realizar la detección de las sombras. La primera añade píxeles con baja reflectancia en el infrarrojo cercano, que podrían ser sombras. Luego otra banda con las sombras proyectadas desde los bordes de las nubes usando la dirección y el ángulo azimut. La última banda es la intersección de estas dos bandas, que finalmente contiene la información de las sombras de nubes detectadas.

Por último, se combinan todas estas bandas de nubes y sombras y se crea una máscara binaria donde los píxeles con valor de 1 están cubiertos por nubes o sombras. A estos píxeles se le realizan transformaciones para eliminar áreas muy pequeñas de nubes y sombras y, finalmente, se dilata la máscara final utilizando el `BUFFER` en la medida que sea necesario. El valor usado para el `BUFFER` fue 60, lo que se traduce en un buffer de 6 píxeles alrededor de las nubes y las sombras.

A pesar de que teóricamente debería funcionar adecuadamente, se ha detectado que este código aplicado en nuestra región de interés tiene fallos a la hora de la detección de las sombras de nubes. Volviendo a evaluar la detección de nubes de la banda SCL, se ha llegado a la conclusión de que precisamente la detección de sombras de nubes obtiene mejores resultados en la banda SCL que en código utilizado. Por lo que, se aprovechará lo mejor de cada máscara uniéndolas con una operación lógica tipo OR para asegurar una detección lo más perfecta posible. A continuación, se aprecia en la Figura 10 la mejora de la máscara de nubes aplicando estos cambios con respecto a las máscaras de nubes proporcionadas por Sentinel-2 para la imagen de agosto de 2020.

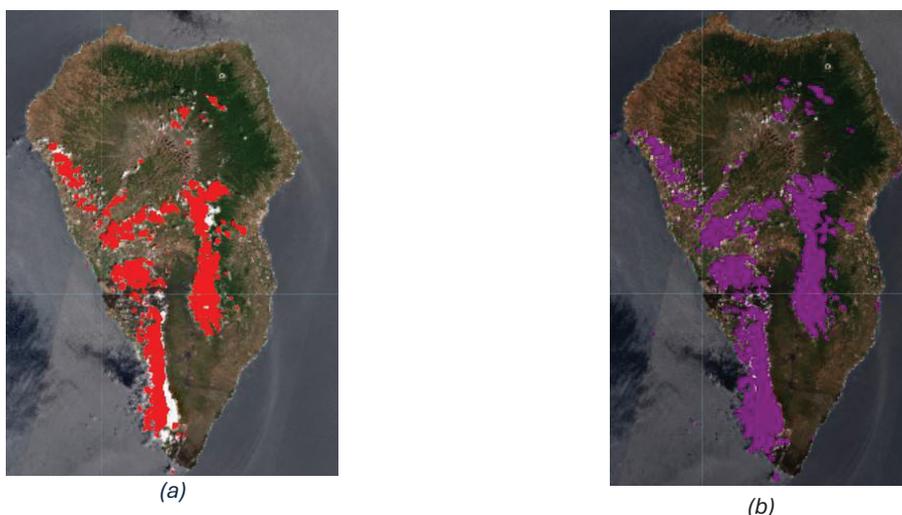


Figura 10: Comparación entre máscaras: (a) Máscara SCL 16/08/2020 y (b) Máscara final 16/08/2020.

4.2.2. Fusión de imágenes

Una vez realizada la máscara de nubes, ya están identificados aquellos píxeles que se tienen que sustituir por los píxeles de la imagen complementaria. Cabe destacar que hay casos en los que no se pueden eliminar completamente todas las nubes debido a la complejidad de detección de las mismas, dependiendo de su tipo y a la densidad de nubes tanto en la imagen de referencia como en las complementarias. Incluso hay ocasiones donde en meses muy nubosos ni siquiera es posible conseguir una imagen complementaria ya que no hay ninguna que nos proporcione una mejora con respecto a la de referencia. Por tanto, la finalidad del fusionado de imágenes es eliminar la máxima cantidad de nubes posible siempre y cuando sea posible.

El planteamiento inicial de la metodología de fusión presentado en la Figura 11, se basaba en una estructura if-else cuya función es hacer la sustitución de los píxeles seleccionados por la máscara de nubes por los píxeles de la imagen complementaria.

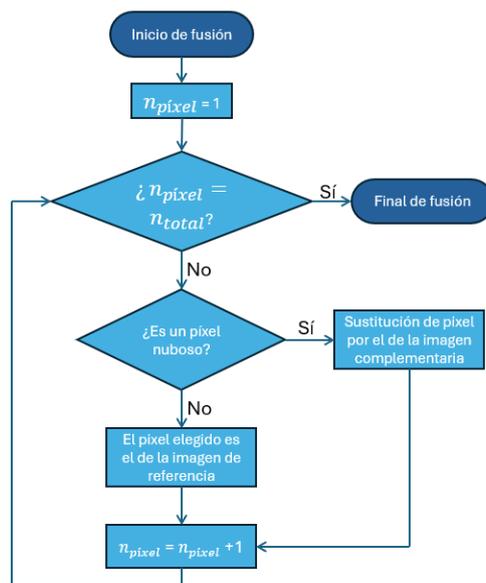


Figura 11: Diagrama de flujo de la estructura if-else.

Sin embargo, las imágenes de Google Earth Engine están compuestas por matrices donde cada píxel contiene información independiente. Al usar este tipo de estructura directamente sobre una imagen se estaría evaluando si toda la imagen en su conjunto cumple la condición, por lo que habría que hacer un análisis píxel por píxel para hacerlo correctamente. Esta manera se requiere de un tiempo considerable y es ineficiente a nivel computacional. Para

solucionar esto, Google Earth Engine tiene estructuras creadas específicamente para imágenes y el adecuado para esta función es el `where` [41].

Esta función realiza un reemplazamiento condicional de píxeles:

```
Imagen_entrada.where(test, value)
```

Funciona de tal manera que cuando el píxel analizado del parámetro `test` sea distinto de 0 se reemplaza por el valor del píxel del parámetro `value`. En caso contrario se mantiene el píxel de la imagen de entrada.

El código por el cual se hará la máscara de nubes y la fusión de imágenes se realiza en Google Earth Engine. Este código se encuentra en el Anexo 2. Por otro lado, una vez realizadas todas las fusiones necesarias se dispone de la serie de imágenes preparada para el posterior análisis del estado de la cubierta forestal de La Palma. En el Anexo 2 se incluyen todas las fusiones de imágenes reflejadas con su máscara de nubes correspondiente.

4.3. Análisis de índices y propuesta de nuevo índice espectral compuesto

Para realizar un estudio en detalle de la salud de la cubierta forestal se requiere el uso de múltiples índices que permitan evaluar distintas propiedades biofísicas de la vegetación. En este apartado se evaluarán todos los índices de vegetación mencionados con el fin de seleccionar aquellos que permitan discriminar la vegetación sana de la que está sufriendo desvitañización y así poder realizar un estudio riguroso. Posteriormente, se presenta la propuesta de un nuevo índice sintético llamado Índice de Salud Forestal Sentinel-2 (ISF-S2), el cual integra la información de los índices seleccionados con el objetivo de obtener una representación unificada y robusta de la salud forestal. El procedimiento llevado a cabo se ve reflejado en la Figura 12.

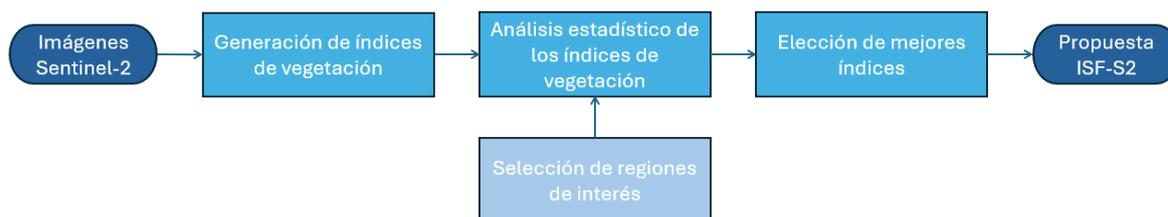


Figura 12: Análisis de índices de vegetación y creación del ISF-S2.

4.3.1. Análisis estadístico de Índices de Vegetación

Tal y como se nombró anteriormente, con el objetivo de realizar el análisis del estado de la vegetación de La Palma, se seleccionarán los índices más adecuados. El criterio empleado se basó en la capacidad de los índices de vegetación para discernir entre vegetación sana, vegetación quemada o enferma, suelo desnudo y suelo construido. Para ello, se han seleccionado dos imágenes de estudio: una del 07/05/2022 (después del volcán) y otra del 10/08/2023 (después del incendio).

Luego, a través de QGIS, se han seleccionado 100 regiones de interés (ROI) por cada año para luego extraer los valores resultantes de cada índice en esas regiones y analizarlos. Las regiones de interés se distribuyen de manera que se seleccionan 25 regiones de interés para cada tipo; vegetación sana, vegetación quemada, suelo desnudo y suelo construido. Cabe destacar que para lograr una mayor precisión a la hora de seleccionar las ROIs se han utilizado dos imágenes capturadas por el sensor SuperDove de la constelación satelital Planet. De las Figuras 13 a la 16 se aprecian las regiones seleccionadas en la imagen del 2022 y de las Figuras 17 a la 20 se muestran las regiones seleccionadas en la imagen del 2023.

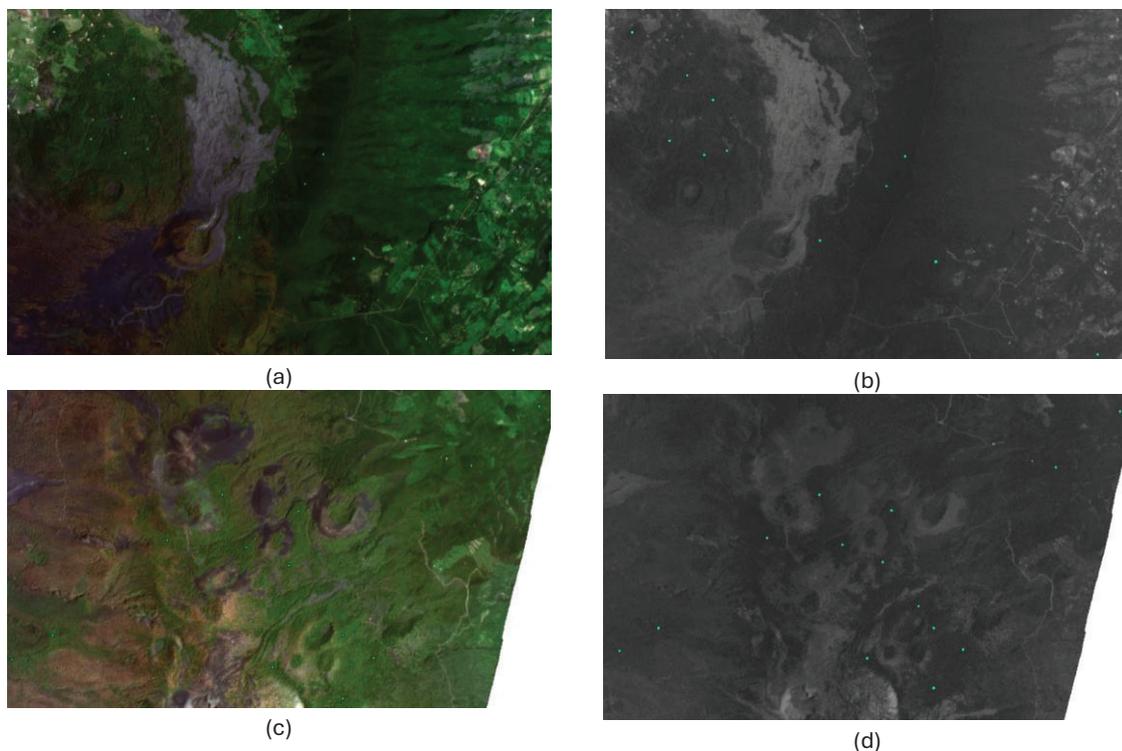


Figura 13: ROIs de vegetación sana de 2022: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.

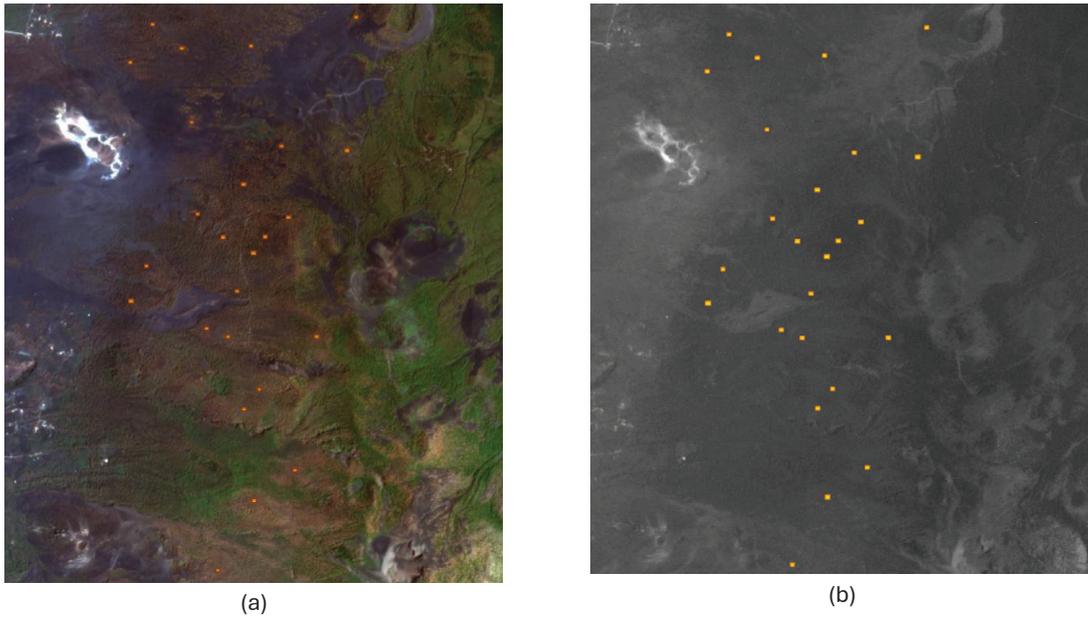


Figura 14: ROIs de vegetación quemada de 2022: (a) ROIs en RGB y (b) ROIs en gris monobanda.

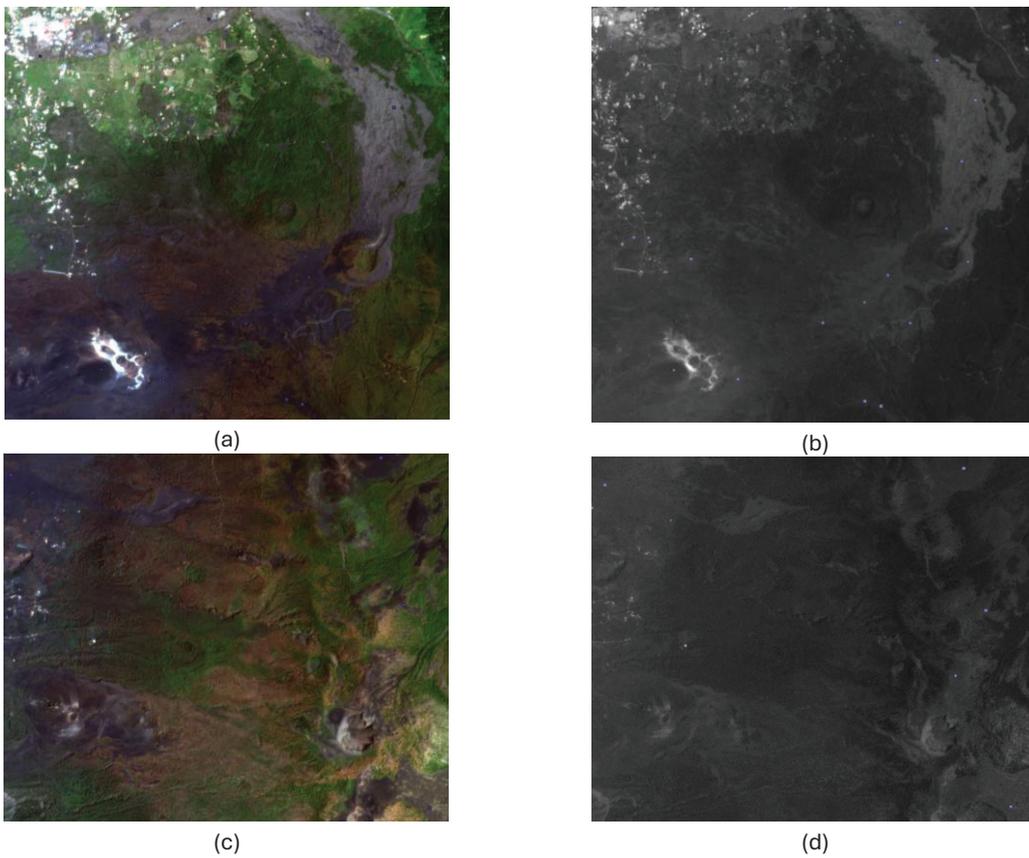


Figura 15: ROIs de suelo desnudo de 2022: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.

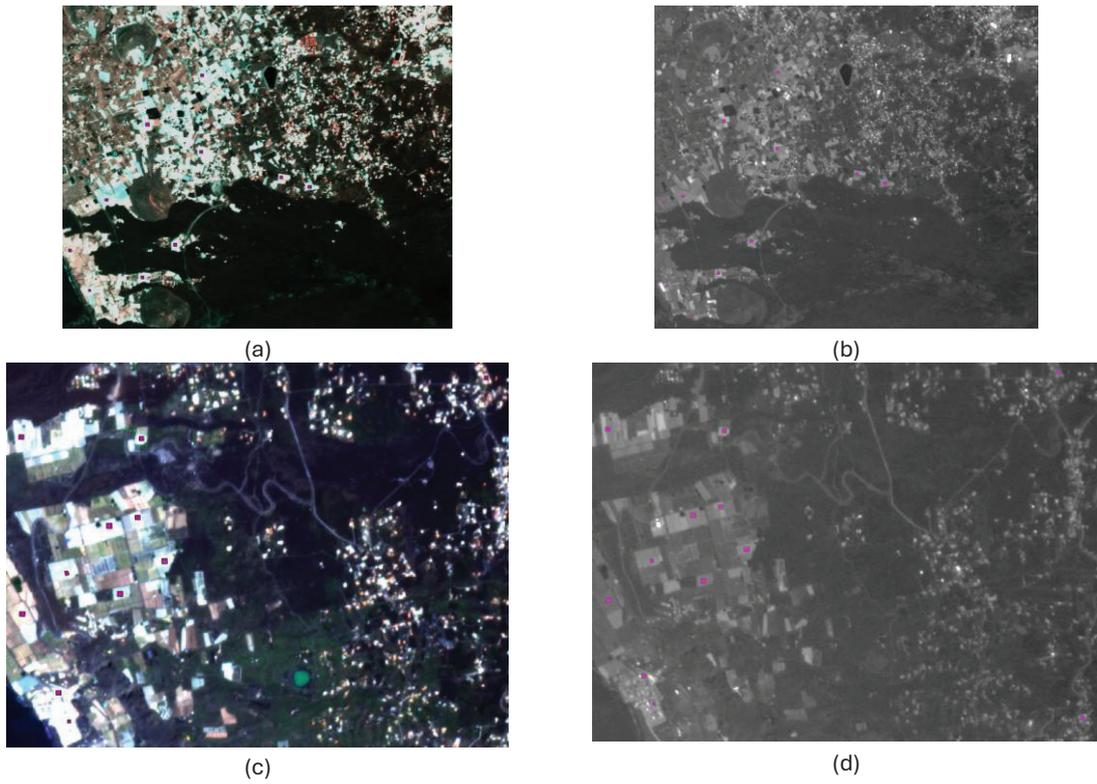


Figura 16: ROIs de suelo construido de 2022: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.

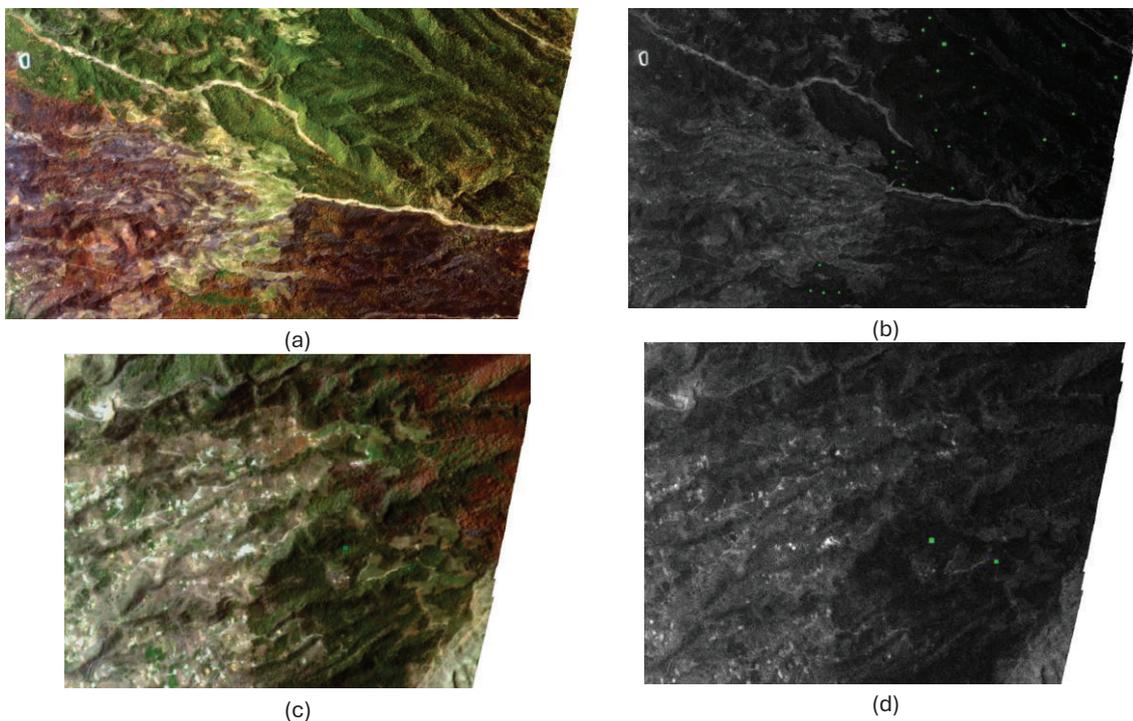


Figura 17: ROIs de vegetación sana de 2023: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.

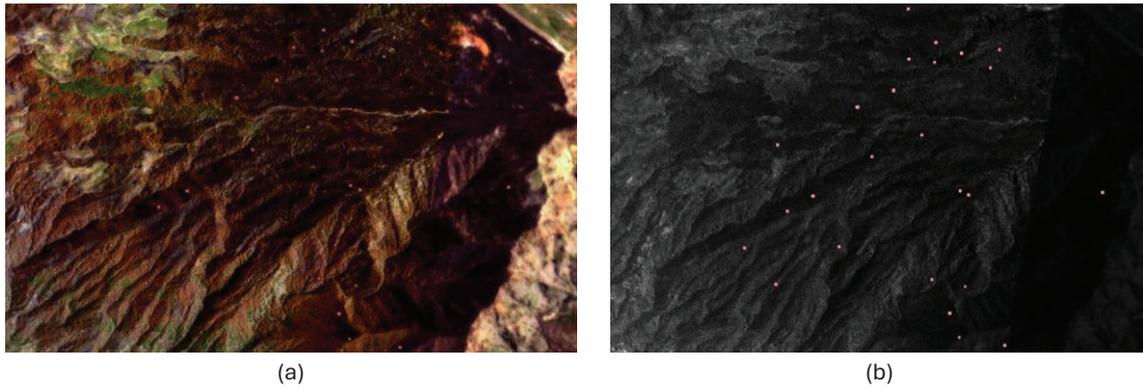


Figura 18: ROIs de vegetación quemada de 2023: (a) ROIs en RGB y (b) ROIs en gris monobanda.

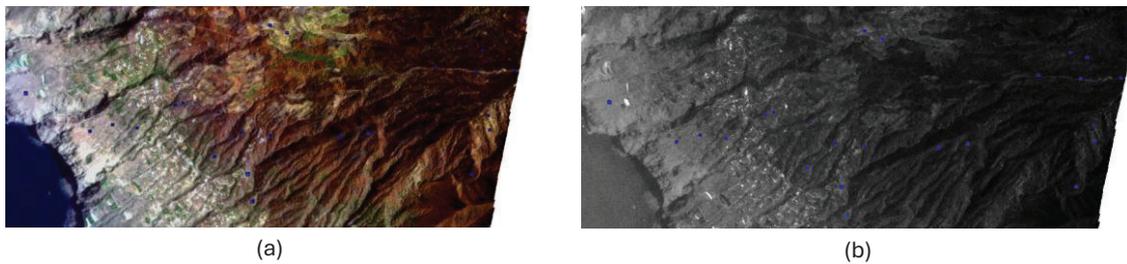


Figura 19: ROIs de suelo desnudo de 2023: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.

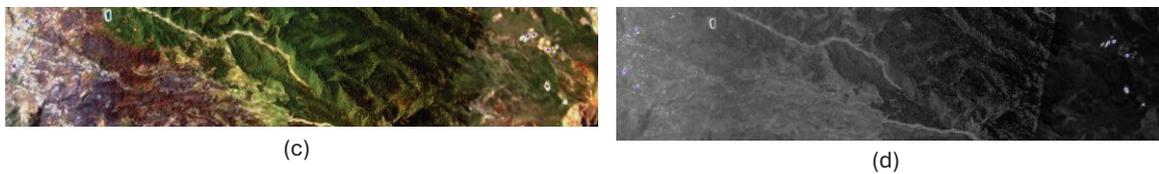
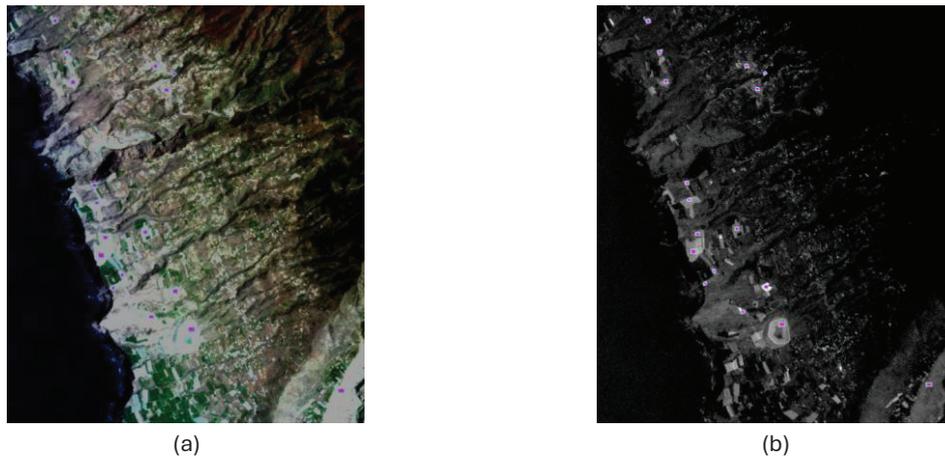


Figura 20: ROIs de suelo construido de 2023: (a) y (c) ROIs en RGB, (b) y (d) ROIs en gris monobanda.

El siguiente paso es generar todos los índices de vegetación con las imágenes Sentinel-2 del 07/05/2022 y del 10/08/2023. Debido a que los índices tienen distintos rangos en sus resultados, es necesario normalizarlos todos de 0 a 1 para así poder comparar en las mismas condiciones. Por tanto, en la Figura 21 se presentan todos los índices normalizados mencionados previamente para la imagen de agosto de 2023.



NDVI



EVI



SAVI



MSAVI2



GNDVI



SR



MSR



GEMI



WDRVI



WVI



ARVI



MCARI2



TCARI



MTVI2



RENDVI



REPI



SIPI



CCI



ARI2



CRI2



PSRI



NPCR



DWSI



NBR

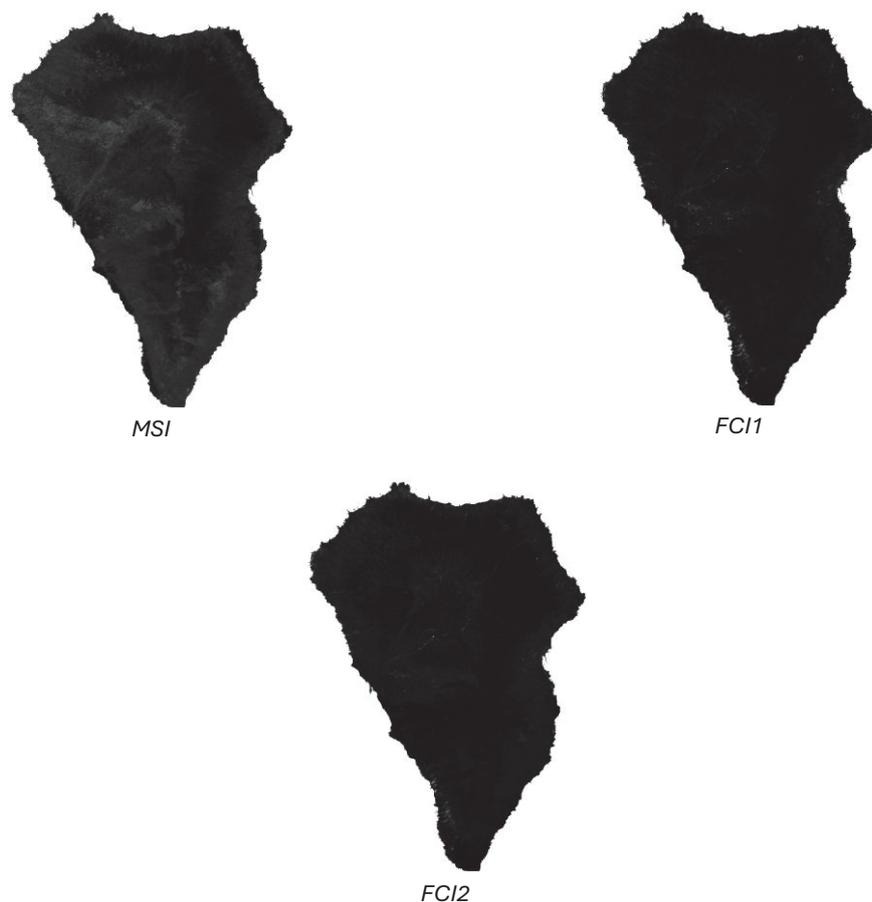


Figura 21: Índices de vegetación aplicados a la imagen del 2023.

Una vez los índices están preparados, se obtendrá el valor de cada índice en cada ROI. El código desarrollado para generar los índices normalizados y para obtener los valores de esos índices en las ROIs seleccionadas se encuentra en el Anexo 3.

Posteriormente, se han utilizado esos valores para hacer un diagrama de caja y bigote por cada índice para los dos años, siendo así posible poder analizar la separabilidad de cada índice. Los mejores índices serán seleccionados según su capacidad para diferenciar la vegetación sana de la quemada. Esto se hará de tal manera que se resta el valor del primer cuartil de la vegetación sana al valor del tercer cuartil de la vegetación quemada obteniendo así la separabilidad de todos los índices.

A modo de ejemplo, en la Figura 22 se muestra el diagrama del NDVI donde se aprecia una buena separabilidad mientras que en la Figura 23 se muestra el diagrama del NPCR donde se aprecia una mala separabilidad para la vegetación sana. Los diagramas de caja y bigote de todos los índices para 2022 y 2023 se encuentran en el Anexo 4.

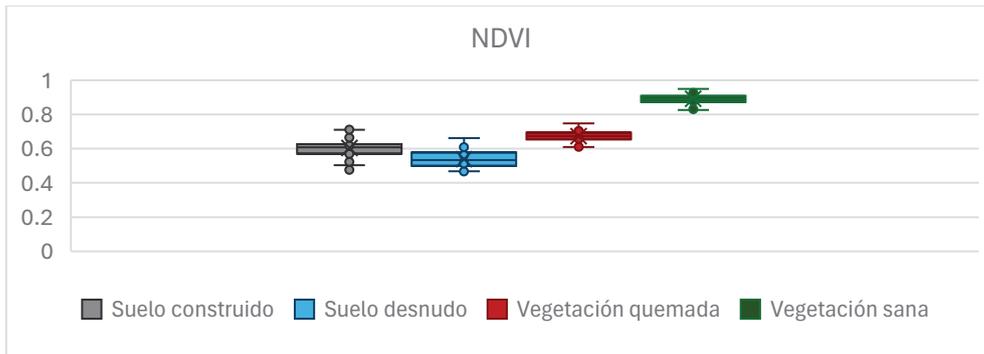


Figura 22: Diagrama de caja y bigote del NDVI para 2022.

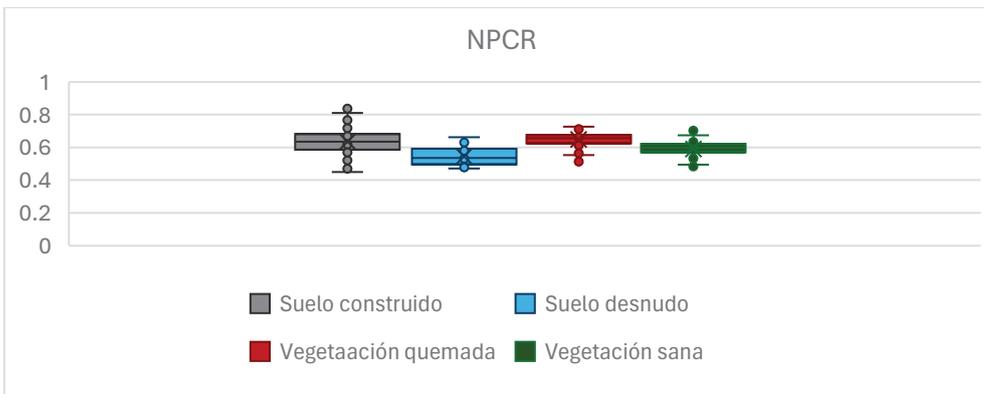


Figura 23: Diagrama de caja y bigote del NPCR para 2022.

En la Figura 24 se ven reflejadas las separabilidades de cada índice entre la vegetación sana y desvitalizada para la imagen del 2022 y la del 2023. Aquellos índices con valores mayores tendrán más capacidad para discriminar la vegetación sana y quemada.

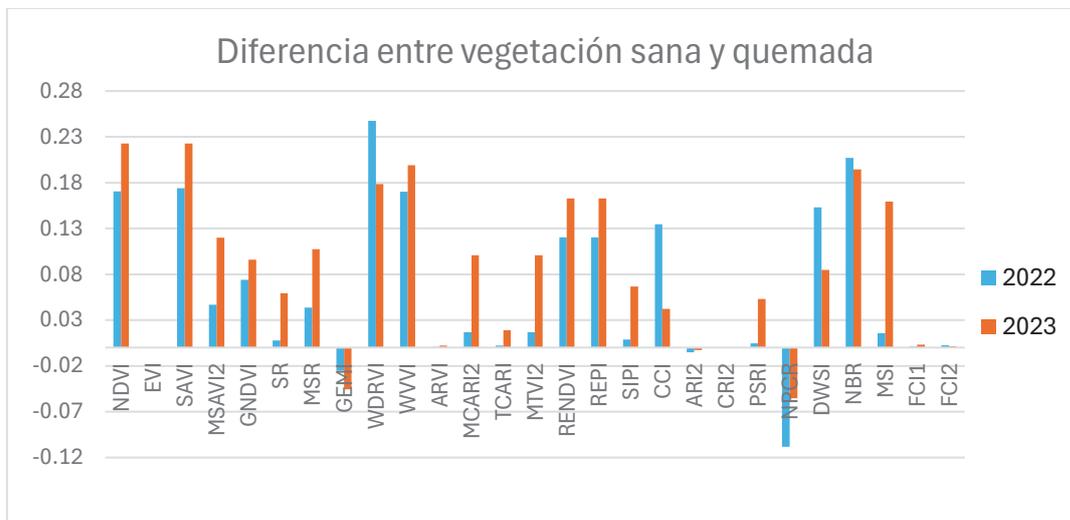


Figura 24: Gráfico que muestra la separabilidad entre vegetación sana y quemada para cada índice.

Para que el análisis de la cubierta forestal sea completo y robusto, lo ideal es elegir el mejor índice de cada categoría. En la Figura 24 se aprecia que el índice de banda ancha más adecuado es el WDRVI y el más adecuado de la banda estrecha es el RENDVI. El CCI es el elegido entre los índices de eficiencia de uso de la luz y, en el caso de los índices de humedad, se optó por analizar el DWSI y el NBR pues, aunque NBR dé mejores resultados, como se verá en la Figura 28, el DWSI tiene también buena capacidad de discriminación entre todas las clases. Estos índices de humedad son especialmente relevantes debido a que usan información de la banda de infrarrojo de onda corta (SWIR), información que se encuentra únicamente disponible de forma gratuita gracias al satélite Sentinel-2. Por último, tanto el PSRI como el NPCR no proporcionan resultados favorables por lo que se descarta el uso de índices de senescencia.

A continuación, en las Figuras 25 a 29 se presentan los diagramas de los 5 índices elegidos para 2022, mientras que en las Figuras 30 hasta la 34 se encuentran los diagramas para 2023.

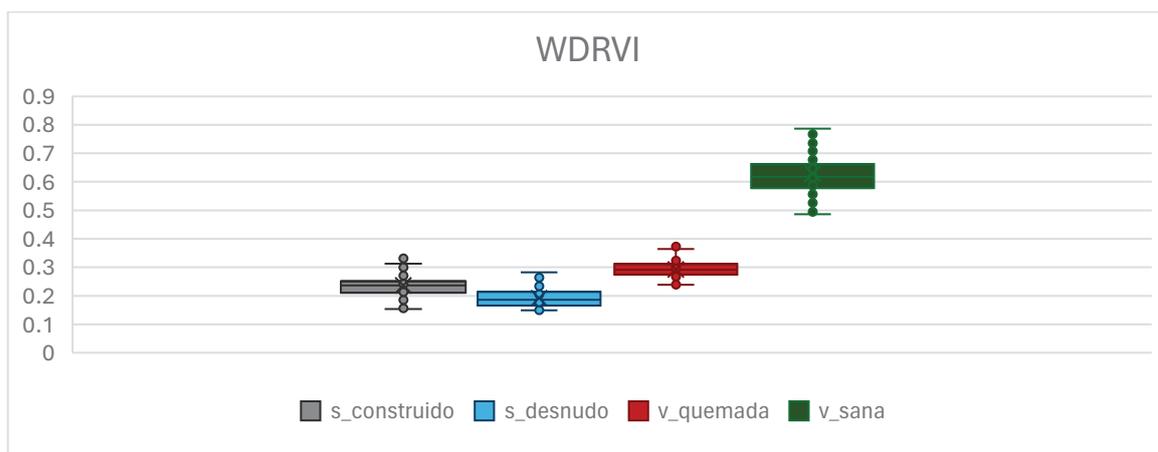


Figura 25: Diagrama de caja y bigote del WDRVI para 2022.

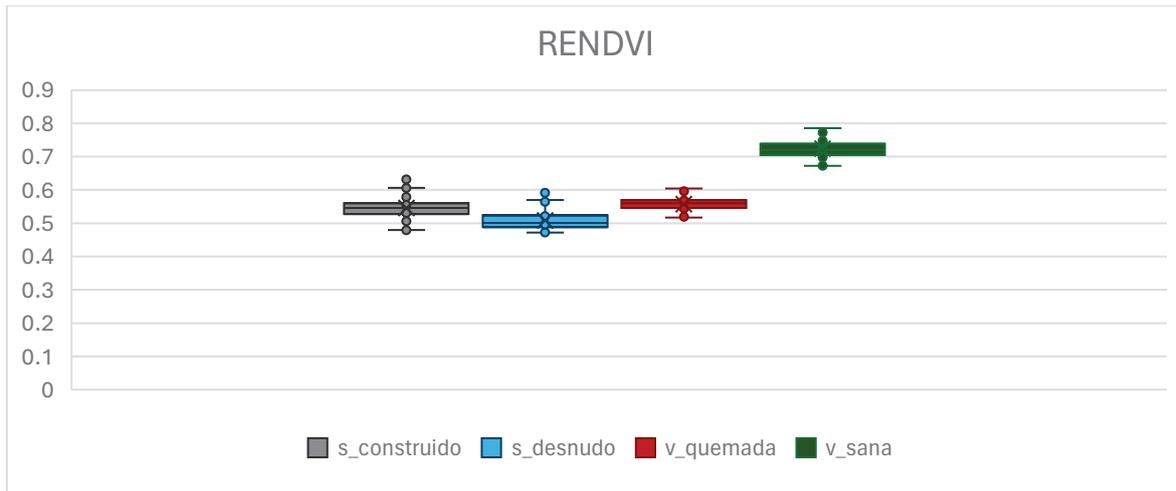


Figura 26: Diagrama de caja y bigote del RENDVI para 2022.

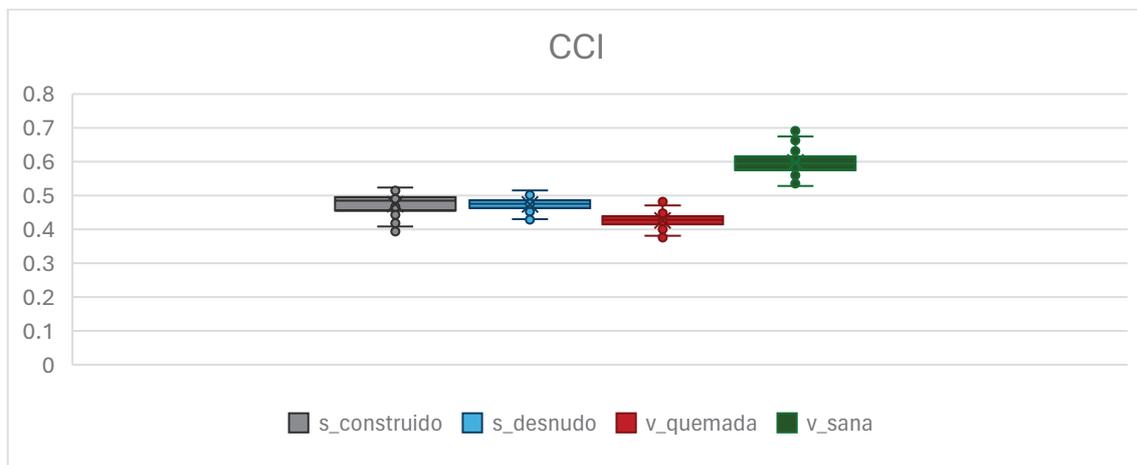


Figura 27: Diagrama de caja y bigote del CCI para 2022.

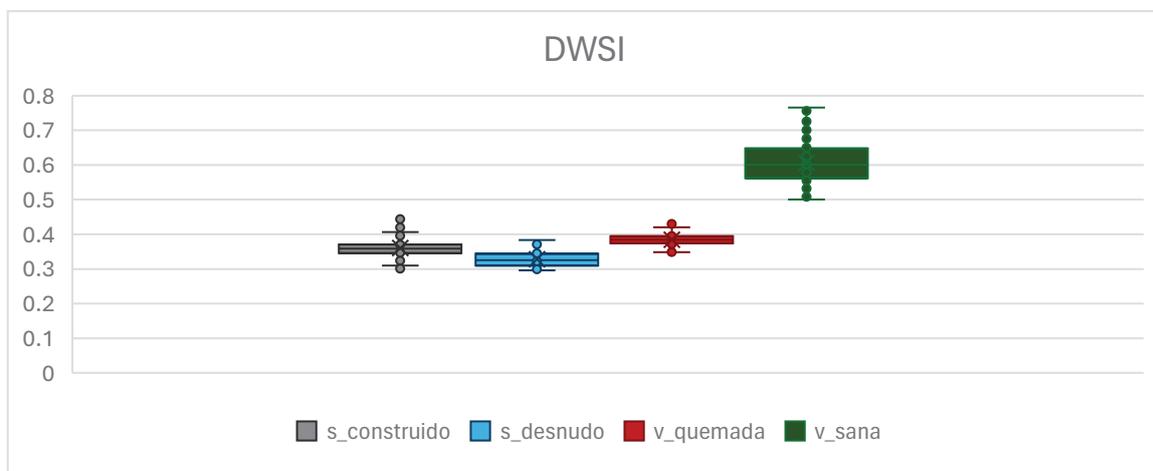


Figura 28: Diagrama de caja y bigote del DWSI para 2022.

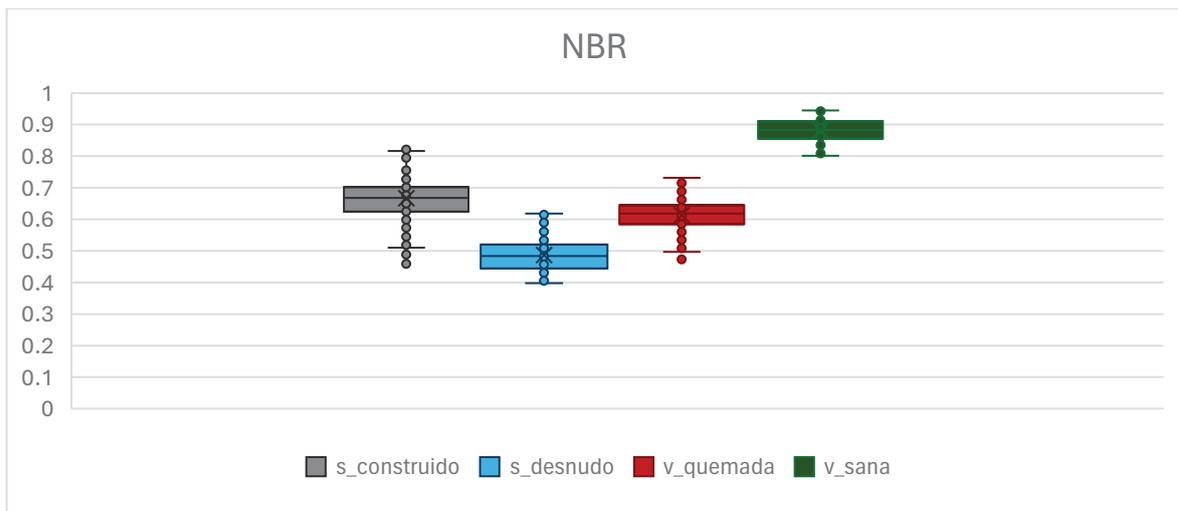


Figura 29: Diagrama de caja y bigote del NBR para 2022.

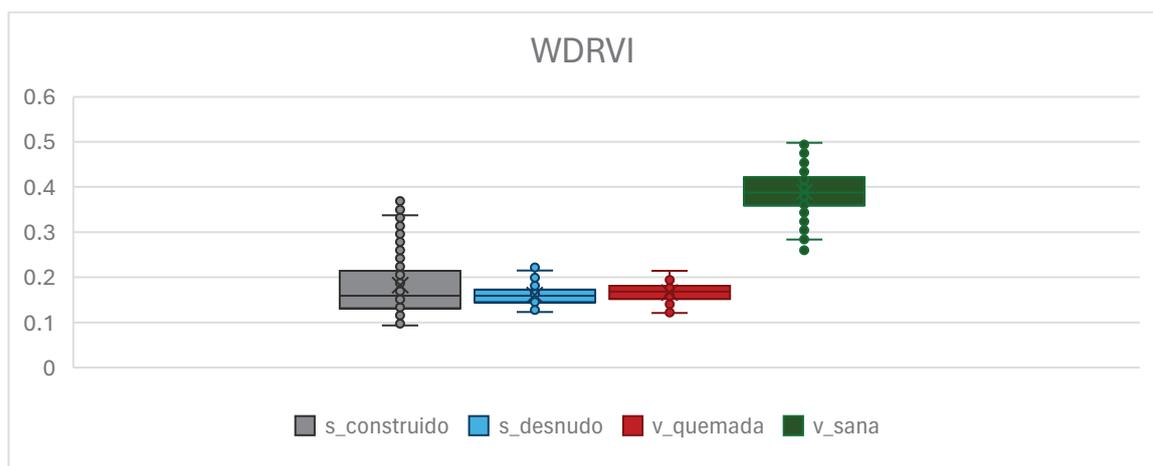


Figura 30: Diagrama de caja y bigote del WDRVI para 2023.

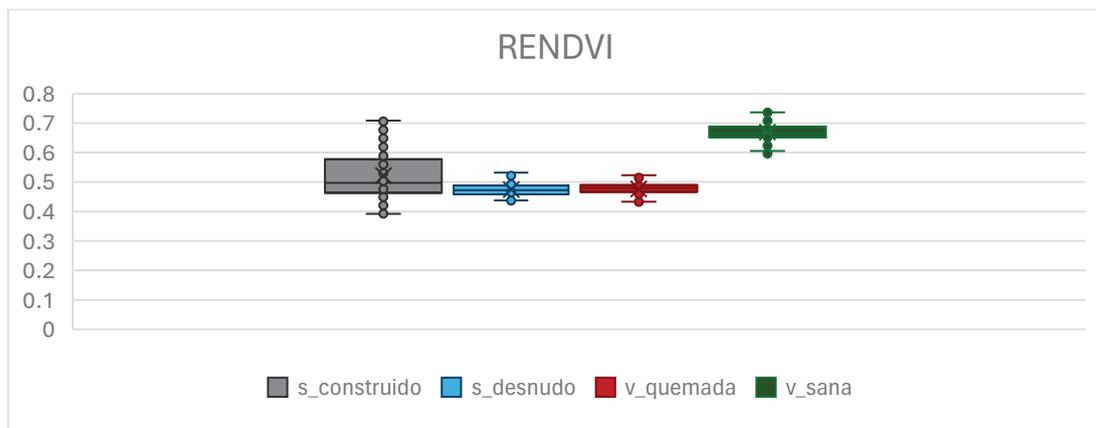


Figura 31: Diagrama de caja y bigote del RENDVI para 2023.

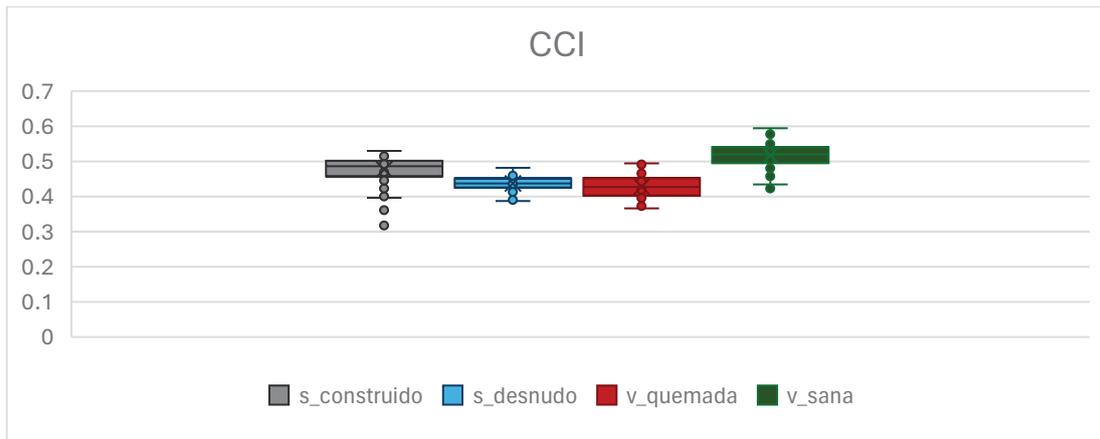


Figura 32: Diagrama de caja y bigote del CCI para 2023.

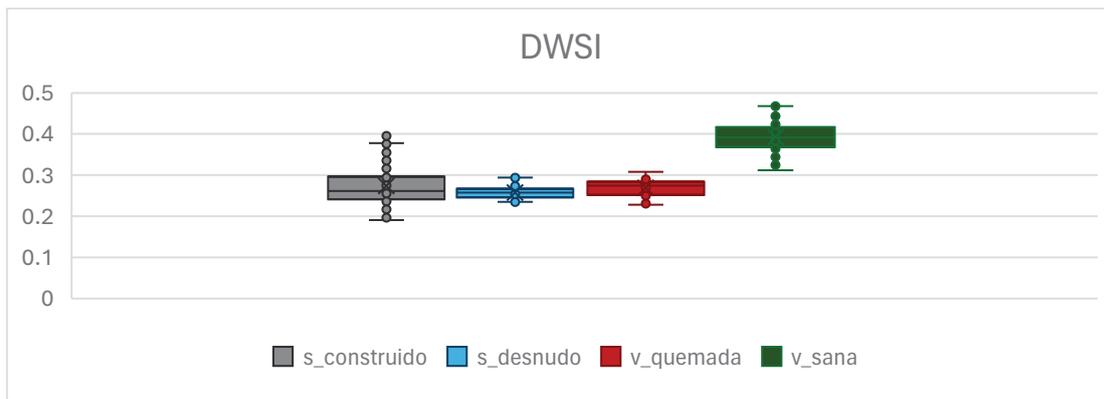


Figura 33: Diagrama de caja y bigote del DWSI para 2023.

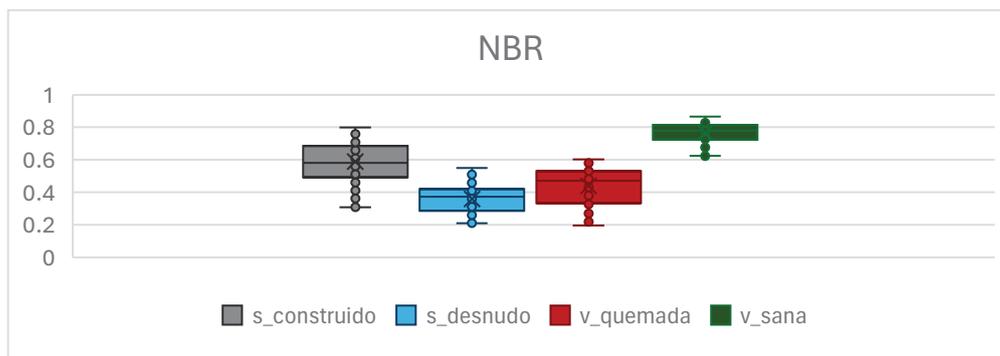


Figura 34: Diagrama de caja y bigote del NBR para 2023.

4.3.2. Propuesta de Índice de Salud Forestal Sentinel-2

Una vez elegidos los índices con mejor separabilidad, se hará un análisis en profundidad del funcionamiento de cada uno en distintas zonas de la isla durante toda la serie temporal. Para ello se han definido 43 parcelas que abarcan la mayoría de los tipos de vegetación (pinares, laurisilva, fayal-brezal, etc) y zonas importantes como la de Cabeza de Vaca en el municipio de El Paso (zona de erupción del volcán) y la zona de interfaz urbano forestal en el municipio de Puntagorda (zona de origen del incendio del 2023).

Seguidamente, se ha seleccionado un píxel específico con cubierta forestal densa en cada una de las 43 parcelas estipuladas y se aplicará cada uno de los índices en dichos píxeles para evaluar su funcionamiento. En la Figura 35 se muestran los 43 píxeles escogidos con el propósito de analizar los índices en la serie de imágenes mensuales de 2019 a 2024. En el Anexo 5 se incluyen los resultados para cada parcela de la evolución cada índice a lo largo de los meses.

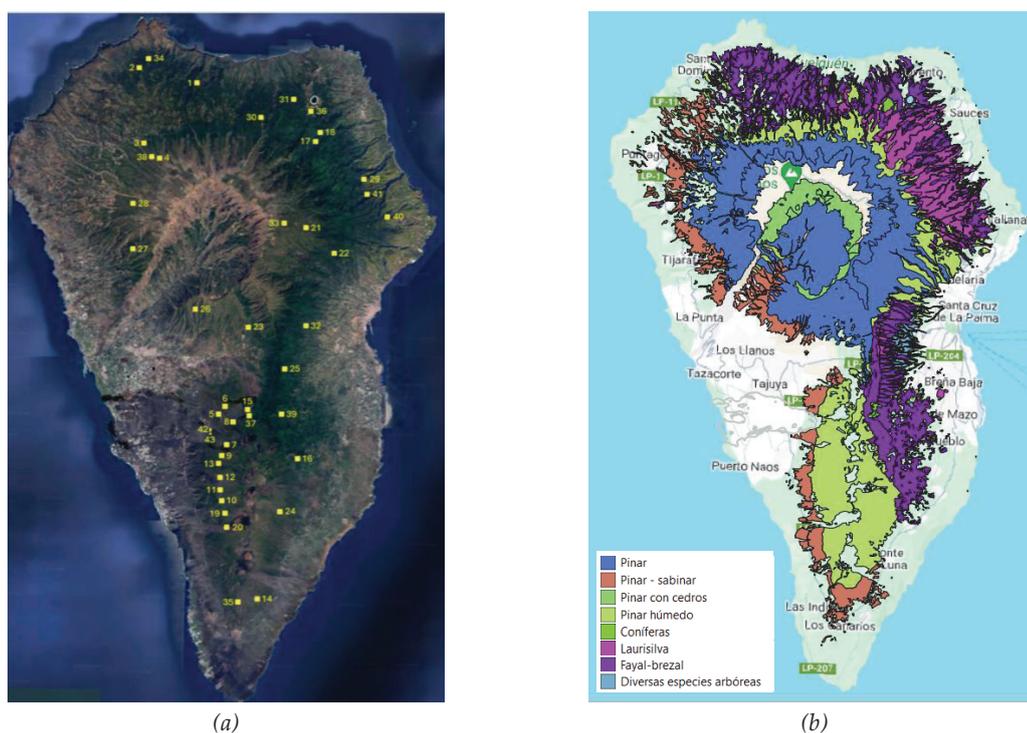


Figura 35: Parcelas seleccionadas para evaluar los índices: a) píxeles elegidos y b) mapa de vegetación del Gobierno de Canarias de 2021.

Inicialmente se propuso crear un nuevo índice de vegetación conformado por la media de los 5 índices seleccionados con el fin de unificar en un único valor la información más relevante

acerca del estado de la vegetación. Sin embargo, tras un análisis de las gráficas del Anexo 5 se apreciaron limitaciones importantes en el comportamiento del CCI y DWSI. Estos índices no aportaban información adicional significativa respecto a los índices seleccionados y, además, introducían comportamientos anómalos en algunas zonas que distorsionaban el promedio. En esa misma línea, el DWSI también mostró una sensibilidad excesiva a variaciones ajenas al estado de la vegetación generando datos poco fiables.

Como resultado, el índice final, denominado como Índice de Salud Forestal Sentinel-2 (ISF-S2), está compuesto por el promedio entre los índices WDRVI, RENDVI y NBR, tal y como se aprecia en la ecuación 28. Esto se debe a que mostraron un comportamiento consistente y con buena capacidad de discriminación entre diferentes superficies. El análisis del comportamiento del ISF-S2 en cada parcela también se encuentra en el Anexo 5.

$$\text{ISF-S2} = \frac{\text{WDRVI} + \text{RENDVI} + \text{NBR}}{3} \quad (28)$$

4.4. Análisis de la cubierta forestal

En este apartado se estudiará la evolución de la cubierta forestal de La Palma. En primer lugar, se creará el ISF-2 para, posteriormente, evaluar el estado de la vegetación a lo largo de la serie temporal mediante el análisis del ISF-S2 en las 6 zonas seleccionadas. Luego, se generarán mapas de cambio a partir del ISF-S2 que permiten identificar visualmente las zonas afectadas o recuperadas. Por último, se analizará el efecto de la erupción volcánica con respecto a la distancia y el foco eruptivo.

4.4.1. Creación del Índice de Salud Forestal Sentinel-2

El primer paso para realizar el posterior análisis de la cubierta forestal con el ISF-S2, consiste en elegir parcelas representativas que abarquen los principales tipos de vegetación, además de las zonas de especial interés (volcán e incendio de La Palma) en las cuales podamos aplicar el ISF-S2. Para ello, de las 43 parcelas se han elegido 6 parcelas para realizar un análisis más detallado. En la Figura 36 se aprecia una vista general de cada parcela seleccionada, mientras que en las Figuras 37 a 42 se muestra con más detalle cada parcela.

- La parcela 28, ubicada en la zona del incendio forestal.
- La parcela 32, correspondiente a castaños.

- La parcela 34, correspondiente a fayal-brezal.
- La parcela 35, representativa de coníferas (pinos).
- La parcela 41, localizada en zona de laurisilva.
- La parcela 42, correspondiente a la zona afectada por la erupción volcánica.

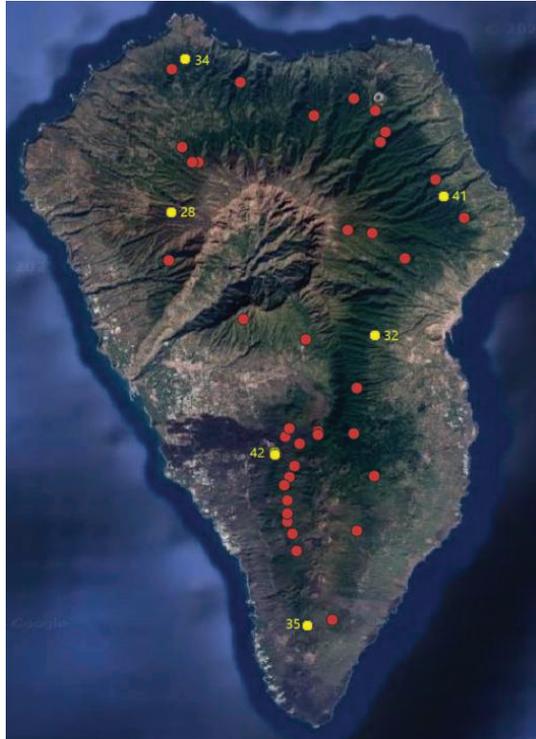


Figura 36: Parcelas seleccionadas para el análisis detallado.



Figura 37: Píxel elegido para la parcela 32.



Figura 38: Píxel elegido de la parcela 28.



Figura 39: Píxel elegido de la parcela 34.



Figura 40: Píxel elegido de la parcela 35.



Figura 41: Píxel elegido de la parcela 41.

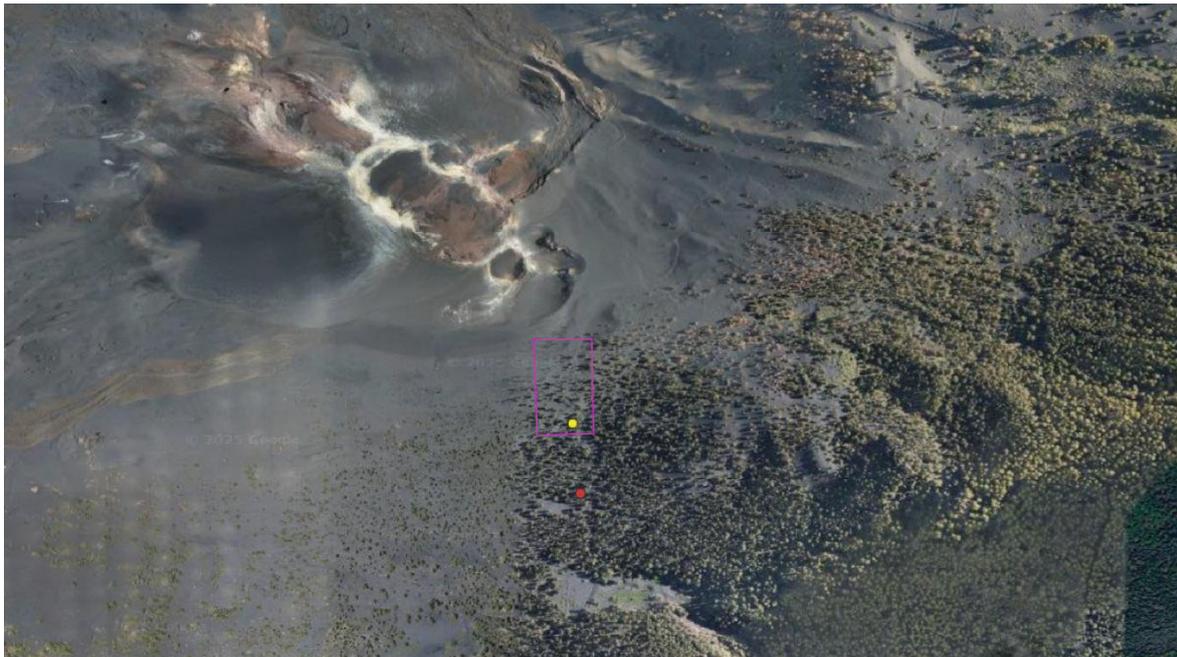


Figura 42: Píxel elegido de la parcela 42.

A partir de los píxeles seleccionados en las parcelas de interés extrae el valor del índice ISF-S2 en las imágenes Sentinel-2 de 2019 a 2024 en cada una de ellas. Las Figuras 43 a 48 presentan los valores mensuales del ISF-S2 con respecto a los índices con los que se creó para cada parcela.



Figura 43: ISF-S2 para parcela 28 (Incendio).



Figura 44: ISF-S2 para parcela 32 (Castaño).

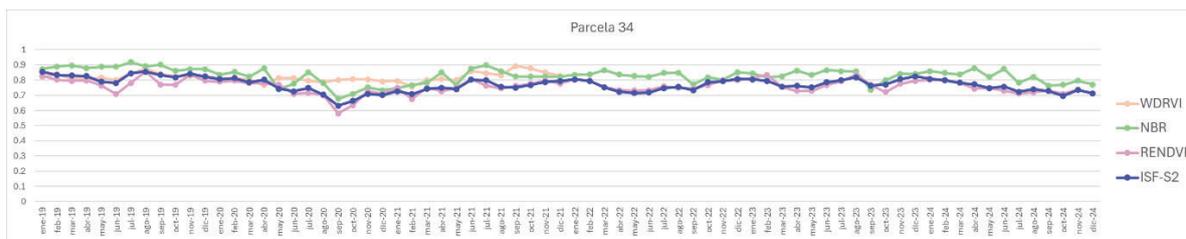


Figura 45: ISF-S2 para parcela 34 (Fayal-brezal).



Figura 46: ISF-S2 para parcela 35 (Pinares).

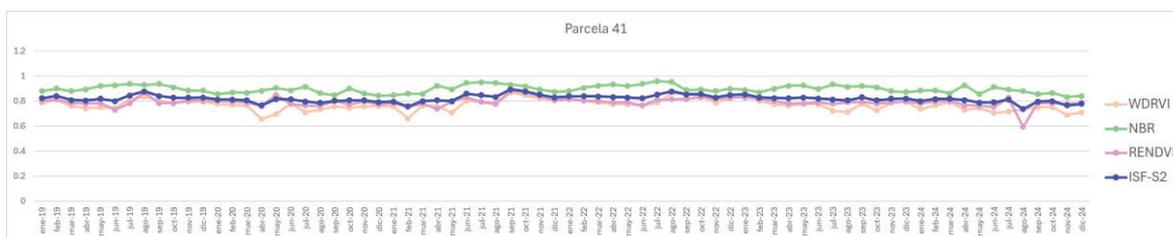


Figura 47: ISF-S2 para parcela 41 (Laurisilva).



Figura 48: ISF-S2 para parcela 42 (Volcán).

4.4.2. Evaluación de la salud forestal durante el transcurso de la serie temporal

Una vez calculado el ISF-S2 para cada parcela, se analiza su comportamiento a lo largo del tiempo. Para ello se le han añadido líneas de tendencia a las gráficas correspondientes al ISF-S2 con el fin de facilitar la interpretación de los datos. Además, se ha añadido la media móvil usando un periodo de 3 meses (línea roja). Estas gráficas muestran distintos patrones entre zonas afectadas y no afectadas por eventos extremos.



Figura 49: Evolución de la vegetación en la zona del incendio.

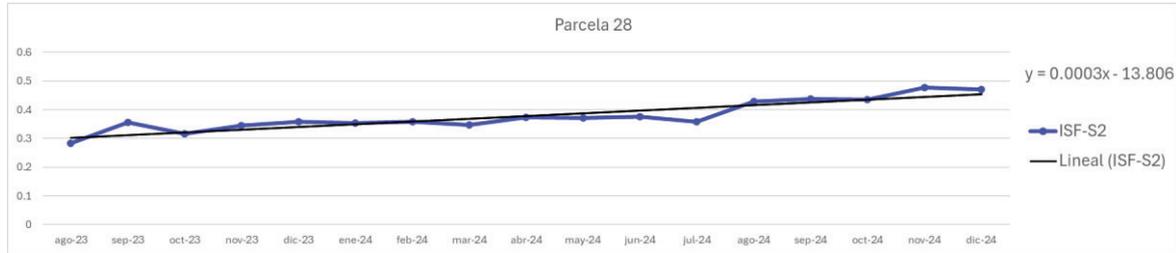


Figura 50: Evolución de la vegetación post-incendio.



Figura 51: Evolución del castaño (zona este)



Figura 52: Evolución del fayal-brezal (zona norte).



Figura 53: Evolución de los pinares (zona sur).



Figura 54: Evolución de la laurisilva (zona noreste).



Figura 55: Evolución de la vegetación en la zona de la erupción volcánica.



Figura 56: Evolución de la vegetación post-erupción.

La parcela 28 (Figura 49), ubicada en la zona del incendio, muestra una vegetación relativamente estable con ciertas fluctuaciones estacionales marcadas por la media móvil. Sin embargo, tras julio de 2023 se aprecia una caída pronunciada del ISF-S2 denotando una degradación en la salud forestal de la vegetación cercana al incendio. A pesar de ello, en la Figura 50, donde muestra la evolución post-incendio de la vegetación, se presenta una pendiente positiva en la línea de tendencia indicando un proceso de regeneración progresiva de la vegetación, aunque todavía no ha llegado a valores de salud vegetal previos al incendio.

Por otro lado, la Figura 55 muestra un repentino deterioro de la vegetación tras septiembre de 2021, reflejando así el impacto inmediato de la erupción volcánica sobre la vegetación. La línea de tendencia de la vegetación post-erupción de la Figura 56 está formada por una pendiente positiva, lo que indica un proceso de recuperación de la salud de la cubierta forestal en la zona del incendio.

Además, en la Figura 55, la media móvil evidencia una cierta variabilidad estacional con una tendencia general a la regeneración de la vegetación. Cabe destacar que en la Figura 55 se aprecia una presunta mejora de la salud de la vegetación con respecto a las condiciones iniciales. Así, en agosto de 2021 el valor del ISF-S2 es algo inferior a 0,5 mientras que en agosto de 2024 el valor se aproxima a 0,6. Se aprecia que, en esa zona, en apenas 1 año se ha regenerado la vegetación y las cenizas del volcán posiblemente han producido una fertilización del suelo. Para un análisis más exhaustivo sería necesario analizar la serie climática en esa zona para analizar la contribución de parámetros como la temperatura o precipitación.

En el caso del castaño (Figura 51), se aprecia un comportamiento estacional propio de este tipo de vegetación. Esta estacionalidad se ve reflejada especialmente en la media móvil (línea roja), donde se repiten ciclos anuales de crecimiento y desvitalización de vegetación. A pesar de ello, la línea de tendencia muestra que los castaños de esa zona han permanecido estables a lo largo del periodo analizado, reflejándose en la casi nula pendiente de la línea de tendencia.

En cambio, en las parcelas 34 (fayal-brezal), 35 (pinares) y 41 (laurisilva), todas localizadas fuera de las áreas de influencia de la erupción y del incendio, se aprecia un comportamiento estable a lo largo del tiempo. Estas parcelas corresponden a las Figuras 52, 53 y 54 respectivamente. Esto se ve respaldado por las pendientes casi nulas de sus líneas de tendencia además de por sus medias móviles, las cuales reflejan leves variaciones estacionales. Esto afirma que la salud de la vegetación en dichas zonas no sufre alteraciones relevantes.

Finalmente, para la parcela 35 el volcán puede haber fertilizado la vegetación pues desde diciembre de 2021 el ISF-S2 ha tenido valores superiores que años precedentes, salvo una rápida desvitalización a partir de julio de 2024 como se analizará en el próximo apartado.

4.4.3. Mapas de cambio

Con el objetivo de analizar los cambios sufridos en la cubierta forestal de La Palma debido a la erupción volcánica de 2021 y al incendio forestal en 2023, también se generaron mapas de cambio a partir del Índice de Salud Forestal Sentinel-2 (ISF-S2).

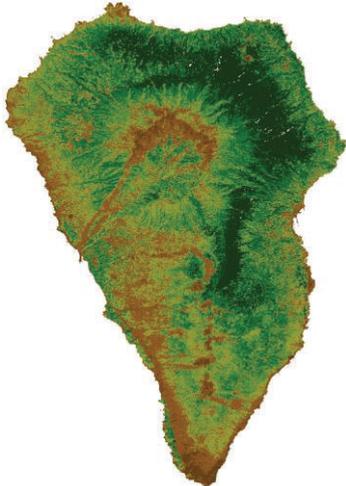
En primer lugar, se deben escoger los meses con menos presencia de nubes para evitar interpretaciones erróneas de los resultados obtenidos. Tras un análisis de los Anexos 1 y 2, se determina que los meses seleccionados son febrero, junio y diciembre. En la Figura 58 se presentan las imágenes obtenidas una vez aplicado el ISF-S2. Se ha seleccionado una paleta de que colores va del marrón al verde, donde marrón significa ausencia o degradación de la vegetación y verde significa vegetación sana. Esta paleta se representa en la Figura 57.

Color	Slice Min	Slice Max
	0.000000	0.400000
	0.400000	0.500000
	0.500000	0.600000
	0.500000	0.650000
	0.600000	0.700000
	0.700000	0.800000
	0.800000	0.959125

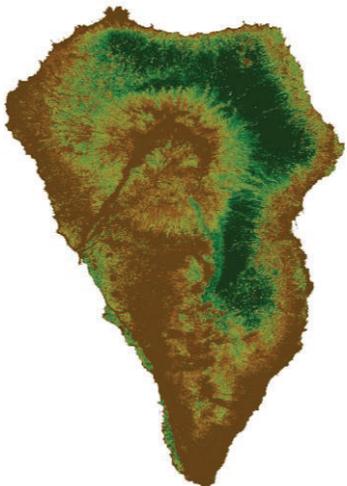
Figura 57: Paleta de colores ISF-S2.

Si se analizan las imágenes de la Figura 58 del mismo año (misma fila), se aprecia claramente que en junio por regla general la vegetación herbácea está seca, lo que aumenta la superficie de color marrón.

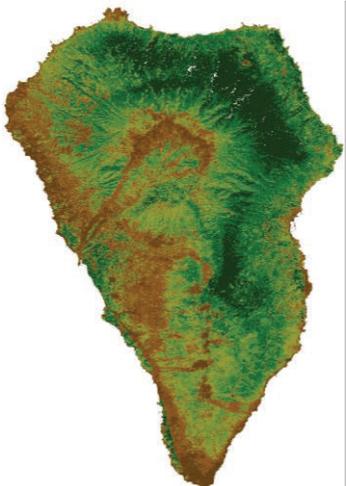
De otra parte, en las imágenes se muestra claramente el efecto de la erupción y del incendio en la cubierta forestal. Concretamente, si se analiza en detalle los meses de diciembre, se puede ver cómo a partir de diciembre de 2021 se aprecia en el suroeste de la isla la zona devastada por la erupción volcánica, ya que esta se inició en septiembre de 2021. Además, de diciembre de 2023 en adelante, se muestra cómo el incendio forestal ha afectado la zona noroeste de la isla.



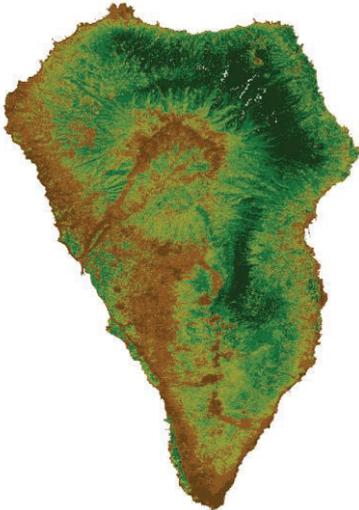
Febrero 2019.



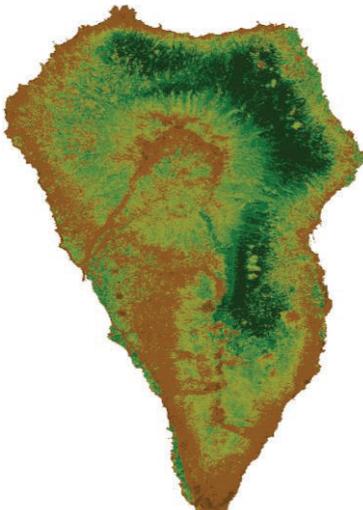
Junio 2019.



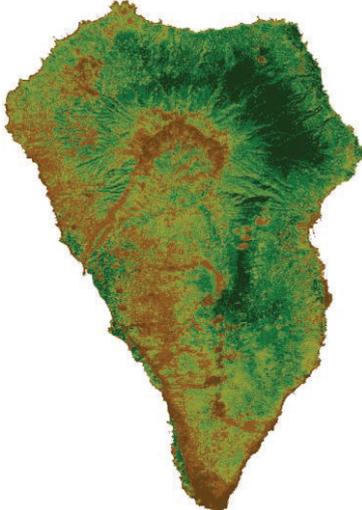
Diciembre 2019.



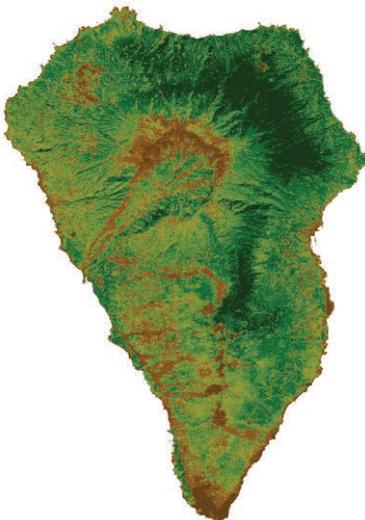
Febrero 2020.



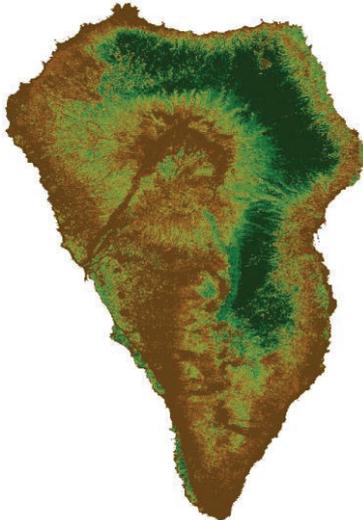
Junio 2020.



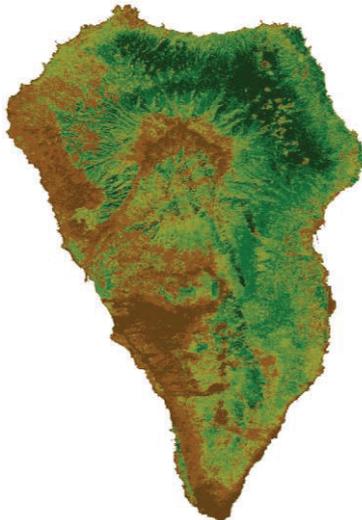
Diciembre 2020.



Febrero 2021.



Junio 2021.



Diciembre 2021.

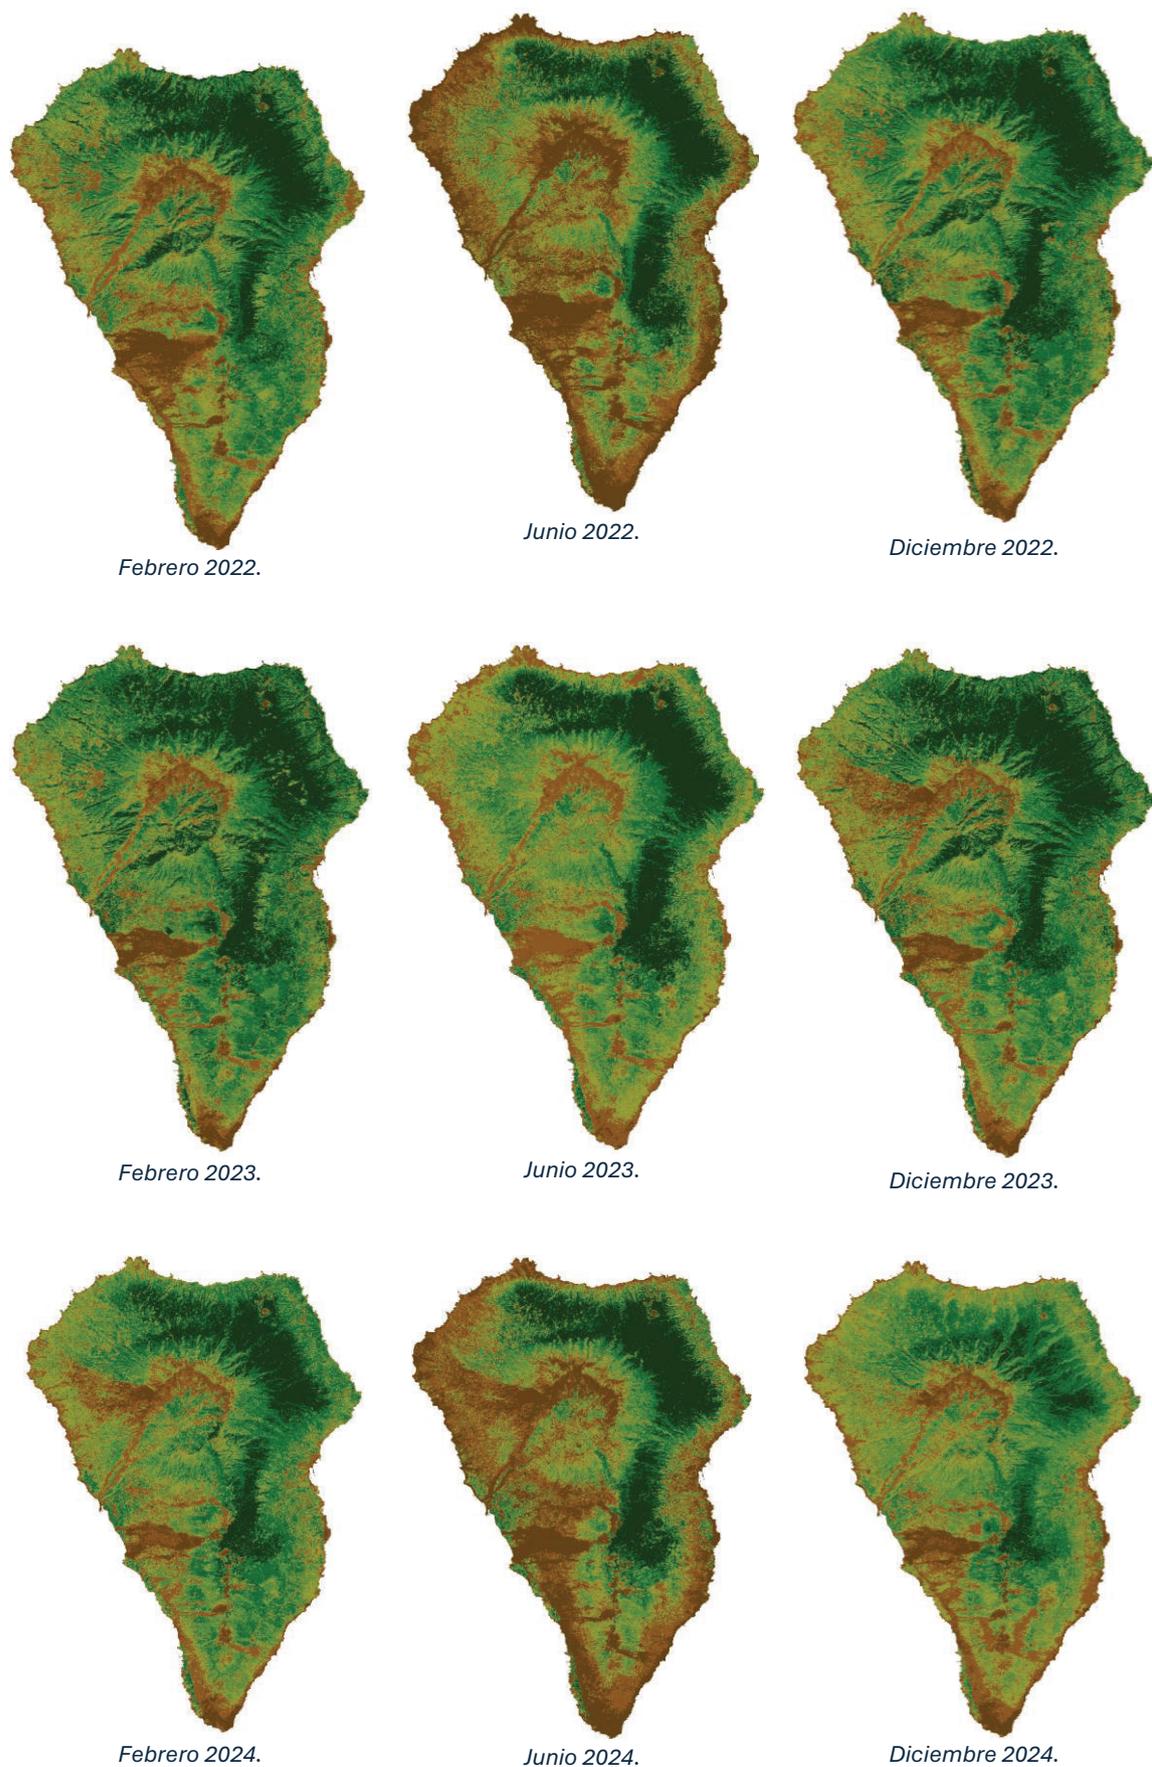
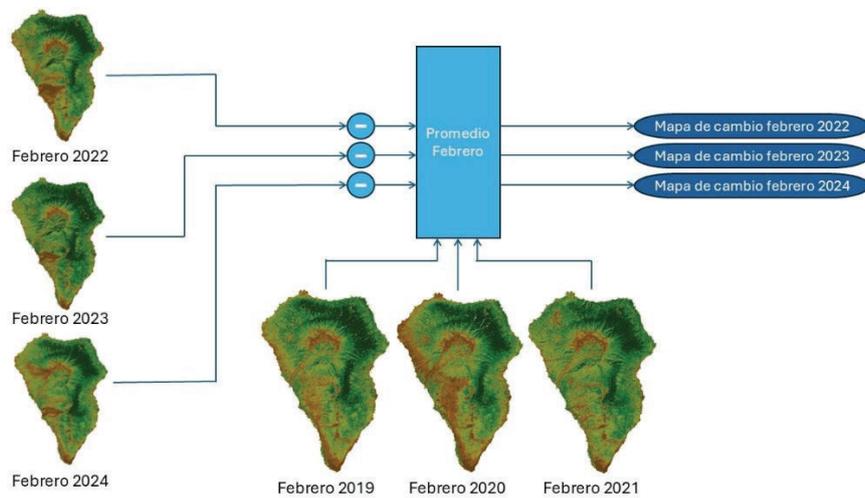
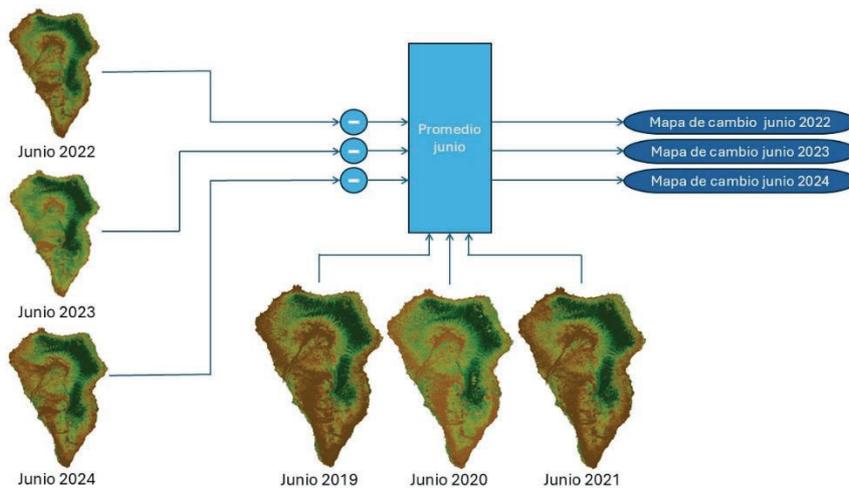


Figura 58: ISF-S2 para los meses seleccionados.

Para hacer un análisis aún más detallado, se han generado los mapas de cambio. Dado que el primer evento ocurrió en septiembre de 2021, se calculó el promedio del valor de cada píxel entre 2019, 2020 y 2021 para cada mes seleccionado. Luego, se ha calculado la diferencia entre cada imagen posterior al evento (2022, 2023 y 2024) y su respectivo promedio teniendo así nueve mapas de cambio en total. La Figura 59 muestra gráficamente este proceso. Cabe destacar que en el mes de diciembre se ha descartado el año 2021 en el promedio para evitar resultados erróneos, tal y como aparece en la Figura 59(c), ya que la erupción tuvo lugar meses antes de esa fecha. Estos mapas de cambio están representados junto a su promedio correspondiente desde la Figura 60 hasta la Figura 62 en una escala de grises, donde el color negro quiere decir que ha empeorado la salud de la vegetación y el color blanco que ha mejorado con respecto a las condiciones anteriores a la erupción e incendio.



(a)



(b)

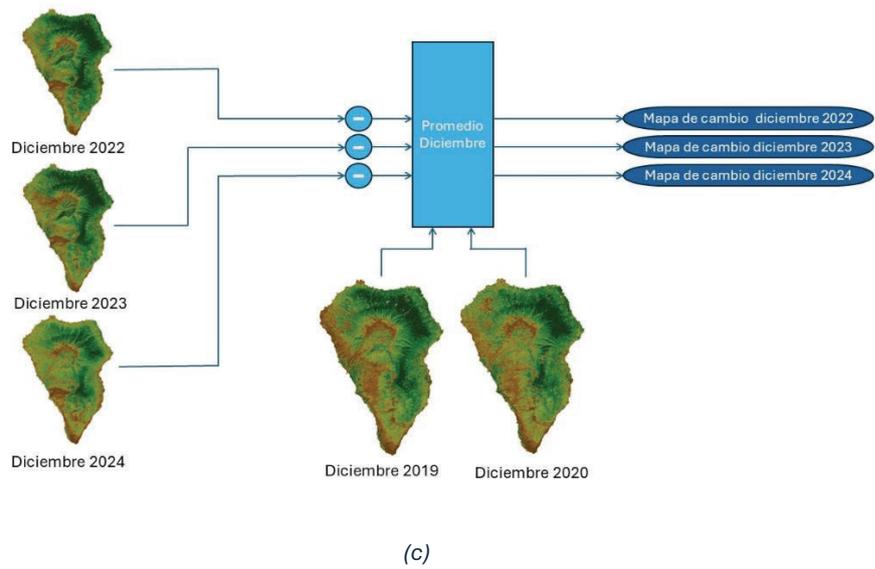


Figura 59: Procedimiento para generar mapas de cambio: (a) Febrero, (b) Junio y (c) Diciembre

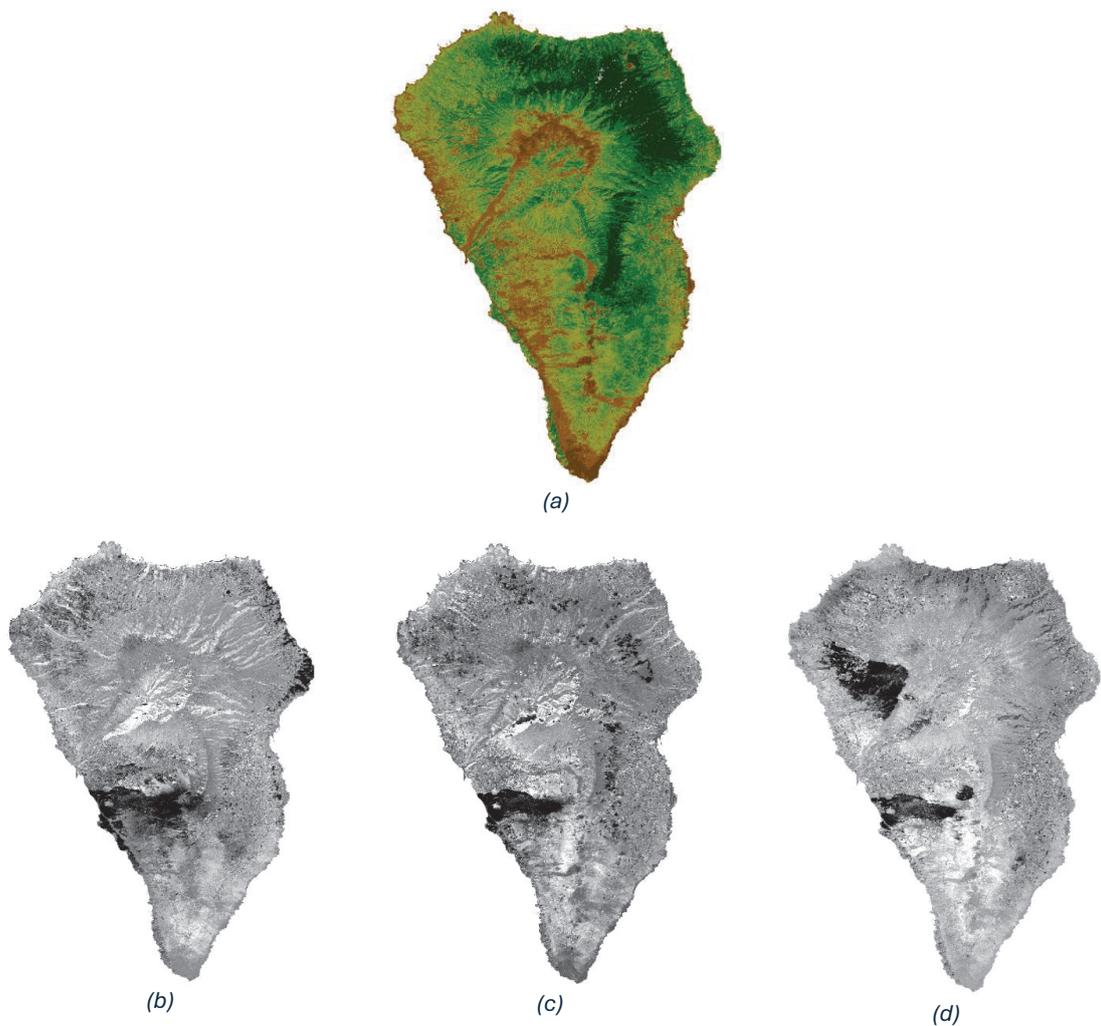


Figura 60: Mapas de cambio del mes de febrero: (a) Promedio febrero 2019, 2020 y 2021, (b) Cambio en febrero 2022, (c) Cambio en febrero 2023 y (d) Cambio en febrero 2024.

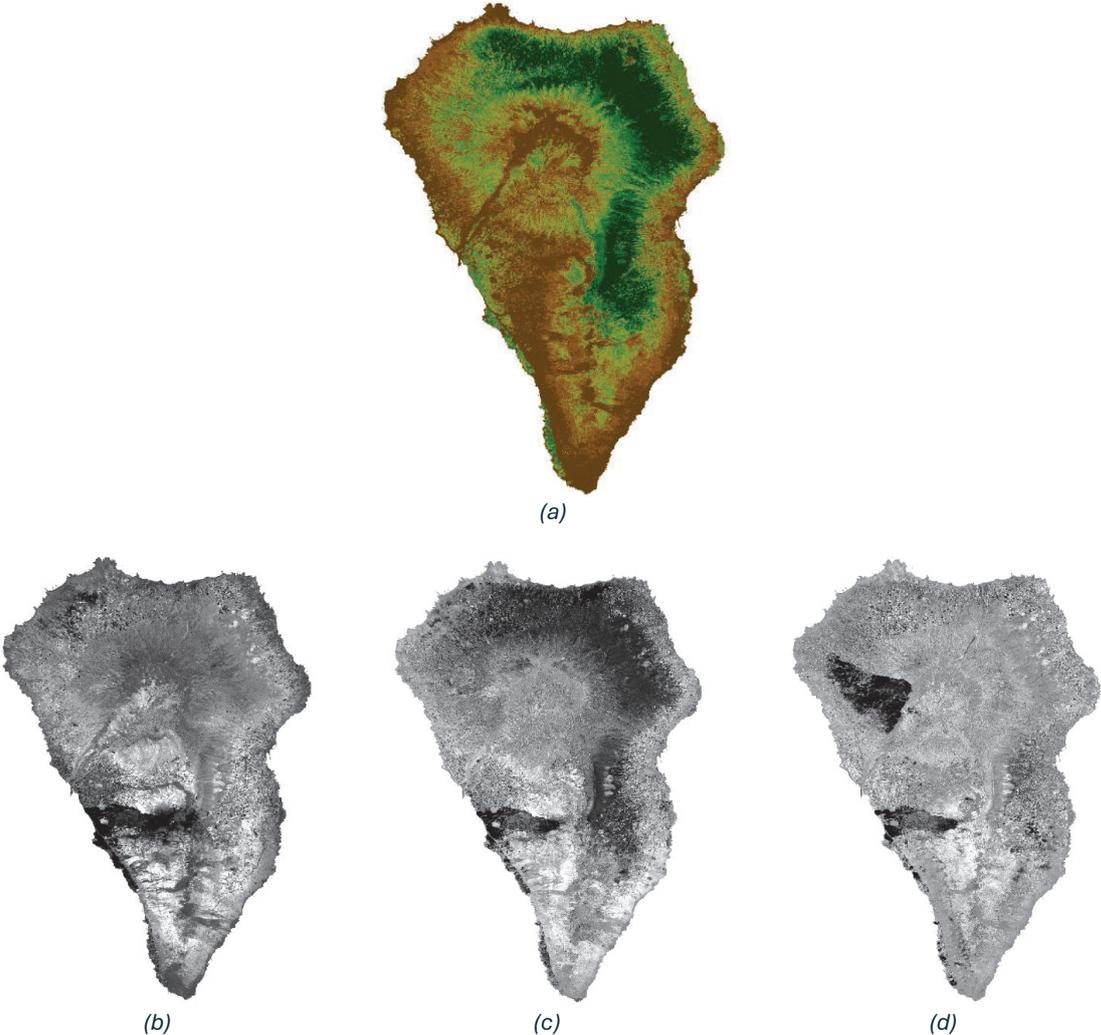


Figura 61: Mapas de cambio del mes de junio: (a) Promedio junio 2019, 2020 y 2021, (b) Cambio en junio 2022, (c) Cambio en junio 2023 y (d) Cambio en junio 2024.

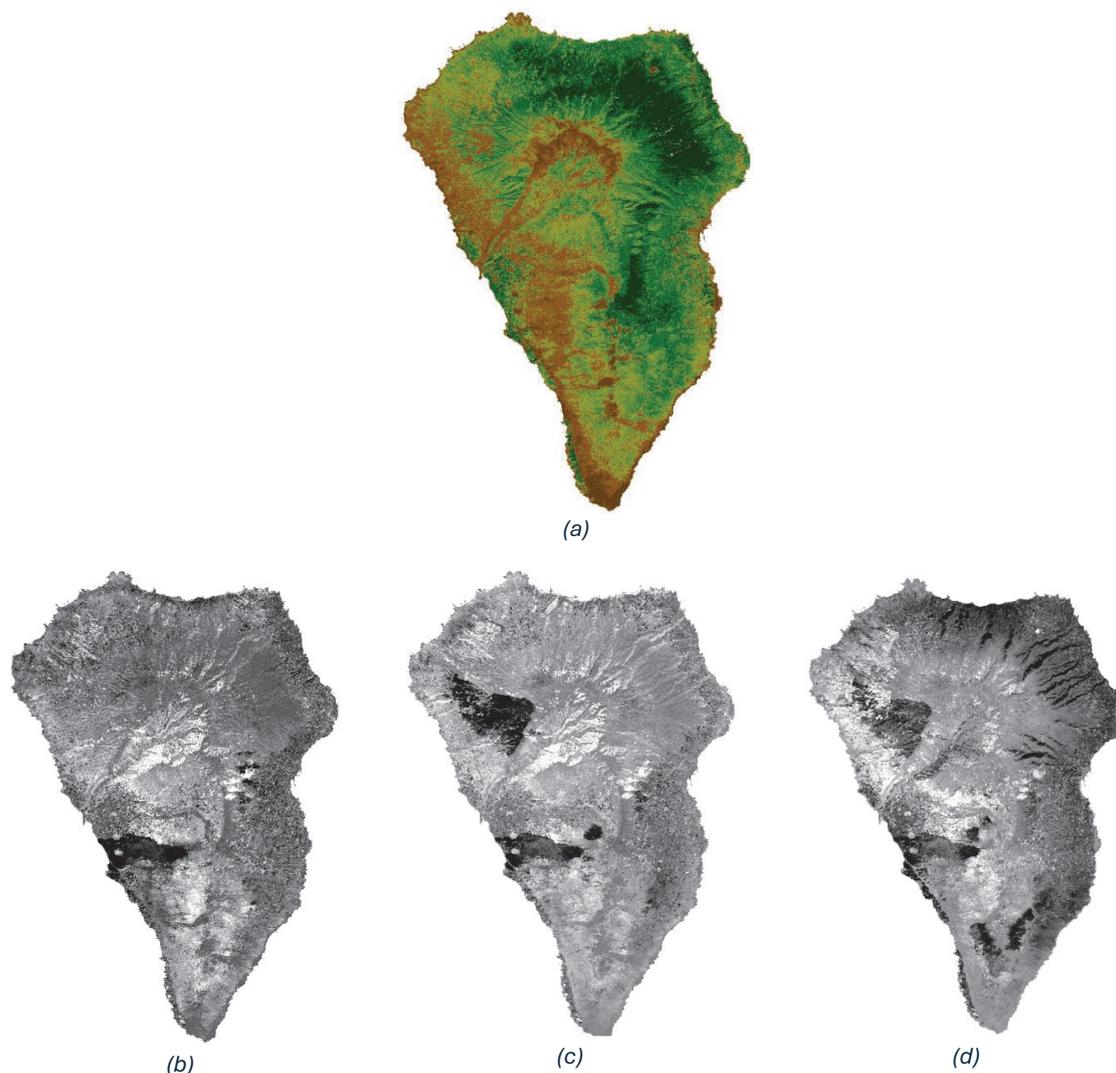


Figura 62: Mapas de cambio del mes de diciembre: (a) Promedio diciembre 2019 y 2020, (b) Cambio en diciembre 2022, (c) Cambio en diciembre 2023 y (d) Cambio en diciembre 2024.

Estos mapas de cambio reflejan la degradación o incluso la pérdida de vegetación provocada por la erupción volcánica. En cuanto a la zona de la erupción volcánica, su área de degradación de la salud forestal presenta una morfología irregular y con formas líneas o lenguas, coherente con los flujos de lava. Es importante recalcar que no toda la zona negra corresponde a vegetación desvitalizada ya que en el terreno afectado había superficies de suelo desnudo antes de que sucediera la erupción.

A pesar de que la imagen muestre una posible sobreestimación de vegetación degradada en la zona de la erupción, la representación sigue siendo relativamente fiel al cambio de la cobertura ya que refleja la transformación real a causa de la cobertura de lava. Por otro lado, la zona del incendio posee un patrón más homogéneo y extenso, reflejando un deterioro rápido e intenso del estado de la cubierta forestal, común en los eventos de fuego.

También hay zonas de grises que representan cambios leves o estabilidad de la salud de la vegetación a lo largo del tiempo, pudiendo interpretarse como zonas no afectadas. Los blancos y grises medios cercanos a las áreas afectadas pueden indicar un rebrote inicial o también puede indicar un impacto leve sobre la vegetación o una cobertura por ceniza. Cabe destacar que la zona central de pinares al sur de la erupción se aprecia una clara mejora en el verdor vegetal.

Analizando en detalle los mapas, se deben resaltar varios acontecimientos significativos mostrados en estos mapas de cambio. En primer lugar, se aprecia una zona circular situada encima de la erupción volcánica (Figura 63(a)) que demuestra que aparentemente la erupción ha provocado una alteración negativa en la salud de los pinares de la zona. Esto se ve respaldado por la Figura 63(b) y (c), donde se aprecia dicha pérdida de vegetación). Además, en diciembre de 2024 (Figura 64(a)) se aprecian dos focos de degradación forestal importantes en el sur de la isla, lo cual resulta especialmente llamativo. Este hecho queda evidenciado en la Figura 64(b) y (c), que muestra una disminución del vigor forestal en la misma zona de interés.

Por otro lado, en la zona sureste del mapa de cambios de junio de 2023 (Figura 61) se aprecia como se ha deteriorado la vegetación. Esto se debe a que la imagen empleada para la diferencia con el promedio es del 27 de junio de 2023, mientras que las imágenes del promedio pertenecen principalmente a principio de junio. Estas semanas de diferencia proporcionaron el tiempo necesario para que la imagen del 27 de junio se haya desvitalizado lo suficiente como para que el mapa de cambios indique que ha habido un deterioro de la vegetación.

Por otra parte, el mapa de cambios también muestra un comportamiento extraño en la zona noreste. Tal y como vemos en la Figura 65, los barrancos de la zona en diciembre de 2024 están completamente en sombra debido a la baja elevación solar. Al parecer, mediante un producto anómalo, las sombras han sido sustituidas valores atípicos.

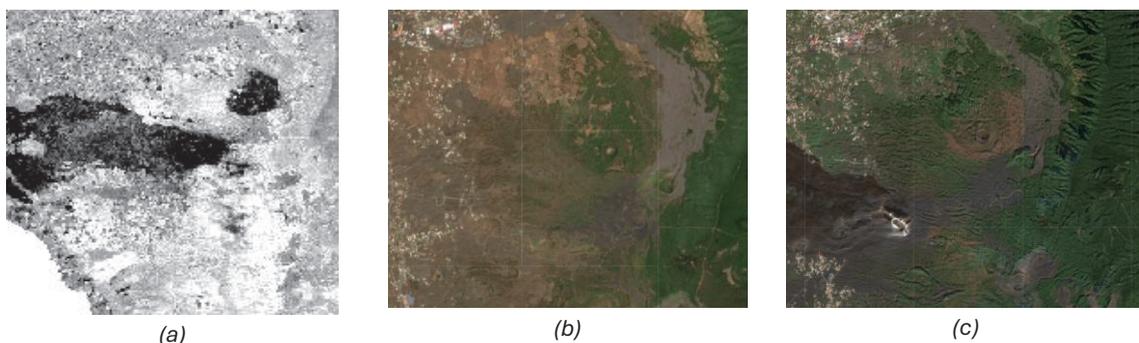


Figura 63: Zona central degradación de salud forestal: (a) Mapa de cambios 02/2024, (b) Imagen satelital pre-erupción Sentinel-2 en RGB y (c) Imagen satelital post-erupción Sentinel-2 en RGB.

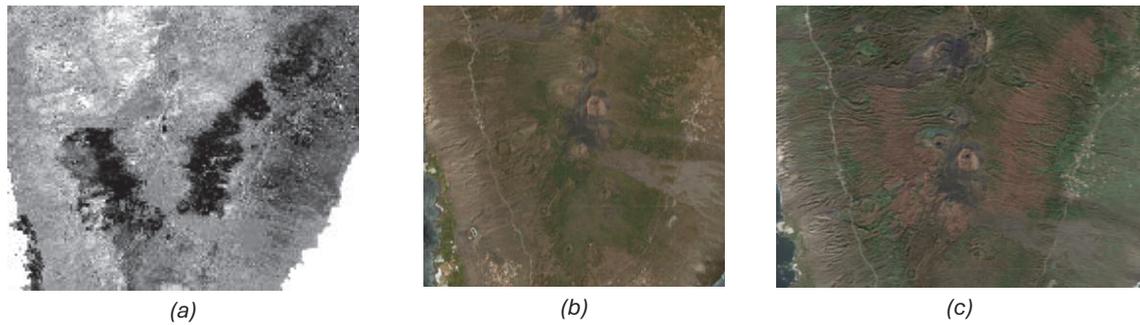


Figura 64: Zona sur degradación de salud forestal: (a) Mapa de cambios 12/2024, (b) Imagen satelital pre-erupción Sentinel-2 en RGB y (c) Imagen satelital post-erupción Sentinel-2 en RGB.

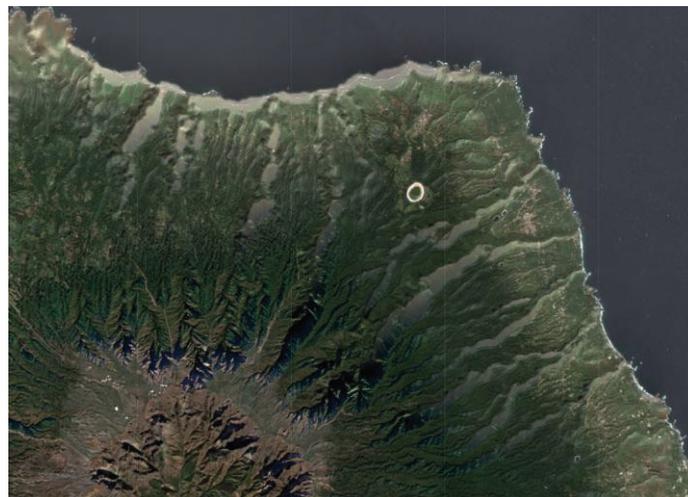


Figura 65: Imagen satelital Snetinel-2 de diciembre de 2024.

Por último, la Figura 67 muestra el mapa de cambios de junio de 2024 debido a que es el más representativo de los hechos sucedidos en la cubierta forestal de la isla sin la interferencia de la vegetación herbácea. La paleta de colores mostrada en la Figura 66 (a) de este mapa consta de rojo, blanco y verde. El rojo resalta el deterioro de la salud forestal con respecto a la vegetación anterior a la erupción volcánica y al incendio, el blanco representa el área que no ha sufrido cambios significativos y el verde indica una mejora de la vigorosidad de la vegetación, que se hace patente alrededor de la zona del volcán. Además, en la Figura 66(b), se muestra el histograma del mapa de cambios, el cual refleja una distribución equilibrada tanto en la cantidad de píxeles como en el área bajo la curva entre las zonas de deterioro y mejora de vigorosidad.

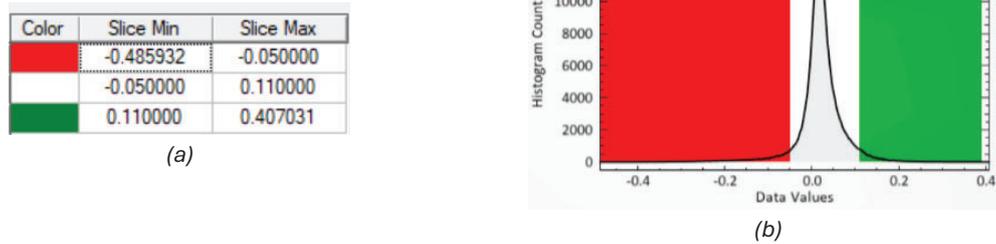


Figura 66: Paleta de colores para mapa de cambios de junio de 2024: (a) Paleta de colores y (b) Histograma.

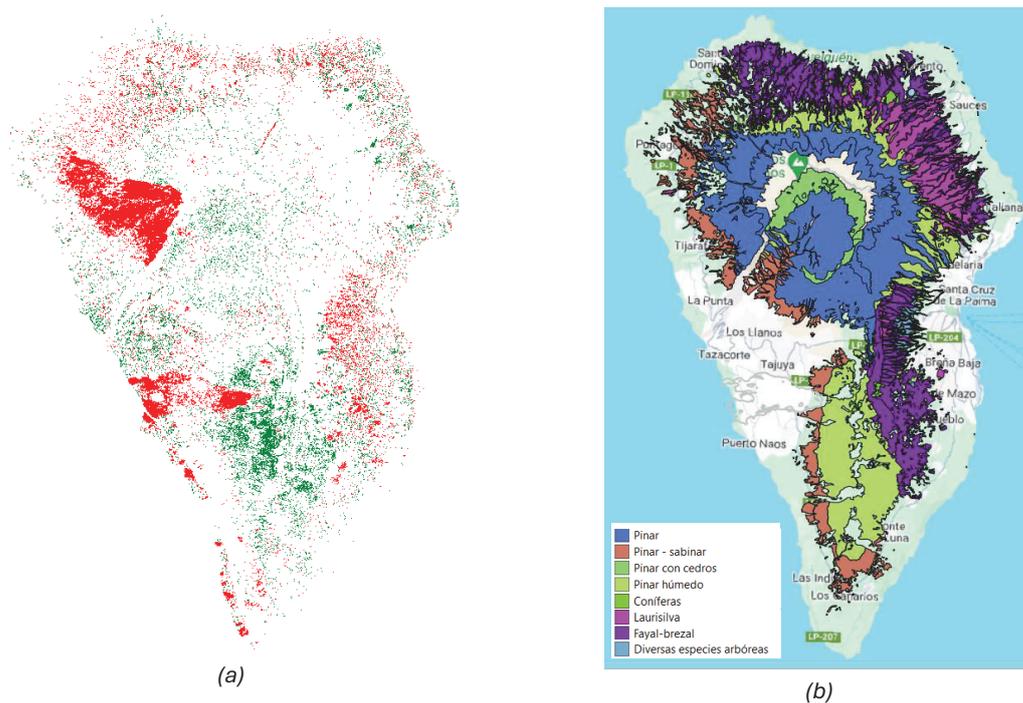


Figura 67: Mapa de cambios: (a) Cambio en junio 2024 con paleta de colores y (b) Mapa de vegetación del Gobierno de Canarias 2021.

Este mapa confirma que la zona del incendio de 2023 ha sufrido una importante reducción de la salud forestal con respecto al estado de la vegetación anterior al incendio. Sin embargo, el aspecto más relevante a destacar es que el proceso de recuperación de las zonas afectadas por la erupción volcánica no solo ha permitido volver a las condiciones iniciales, sino que ha causado una fertilización provocando una mejora notoria en el verdor de la vegetación de la zona.

Estos resultados demuestran la consistencia de este Trabajo de Fin de Grado, ya que coincide con lo mencionado con anterioridad al analizar la serie temporal (Figura 55), en la que se mostraba una mejora de la salud de la vegetación por encima de las condiciones iniciales.

4.4.4. Análisis con respecto a la distancia y orientación al foco eruptivo

Para realizar un análisis más riguroso de los efectos de la erupción volcánica, se evaluó los cambios producidos en la cobertura forestal a distintas distancias y orientaciones con respecto al foco eruptivo. Tal y como se mostró en el mapa de cambios, las zonas afectadas por el volcán fueron la zona sur y los alrededores al volcán. Debido a esto, se analizarán las parcelas mostradas en la Figura 68.

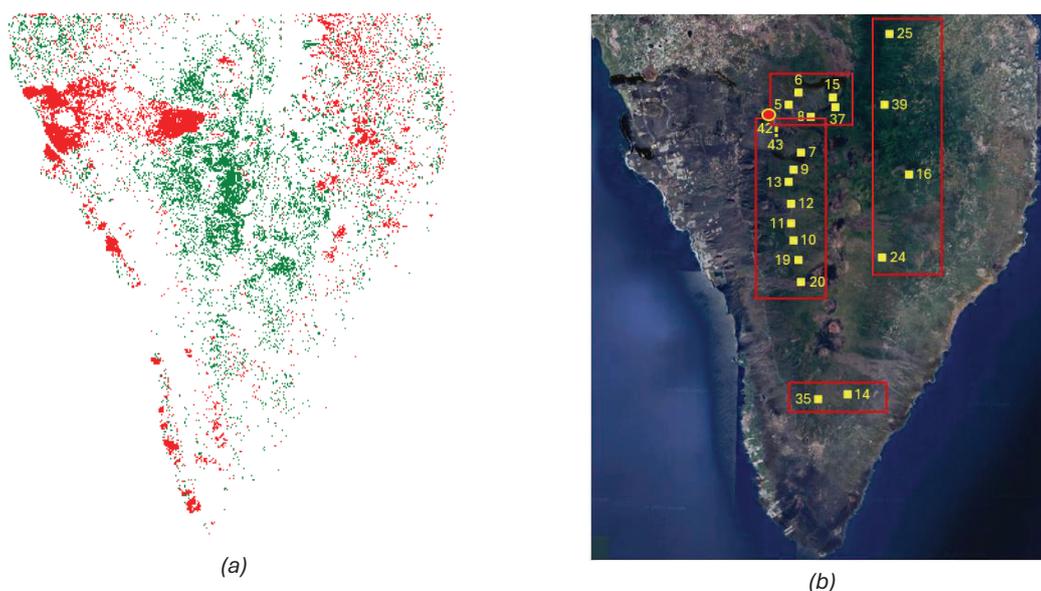


Figura 68: Análisis de los efectos de la erupción volcánica: (a) Mapa de cambios de junio de 2024 y (b) Parcelas elegidas a diferentes distancias y orientaciones.

A continuación, en las Figuras 69 a 72 se muestran los efectos de la erupción volcánica para cada parcela seleccionada. Estas parcelas están agrupadas según patrones de comportamiento similares en 4 zonas.

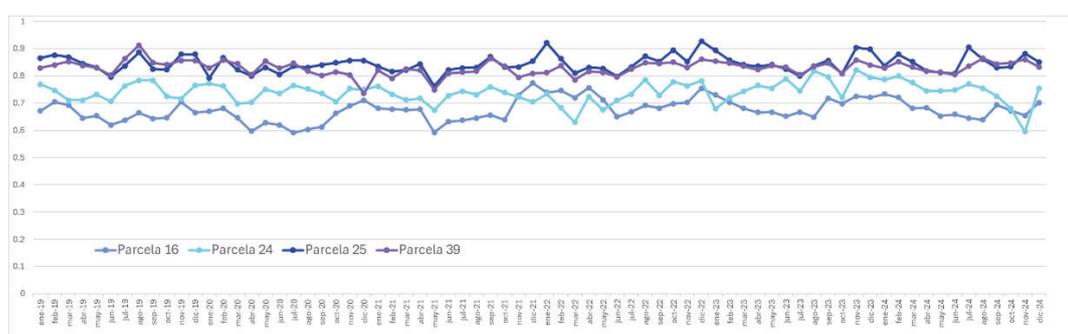


Figura 69: Análisis de los efectos de la erupción en la zona Este alejada del volcán.

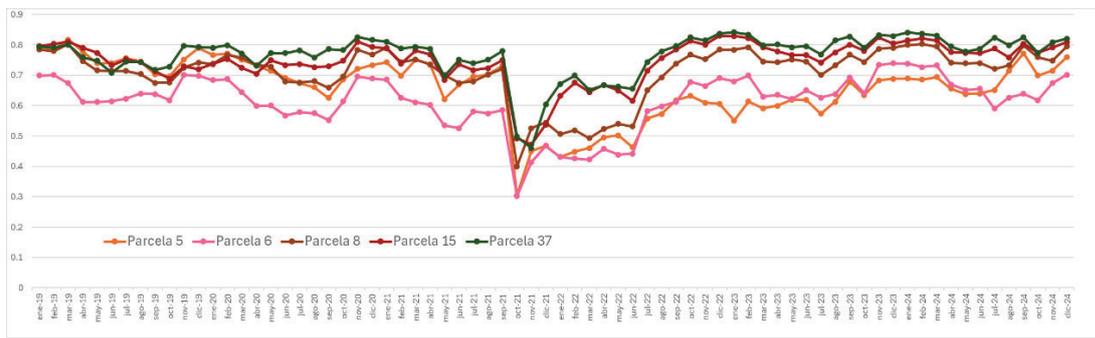


Figura 70: Análisis de los efectos de la erupción en la zona Norte cercana del volcán.



Figura 71: Análisis de los efectos de la erupción en la zona Sur cercana del volcán.

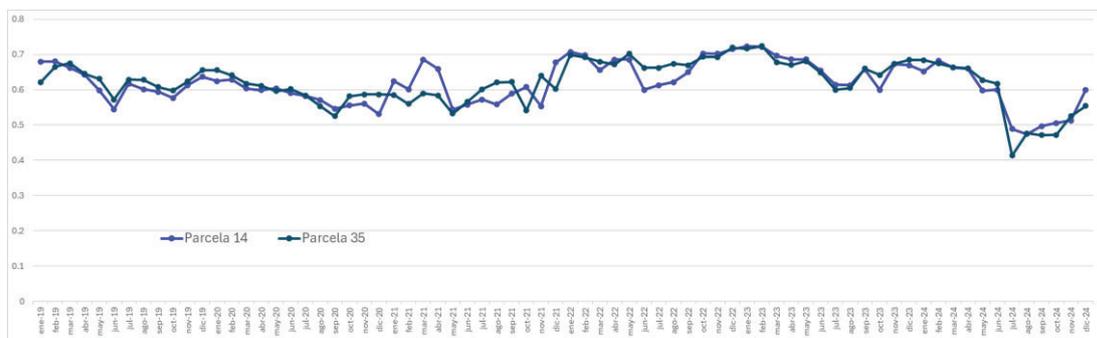


Figura 72: Análisis de los efectos de la erupción en la zona Sur alejada del volcán.

Estas cuatro zonas muestran comportamientos diferenciados:

- Zona Este alejada (Figura 69), no muestra ningún efecto producido por el volcán.
- Zona al Norte cercana (Figura 70), presenta signos de pérdida de vigor en la vegetación a partir de septiembre de 2021. También refleja una recuperación progresiva y una leve mejora de la vigorosidad.

- Zona al Sur cercana (Figura 71), muestra un comportamiento similar a la zona Norte cercana. Sin embargo, esta zona refleja una mayor recuperación de la vigorosidad (se ha excluido la parcela 9 debido a que posee un comportamiento atípico).
- Zona al Sur alejada (Figura 72), en la que se aprecia una leve afección tras la erupción, seguida por una recuperación considerable. Esta parcela destaca por un fenómeno de desvitalización en julio de 2024 con rápida recuperación.

Los datos muestran una coherencia clara con los resultados obtenidos en el análisis multitemporal y con los mapas de cambio elaborados, reflejando las mejoras de vigorosidad de la vegetación cercana a la erupción. Tal y como se aprecia en las Figuras 71 y 72, la zona sur al volcán ha experimentado una mayor mejora de vigorosidad, lo cual concuerda con la dirección de los vientos alisios hacia el sur, responsables de una mayor deposición de cenizas en esa área.

5. Conclusiones

En este capítulo se revisan los objetivos iniciales del TFG, así como los resultados obtenidos. Además, se proponen algunas líneas de mejora que permitirían ampliar y desarrollar el trabajo realizado y reflejado en este documento.

5.1. Revisión de los objetivos

Este Trabajo de Fin de Grado se ha centrado en el análisis multitemporal de la cubierta forestal de la isla de La Palma, con el fin de estudiar los efectos causados por la erupción volcánica del año 2021 y el incendio forestal del 2023. Para este fin, se han empleado imágenes multispectrales de teledetección capturadas por los sensores del satélite Sentinel-2 además de varias cartografías forestales. Esto ha permitido caracterizar y evaluar el estado de la cubierta forestal a lo largo del tiempo.

A continuación se describe la secuencia de objetivos y tareas realizados para este desempeño:

- Se han estudiado los sistemas de teledetección y se ha seleccionado la técnica de teledetección espacial con sensores pasivos como la adecuada al enfoque de este TFG.
- Se ha realizado una inspección minuciosa en la base de datos de imágenes del Sentinel-2, gratuitas en el ámbito de programa Copernicus, para seleccionar las más adecuadas en términos de cobertura de nubes y calidad radiométrica y, así, generar una serie temporal de imágenes que abarque el periodo entre los años 2019-2024.
- Posteriormente, se ha procedido al análisis y procesado de la serie temporal para sintetizar 72 imágenes (una por mes), empleando técnicas de fusión al objeto de completar una serie limpia de nubes.
- Se han analizado los principales índices de vegetación existentes (27 índices) y se ha estudiado el funcionamiento de cada uno de ellos en distintas coberturas de suelo, con el fin de seleccionar aquellos que mejor discriminen la vegetación sana de la desvitalizada en el entorno geográfico objeto de estudio.
- Se ha propuesto un nuevo Índice de Salud Forestal (ISF-S2) más robusto como combinación de los índices seleccionados. Se ha aplicado al análisis de la vegetación

a lo largo de la serie temporal, así como para la generación de mapas de cambio para identificar las zonas afectadas por los eventos extremos.

- Se han empleado distintas cartografías como apoyo para delimitar las zonas de estudio y clasificar los distintos tipos de vegetación existentes en la isla de La Palma.
- Las cartografías han permitido contextualizar espacialmente los cambios detectados por los índices de vegetación. Además, han hecho posible hacer un análisis de los efectos del volcán con respecto a la distancia y orientación al foco eruptivo.
- A partir del análisis conjunto proporcionado por el ISF-S2 combinado con las cartografías forestales, se han identificado los efectos causados por la erupción volcánica y el incendio forestal ya señalados.
- Se ha llevado a cabo una evaluación específica de los cambios sufridos por distintas especies forestales. Esto ha dado lugar a la identificación de patrones de desvitalización y recuperación según su ubicación geográfica.

En conjunto, todos los objetivos planteados han sido llevados a cabo con éxito. Esto ha propiciado una caracterización detallada del impacto de los eventos extremos mencionados sobre el ecosistema forestal de La Palma.

5.2. Conclusiones del análisis de los resultados

Los resultados del presente Trabajo de Fin de Grado concluyen que las técnicas de teledetección multiespectral con Sentinel-2 resultan eficaces para evaluar los efectos drásticos causados por desastres naturales sobre la vegetación.

Gracias al diseño del índice sintético ISF-S2, que combina tres índices espectrales normalizados, ha sido posible obtener un indicador unificado y robusto permitiendo obtener resultados coherentes con la realidad observada en el terreno.

Los resultados obtenidos destacan el potencial de esta metodología para la monitorización multitemporal de la cubierta forestal, permitiendo no solo detectar desvitalizaciones de la vegetación, sino también de analizar distintas clases de cobertura (vegetación sana, desvitalizada, suelo desnudo y construido) e identificar la recuperación ecológica en diferentes tipos de vegetaciones.

Por lo tanto, a través de los resultados obtenidos, se pueden obtener las siguientes conclusiones:

- La metodología basada en imágenes Sentinel-2 permite realizar un seguimiento continuo con una resolución espacial y temporal adecuadas para este tipo de estudios.
- El índice ISF-S2 ha demostrado una alta sensibilidad para la detección de cambios en la vegetación provocados por los eventos extremos mencionados.
- En las zonas quemadas, tanto de la erupción como del incendio, se observa una caída brusca de la vigorosidad de la vegetación. Esto viene seguido por una recuperación parcial en los meses posteriores.
- Las zonas afectadas por el incendio, a pesar de que se aprecia una recuperación progresiva de la salud forestal, aún no han conseguido alcanzar el nivel de vigorosidad presente antes del incendio.
- En los ecosistemas de las zonas no afectadas (pinares, fayal-brezal, laurisilva y castaños) la vegetación se mantiene estable. Esto confirma su buena conservación a lo largo de la serie temporal y también la validez del índice para discriminar entre zonas afectadas y no afectadas.
- Especialmente en las zonas de castaños, se confirma la influencia de la estacionalidad de la vegetación, ya que el ISF-S2 tiende a disminuir durante los meses más secos.
- En las zonas afectadas por el volcán, ocurre una abrupta desvitalización a partir de septiembre de 2021. Sin embargo, hay que destacar una considerable mejora posterior de la salud de la vegetación llegando incluso a conseguir un mejor estado de vigorosidad con respecto a la vegetación pre-erupción. Esto está posiblemente asociado a la fertilización de la zona a causa de las cenizas volcánicas.
- Los mapas de cambio generados con ISF-S2 permiten identificar visualmente las zonas críticas con pérdida o ganancia de salud vegetal con respecto a la vegetación anterior a los eventos mencionados. Además, permiten corroborar la pérdida de salud vegetal en la zona del incendio y la fertilización de la vegetación en las zonas cercanas a la erupción.

El análisis espacial según la distancia y orientación al foco eruptivo proporciona varias conclusiones:

- La zona este alejada al volcán no presenta cambios debidos a la erupción.

- Las zonas Norte y Sur cercanas muestran una pérdida de vigorosidad a partir de septiembre de 2021, seguidos de una recuperación progresiva. Destaca la zona sur por su mayor recuperación.
- La zona Sur alejada refleja una leve degradación del verdor vegetal con una recuperación considerable. Destaca un fenómeno puntual de desvitalización en julio de 2024, con una tempranera recuperación.

Los resultados obtenidos con la evaluación de la serie temporal y los mapas de cambio validan la capacidad del ISF-S2 para detectar cambios en la cobertura forestal, al reflejar de manera diferenciada el área afectada por el incendio, los signos de recuperación en la zona volcánica y la estabilidad de la vegetación no afectada por la erupción ni el incendio.

5.3. Líneas futuras

Los resultados obtenidos en este Trabajo de Fin de Grado establecen posibles líneas futuras de investigación complementarias, que permitirían mejorar el alcance del análisis y la precisión del mismo.

Entre las posibles ampliaciones del estudio, se plantean las siguientes propuestas:

- Integrar otras fuentes de datos satelitales con mayor resolución para mejorar la detección de cambios en zonas con nubosidad persistente o cobertura mixta.
- Desarrollar una metodología más avanzada o automatizada que realice el seguimiento continuo y preciso de la cubierta a lo largo de varios años.
- Realizar un análisis climático de la serie temporal, con el fin de analizar la contribución de parámetros como la temperatura o la precipitación. Con esto será posible estudiar su posible influencia sobre los patrones de degradación o recuperación.

Bibliografía

- [1] E. Chuvieco, *Principios de Teledetección Espacial*. Madrid: RIALP, 1996.
- [2] H.G. Jones y R.a. Vaughan, *Remote Sensing of Vegetation. Principles, Techniques and Applications*. Oxford: Oxford University Press, 2010.
- [3] F. Akcesme, M. Can, O. Gürsoy y B. Akcesme, Leaf Area Assessment By Image Analysis, *Southeast Europe Journal of Soft Computing*, vol. 1, pp. 215-233, 2012.
- [4] G. Ozdemir y E. Sumer, A comparison tool for different vegetation indices from spaceborne imagery, en *2013 6th International Conference on Recent Advances in Space Technologies (RAST)*, 2013, pp. 133-137.
- [5] Copernicus, “Programa Copernicus”, Accedido: 28 de diciembre de 2024. [En línea]. Disponible en: <https://www.copernicus.eu/es>.
- [6] Copernicus, “Información de los servicios de Copernicus y productos Sentinel relacionados con la región ártica,” Accedido: 28 de diciembre de 2025. [En línea]. Disponible en: <https://www.copernicus.eu/es/informacion-de-los-servicios-de-copernicus-y-productos-sentinel-relacionados-con-la-region-artica>.
- [7] E. Chuvieco, *Teledetección Ambiental. La observación de la Tierra desde el Espacio*. Barcelona: Ariel Ciencia, 2002.
- [8] Y. Sun, H. Ren, T. Zhang, C. Zhang y Q. Qin, Crop Leaf Area Index Retrieval Based on Inverted Difference Vegetation Index and NDVI, *IEEE Geoscience and Remote Sensing Letters*, vol. 15, n.º 11, pp. 1662-1666, 2018.
- [9] X. Jin, Z. Li, H. Feng, Z. Ren y S. Li, Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index, *Crop Journal*, vol. 8, n.º 1, pp. 87-97, 2020.
- [10] Campbell, J. B.; Wynne, R. H, *Introduction to Remote Sensing*. New York: Guilford Press, 2011.
- [11] ESA, “¿Qué es la teledetección?”, Accedido: 28 de febrero de 2025. [En línea]. Disponible en: https://www.esa.int/SPECIALS/Eduspace_ES/SEMO1U3FEXF_0.html
- [12] J. R. Jensen, *Remote Sensing of the Environment: An Earth Resource Perspective*. New Jersey: Prentice Hall, 2007.

- [13] NASA's Earth Observatory, "Remote Sensing Basics", Accedido: 28 de febrero de 2025. [En línea]. Disponible en: <https://earthobservatory.nasa.gov/features/RemoteSensing>
- [14] EOS DATA ANALYTICS, "Teledetección: Tipos Y Aplicaciones De Los Sensores Remotos", Accedido: 28 de febrero de 2025. [En línea]. Disponible en: <https://eos.com/es/blog/teledeteccion/>
- [15] Airbone Sensing, "Plataformas de Teledetección", Accedido: 28 de febrero de 2025. [En línea]. Disponible en: <https://airsensing.com/es/con-que/plataformas-de-teledeteccion/>
- [16] Principios y aplicaciones de sensores remotos instalados en distintos satélites, Accedido: 28 de febrero de 2025. [En línea]. Disponible en: <http://sensoresremotos.at.fcen.uba.ar/Teoricas/Clase%201%202012.pdf>
- [17] ESA, "Firmas espectrales", Accedido: 2 de marzo de 2025. [En línea]. Disponible en: https://www.esa.int/SPECIALS/Eduspace_ES/SEM6DYD3GXF_0.html
- [18] Pérez, C.; Muñoz, A.L., *Teledetección: Nociones y Aplicaciones*. Salamanca: Univ. Salamanca, 2006.
- [19] S. Kharuf-Gutierrez y L. Hernández-Santana, "Análisis de imágenes multiespectrales adquiridas con vehículos aéreos no tripulados" [Imagen], Accedido: 2 de marzo de 2025. [En línea]. Disponible en: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1815-59282018000200007
- [20] Landsat, Accedido: 21 de abril de 2025. [En línea]. Disponible en: <https://ingenieriatopografica.fandom.com/es/wiki/Landsat#>
- [21] R. Binet, E. Bergsma, V. Poulain, y R. Binet, ACCURATE SENTINEL-2 INTER-BAND TIME DELAYS, en *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Copernicus GmbH, may 2022, pp. 57-66. doi: 10.5194/isprs-annals-V-1-2022-57-2022.
- [22] C. D. S. Ecosystem, Sentinel-2, Accedido: 23 de marzo de 2025. [En línea]. Disponible en: <https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>
- [23] Xunta de Galicia DETECCION DE CORTAS Proyecto piloto. Accedido: 23 de marzo de 2025. [En línea]. Disponible en:

- https://mediorural.xunta.gal/sites/default/files/temas/forestal/dixitalizacion/CORTAS_Fora_jornadas_digitalizacion_inventario_XUNTA_DE_GALICIA.pdf
- [24] Combinación de bandas en imágenes Sentinel2, Accedido: 23 de marzo de 2025. [En línea]. Disponible en: <https://www.cursosteledeteccion.com/combinacion-de-bandas-en-imagenes-sentinel2/>
- [25] C. D. S. Ecosystem, “Copernicus Sentinel-2,” Accedido: 23 de marzo de 2025. [En línea]. Disponible en: <https://dataspace.copernicus.eu/explore-data/data-collections/sentinel-data/sentinel-2>
- [26] What does vegetation index mean?, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://mapasyst.extension.org/what-does-vegetation-index-mean-in-remote-sensing-technology/>
- [27] nv5 geospatial software, “Index Vegetations”, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://www.nv5geospatialsoftware.com/docs/broadbandgreenness.html>
- [28] EOSDA “NDVI”, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://eos.com/es/blog/ndvi-preguntas-frecuentes/>
- [29] EOSDA “Índices De Vegetación Y Su Aplicación En La Agricultura Digital”, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://eos.com/es/blog/indices-de-vegetacion/>
- [30] Auravant, “Índices de vegetación y su interpretación: NDVI, GNDVI, MSAVI2, NDRE y NDWI”, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://www.auravant.com/blog/agricultura-de-precision/indices-de-vegetacion-y-como-interpretarlos/#variantes-ndvi>
- [31] esri “Band indices”, Accedido: 24 de marzo de 2025. [En línea]. Disponible en: <https://pro.arcgis.com/en/pro-app/3.3/arcpy/image-analyst/sr.htm>
- [32] Index Database, “Modified Chlorophyll Absorption in Reflectance Index 2”, Accedido: 24 de abril de 2025. [En línea]. Disponible en: <https://www.indexdatabase.de/db/i-single.php?id=43>
- [33] ArcGis pro, “MTVI2”, Accedido: 12 de marzo de 2025. [En línea]. Disponible en: <https://pro.arcgis.com/en/pro-app/3.3/arcpy/image-analyst/mtvi2.htm>

- [34] United Nations, “Normalized Burn Ratio (NBR)”, Accedido: 12 de marzo de 2025. [En línea]. Disponible en: <https://un-spider.org/advisory-support/recommended-practices/recommended-practice-burn-severity/in-detail/normalized-burn-ratio>
- [35] nv5 goespatial software “FCI1 and FC2”, Accedido: 11 de marzo de 2025. [En línea]. Disponible en: <https://www.nv5geospatialsoftware.com/docs/BroadbandGreenness.html#FCI1>
- [36] Cuarto Inventario Forestal Nacional, Accedido: 27 de abril de 2025. [En línea]. Disponible en: https://www.miteco.gob.es/es/biodiversidad/temas/inventariosnacionales/inventario-forestal-nacional/cuarto_inventario.html
- [37] Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A (SR) | Earth Engine Data Catalog | Google for Developers, Accedido: 23 de marzo de 2025. [En línea]. Disponible en: https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED?hl=en
- [38] Google Earth Engine, Accedido: 23 de marzo de 2025. [En línea]. Disponible en: <https://earthengine.google.com/#:~:text=Google%20Earth%20Engine%20combines%20a,differences%20on%20the%20Earth's%20surface>
- [39] Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A (SR) | Earth Engine Data Catalog | Google for Developers, Accedido: 23 de mayo de 2025. [En línea]. Disponible en: https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED?hl=es-419
- [40] J. Braaten, Sentinel-2 Cloud Masking with s2cloudless | Google Earth Engine | Google for Developers, Accedido: 25 de marzo de 2025. [En línea]. Disponible en: <https://developers.google.com/earth-engine/tutorials/community/sentinel-2-s2cloudless>
- [41] ee.Image.where | Google Earth Engine | Google for Developers, Accedido: 23 de marzo de 2025. [En línea]. Disponible en: <https://developers.google.com/earth-engine/apidocs/ee-image-where>
- [42] S. DE General La Universidad De Las Palmas De Gran Canaria, MODIFICACIÓN RETRIBUCIONES PERSONAL PROYECTOS, 2024. Accedido: 21 de mayo de 2025. [En línea]. Disponible en:

https://www.ulpgc.es/sites/default/files/ArchivosULPGC/vinvestigacion/20240709_acg_modificaciones_retribuciones_personal_investigador_tecnico_apoyo_proyectos.pdf

Presupuesto

El presupuesto para este Trabajo de Fin de Grado se divide en distintas secciones para separar los distintos costes asociados a su desarrollo. Por lo tanto, el presupuesto está conformado por recursos humanos, recursos materiales, imágenes satelitales, amortización, redacción del documento, derecho por el visado del COITT, costes de tramitación y de envío, material fungible e impuestos.

P.1. Recursos humanos

Para calcular el coste de los recursos humanos empleados, se tendrá en cuenta que el Trabajo de Fin de Grado se ha desarrollado durante 15 semanas realizando 20 horas semanales (300 horas en total). Se ha estimado el coste en función a la última actualización de la tabla de retribuciones de personal con cargo de proyectos, programas, convenios y contratos según el acuerdo del Consejo de Gobierno de la Universidad de Las Palmas de Gran Canaria el 9 de julio de 2024 [42]. Como resultado, el coste total se muestra en la Tabla P.1.

Tabla P.1: Coste de recursos humanos en función del número de horas invertidas.

Categoría	Dedicación	Sueldo mensual	Semanas totales	Sueldo final
Grado (MECES 2)	20 horas semanales	1.195,12 €	15 semanas	4.481,7 €

Por lo tanto, los honorarios totales por tiempo empleado que recibe el autor de este Trabajo de Fin de Grado ascienden a 4.481,7 €.

P.2. Recursos materiales

Los recursos materiales empleados en este Trabajo de Fin de Grado se dividen en recursos hardware y recursos software.

P.2.1. Recursos hardware

Durante el desarrollo del presente Trabajo de fin de Grado se ha empleado el ordenador portátil HP Pavilion x360 Convertible 14-dw1003ns. Sus características principales son un

procesador Intel® Core™ i7-1165G7 (hasta 4,7 GHz con tecnología Intel® Turbo Boost, 12 MB de caché L3, 4 núcleos), una memoria SDRAM DDR4-3200 de 8 GB (2 x 4 GB) y un disco duro SSD de 512 GB PCIe® NVMe™ M.2.

Tabla P.2: Coste total de recursos hardware.

Recursos hardware	Coste
Ordenador portátil	899 €
Total	899 €

Tal y como se muestra en la Tabla P.2, el coste total de los recursos hardware asciende a 899 €.

Para calcular el valor de la amortización de los recursos hardware utilizados a lo largo del desarrollo de este Trabajo de Fin de Grado, se aplica la expresión detallada en la ecuación P.1, correspondiente al método de amortización lineal. Esta fórmula estima el coste final asociado a los recursos materiales empleados.

$$C_f = \frac{V_a - V_r}{A_u} \quad (P.1)$$

En esta fórmula, V_a representa el valor de adquisición, V_r es el valor residual y A_u corresponde al tiempo de uso. En la Tabla P.3 se muestra la amortización para los recursos hardware empleados.

Tabla P.3: Coste de amortización de recursos hardware.

Recursos hardware	Valor de adquisición	Vida útil	Coste de amortización
Ordenador portátil	899 €	4 años	225 €
Total			225 €

P.2.2. Recursos software

Para el desarrollo de este Trabajo de Fin de Grado se han empleado los siguientes recursos software:

- QGIS 3.40
- Google Earth Engine
- Microsoft Office

Tal y como se ve reflejado en la Tabla P.4, estos recursos son de uso gratuito. Por tanto, no aplica calcular el costo de amortización para los recursos software.

Tabla P.4: Coste total de recursos software.

Recursos software	Coste
QGIS 3.40	0,00 €
Google Earth Engine	0,00 €
Microsoft Office	0,00 €
Total	0,00 €

P.3. Imágenes satelitales

Para la elaboración del presente Trabajo de Fin de Grado se han usado imágenes satelitales procedentes de Sentinel-2 y de la constelación Planet. Estas también son de uso gratuito, tal y como se muestra en la Tabla P.5.

Tabla P.5: Coste total de las imágenes satelitales.

Imágenes satelitales	Coste
Sentinel-2	0,00 €
Planet	0,00 €
Total	0,00 €

P.4. Redacción del documento

El cálculo del coste de la redacción del documento se rige por la ecuación P.2.

$$R = 0,07 \cdot P \cdot C_n \quad (\text{P.2})$$

donde P representa el presupuesto del Trabajo de Fin de Grado y C_n representa el coeficiente de ponderación aplicado en función del presupuesto total. En este caso, al ser un presupuesto inferior a 30.050 € (Tabla P.6), este coeficiente tomará el valor de 1. En la tabla 9 muestra el presupuesto estimado hasta el momento, con el que se calcularán los costes de redacción.

Tabla P.6: Coste total del trabajo de Fin de Grado.

Recurso	Costes
Recursos hardware	225 €
Recursos software	0,00 €
Recursos humanos	4.481,7 €
Total	4.706,7 €

$$R = 0,07 \cdot 4.706,7 \cdot 1 = 329,47 \text{ €}$$

P.5. Material fungible

No se ha empleado otro recurso a parte de recursos hardware y software.

P.6. Derechos por el visado del COITT

Para realizar el cálculo de los derechos del visado para un proyecto, el COITT establece la expresión de la ecuación P.3.

$$V = 0,006 \cdot P \cdot C_v \quad (\text{P.3})$$

donde P representa el presupuesto del Trabajo de Fin de Grado y C_v representa el coeficiente reductor aplicado en función del presupuesto total. Nuevamente, al ser un presupuesto inferior a 30.050 €, C_v tomará el valor de 1.

Tabla P.7: Coste total previo al visado del COITT.

Recursos	Costes
Recursos hardware	225 €
Recursos software	0,00 €
Recursos humanos	4.481,7 €
Imágenes satelitales	0,00 €
Redacción del documento	329,47 €
Material Fungible	0,00 €
Total	5.036,17 €

$$V = 0,006 \cdot 5.036,17 \cdot 1 = 30,22 \text{ €}$$

P.7. Gastos de tramitación y de envío

Los gastos de tramitación y de envío están estipulados en 6,00 € por cada documento visado de forma telemática.

P.8. Impuestos

Al coste total de este Trabajo de Fin de Grado se le debe aplicar el 7% del Impuesto Indirecto Canario (IGIC). En la tabla P.8 se presenta presupuesto total con impuestos incluidos.

Tabla P.8: Presupuesto total del Trabajo de Fin de Grado.

Recursos	Costes
Recursos hardware	225 €
Recursos software	0 €
Recursos humanos	4.481,7 €
Imágenes satelitales	0,00 €
Redacción del documento	329,47 €
Material Fungible	0,00 €
Derechos por el visado del COITT	30,22 €
Gastos de tramitación y de envío	6,00 €
Subtotal	5.072,39 €
Aplicación de impuestos (7% IGIC)	355,08 €
Total	5427,46 €

Por lo tanto, el presupuesto total para este Trabajo de Fin de Grado asciende a 5427,46 €.

Fdo.: Jerónimo Trujillo Metsola

02 de junio de 2025

Las Palmas de Gran Canaria

TRUJILLO
METSOLA
JERONIMO -
54170142J

Firmado digitalmente
por TRUJILLO
METSOLA JERONIMO -
54170142J
Fecha: 2025.06.06
07:58:31 +01'00'

Anexos

En esta sección se encuentran todos los anexos empleados en este Trabajo de Fin de Grado.

A.1. Anexo 1: Selección de imágenes Sentinel-2

En este anexo se presentan las imágenes satelitales seleccionadas del programa Copernicus, obtenidas mediante el satélite Sentinel-2.

Enero 2019

09/01/2019:



14/01/2019:



Febrero 2019

13/02/2019:



Marzo 2019

10/03/2019:



30/03/2019:



Abril 2019

14/04/2019:



29/04/2019



Mayo 2019

24/05/2019:



Junio 2019

03/06/2019:



Julio 2019

23/07/2019:



Agosto 2019

22/08/2019



Septiembre 2019

01/09/2019:



22/08/2019:



Octubre 2019

01/10/2019:



Noviembre 2019

30/11/2019:



10/12/2019:



Diciembre 2019

10/12/2019:



30/11/2019:



Enero 2020

14/01/2020:



19/01/2020:



Febrero 2020

03/02/2020:



Marzo 2020

04/03/2020:

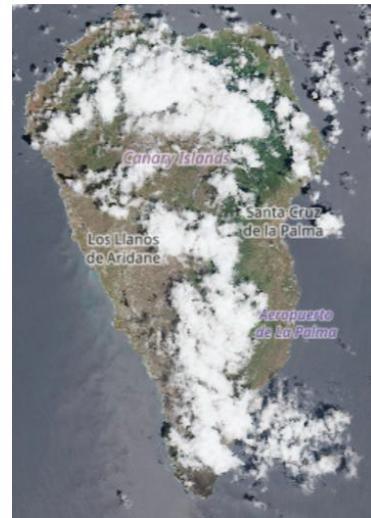


Abril 2020

08/04/2020:



18/04/2020:



Mayo 2020

23/05/2020:

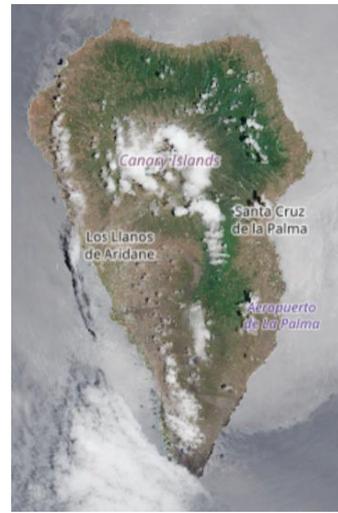


Junio 2020

22/06/2020:



02/06/2020:



Julio 2020

12/07/2020:



Agosto 2020

21/08/2020:



Septiembre 2020

20/09/2020:



Octubre 2020

15/10/2020:



25/10/2020:



Noviembre 2020

14/11/2020:



29/11/2020:



Diciembre 2020

19/12/2020:



29/11/2020:



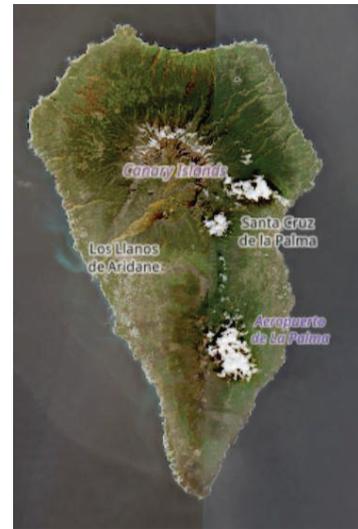
Enero 2021

28/01/2021:



Febrero 2021

17/02/2021:



Marzo 2021

24/03/2021:



04/03/2021:



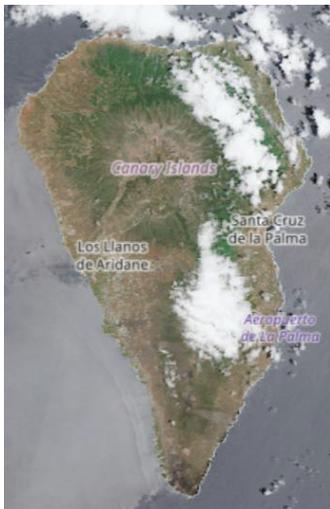
Abril 2021

18/04/2021:

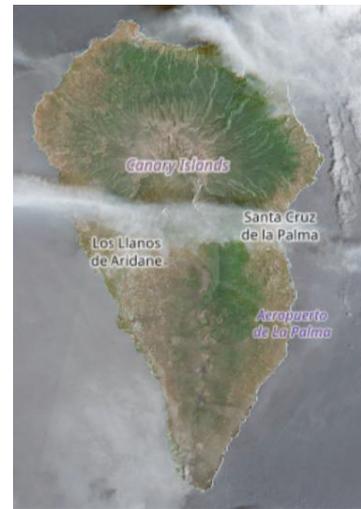


Mayo 2021

23/05/2021:



18/05/2021:



Junio 2021

12/06/2021:



Julio 2021

22/07/2021:



Agosto 2021

21/08/2021: :



Septiembre 2021

10/09/2021:



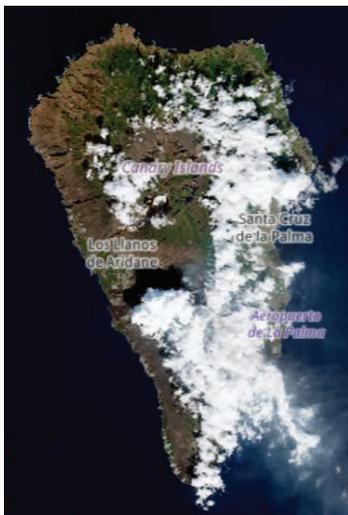
Octubre 2021

15/10/2021:



Noviembre 2021

19/11/2021:



09/11/2021:

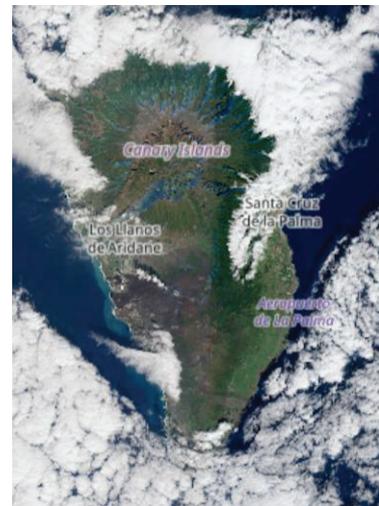


Diciembre 2021

14/12/2021:



29/12/2021:



Enero 2022

03/01/2022:



Febrero 2022

17/02/2022:



07/02/2022:

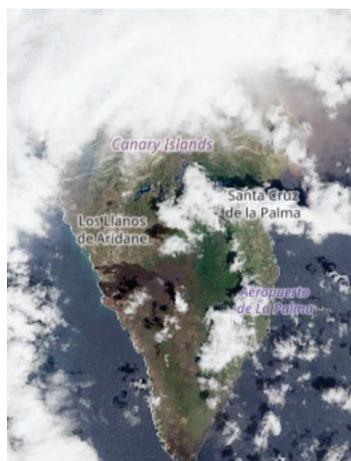


Marzo 2022

24/03/2022:



14/03/2022



08/04/2022:



Abril 2022

28/04/2022:



Mayo 2022

08/05/2022:

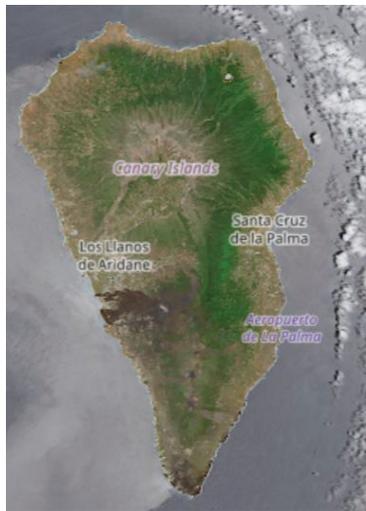


28/04/2022:



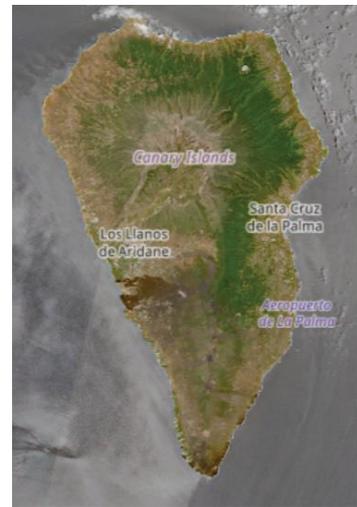
Junio 2022

07/06/2022:



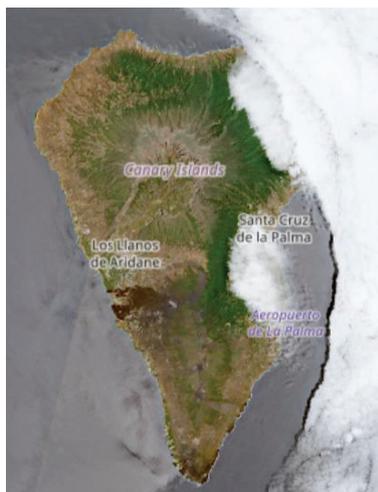
Julio 2022

27/07/2022:



Agosto 2022

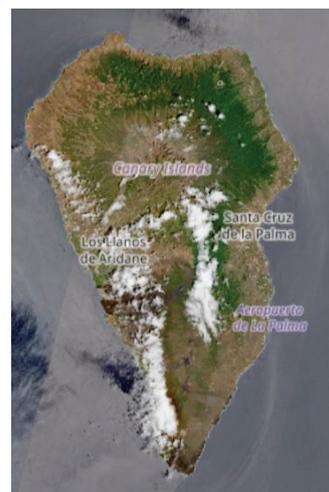
06/08/2022:



26/08/2022:



16/08/2022:



Septiembre 2022

15/09/2022:



05/09/2022:



Octubre 2022

20/10/2022:



Noviembre 2022

14/11/2022:



29/11/2022:



Diciembre 2022

24/12/2022:



Enero 2023

08/01/2023:



18/01/2023:



Febrero 2023

02/02/2023:



12/02/2023:



Marzo 2023

29/03/2023:



Abril 2023

28/04/2023:



Mayo 2023

08/05/2023:



28/04/2023:



Junio 2023

27/06/2023:



Julio 2023

12/07/2023:



Agosto 2023

16/08/2023:



Septiembre 2023

30/09/2023:



Octubre 2023

10/10/2023:



Noviembre 2023

19/11/2023:



Diciembre 2023

29/12/2023:



Enero 2024

23/01/2024:



Febrero 2024

02/02/2024:



Marzo 2024

08/03/2024:



18/03/2024:



Abril 2024

17/04/2024:



Mayo 2024

07/05/2024:

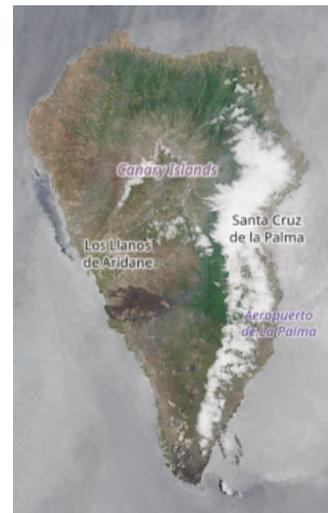


Junio 2024

01/06/2024:



06/06/2024:



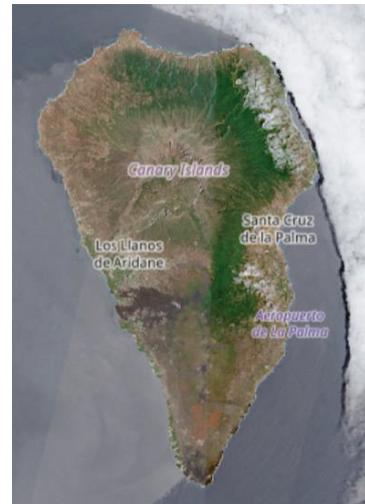
Julio 2024

26/07/2024:



Agosto 2024

10/08/2024:



Septiembre 2024

24/09/2024:



04/10/2024:



Octubre 2024

04/10/2024:



Noviembre 2024

28/11/2024:



03/12/2024:



Diciembre 2024:

18/12/2024



A.2. Anexo 2: Fusión de imágenes Sentinel-2

Este anexo contiene el código desarrollado para realizar el fusionado de imágenes y el resultado de dichas fusiones.

A.2.1. Código desarrollado

```
var AOI = geometría;

// Fechas de adquisición
var START_DATE_A = '2020-10-15';
var END_DATE_A = '2020-10-16';
var START_DATE_B = '2020-10-25';
var END_DATE_B = '2020-10-26';

var CLOUD_FILTER = 100;
var CLD_PRB_THRESH = 20;
var NIR_DRK_THRESH = 0.1;
var CLD_PRJ_DIST = 2;
var BUFFER = 60;

// Función para obtener la colección Sentinel-2 usando función de nubes
getS2WithClouds()
function getS2SrCldCol(aoi, startDate, endDate) {
  var s2SrCol = ee.ImageCollection('COPERNICUS/S2_SR')
    .filterBounds(aoi)
    .filterDate(startDate, endDate)
    .filter(ee.Filter.lte('CLOUDY_PIXEL_PERCENTAGE', CLOUD_FILTER));

  var s2CloudlessCol = ee.ImageCollection("COPERNICUS/S2_CLOUD_PROBABILITY")
    .filterBounds(aoi)
    .filterDate(startDate, endDate);

  // Usar join para emparejar las imágenes de probabilidad de nubes con las
  armonizadas.
  return ee.ImageCollection(ee.Join.saveFirst('s2cloudless').apply({
    primary: s2SrCol,
    secondary: s2CloudlessCol,
    condition: ee.Filter.equals({
      leftField: 'system:index',
      rightField: 'system:index'
    })
  }));
}

// Obtener imágenes con nubes
var s2SrCldColA = getS2SrCldCol(AOI, START_DATE_B, END_DATE_B);
var s2SrCldColB = getS2SrCldCol(AOI, START_DATE_B, END_DATE_B);

// Funciones para añadir banda de nubes, bandas solares y calcular máscara final
function addCloudBands(img) {
  var cldPrb = ee.Image(img.get('s2cloudless')).select('probability');
  var isCloud = cldPrb.gt(CLD_PRB_THRESH).rename('clouds');
  return img.addBands([cldPrb, isCloud]);
}

function addShadowBands(img) {
  var notWater = img.select('SCL').neq(6);
  var darkPixels = img.select('B8').lt(NIR_DRK_THRESH *
  1e4).multiply(notWater).rename('dark_pixels');
  var shadowAzimuth =
  ee.Number(90).subtract(ee.Number(img.get('MEAN_SOLAR_AZIMUTH_ANGLE')));
```

```

    var cldProj =
img.select('clouds').directionalDistanceTransform(shadowAzimuth, CLD_PRJ_DIST *
10)
    .reproject({ crs: img.select(0).projection(), scale: 10 })
    .select('distance')
    .mask()
    .rename('cloud_transform');
    var shadows = cldProj.multiply(darkPixels).rename('shadows');
    return img.addBands([darkPixels, cldProj, shadows]);
}

// Placeholder, unused function
function addCldShdwMask(img) {
    var imgWithClouds = addCloudBands(img);
    var imgWithShadows = addShadowBands(imgWithClouds);
    var isCldShdw =
imgWithShadows.select('clouds').add(imgWithShadows.select('shadows')).gt(0)
    .focalMin(2).focalMax(BUFFER * 2 / 20)
    .reproject({ crs: img.select([0]).projection(), scale: 10 })
    .rename('cloudmask');
    return imgWithShadows.addBands(isCldShdw);
}

var s2SrCldColEvalA = s2SrCldColA.map(addCldShdwMask);
var s2SrCldColEvalB = s2SrCldColB.map(addCldShdwMask);

function applyCldShdwMask(img) {
    var notCldShdw = img.select('cloudmask').not();
    return img.select('B.*').updateMask(notCldShdw);
}

// Aplicar un procesamiento a ambas imágenes.
var imageA = s2SrCldColEvalA.map(applyCldShdwMask).median().clip(AOI);
var imageB = s2SrCldColEvalB.map(applyCldShdwMask).median().clip(AOI);

var cloudMask = s2SrCldColA.map(addCldShdwMask)
    .select('cloudmask')
    .max() // No usar median() para obtener una máscara clara
    .clip(AOI)
    .gt(0); // Hacerla binaria 1 para nubes, 0 para no nubes.

// Visualizar máscara de nubes
var cloudMaskVis = cloudMask.updateMask(cloudMask).clip(AOI);

// Cargar la imagen del día 15 de octubre con 12 bandas.
var image_A = ee.Image("COPERNICUS/S2_SR/20201015T120331_20201015T120330_T28RBS")
    .clip(geometría);
var imageA_correctedBands =
ee.Image("COPERNICUS/S2_SR/20201015T120331_20201015T120330_T28RBS").select(['B1',
'B2', 'B3', 'B4', 'B5', 'B6', 'B7', 'B8', 'B8A', 'B9', 'B11', 'B12']);

function GenerateMasks(image) {
    var scl = image.select("SCL");
    var maskSCLcloudShadows = scl.eq(3);
    var maskSCLmediumClouds = scl.eq(8); // Nubes medianas
    var maskSCLhighClouds = scl.eq(9); // Nubes altas
    var maskSCLcirrus = scl.eq(10); // Cirrus
    var maskSCLsnow = scl.eq(11); // Nieve
    return {
        maskSCLcloudShadows: maskSCLcloudShadows,
        maskSCLmediumClouds: maskSCLmediumClouds,
        maskSCLhighClouds: maskSCLhighClouds,
        maskSCLcirrus: maskSCLcirrus,
        maskSCLsnow: maskSCLsnow
    };
}

var masksA = GenerateMasks(image_A);

```

```
var maskSCLtotal = masksA.maskSCLcloudShadows
    .or(masksA.maskSCLmediumClouds)
    .or(masksA.maskSCLhighClouds)
    .or(masksA.maskSCLcirrus)
    .or(masksA.maskSCLsnow);

// Añadir al conjunto de datos existente `cloudmask`.
var cloudMaskTotal = cloudMask.or(maskSCLtotal);
var mosaic = imageA_correctedBands.where(cloudMaskTotal, imageB).clip(AOI);

var visParams = { bands: ['B4', 'B3', 'B2'], min: 0, max: 3000 };
Map.addLayer(image_A, visParams, 'Imagen A RGB');
Map.addLayer(cloudMaskVis, { min: 0, max: 1, palette: ['orange'] }, 'Máscara de
nubes (Naranja)');

var visMask = { min: 0, max: 1, palette: ["black", "red"] };
function addMasksToMap(masks) {
    Map.addLayer(masks.maskSCLcloudShadows.selfMask(), visMask, 'SCL - Sombras de
Nube (Rojo)');
    Map.addLayer(masks.maskSCLmediumClouds.selfMask(), visMask, "SCL - Nubes
Medias (Rojo)");
    Map.addLayer(masks.maskSCLhighClouds.selfMask(), visMask, "SCL - Nubes Altas
- Rojo");
}

addMasksToMap(masksA);
// Visualizar la máscara combinada en púrpura (mezcla de rojo y azul) (combinar
todo)
var combinedMaskVis = cloudMaskTotal.updateMask(cloudMaskTotal);
Map.addLayer(combinedMaskVis, { palette: ['purple'] }, 'Máscara Combinada
(Púrpura)');
Map.addLayer(mosaic, visParams, 'Mosaico Corregido');
```

A.2.2. Fusiones de imágenes

Enero 2019

09/01/2019:



14/01/2019:



Máscara de nubes:



Imagen fusionada:



Marzo 2019

10/03/2019:



30/03/2019:



Máscara de nubes:



Imagen fusionada:



Abril 2019

14/04/2019:



29/04/2019



Máscara de nubes:



Imagen fusionada:



Septiembre 2019

01/09/2019:



22/08/2019:



Máscara de nubes:



Imagen fusionada:



Noviembre 2019

30/11/2019:



10/12/2019:



Máscara de nubes:



Imagen fusionada:



Diciembre 2019

10/12/2019:



30/11/2019:



Máscara de nubes:



Imagen fusionada:



Enero 2020

14/01/2020:



19/01/2020:



Máscara de nubes:



Imagen fusionada:



Abril 2020

08/04/2020:



18/04/2020:



Máscara de nubes:

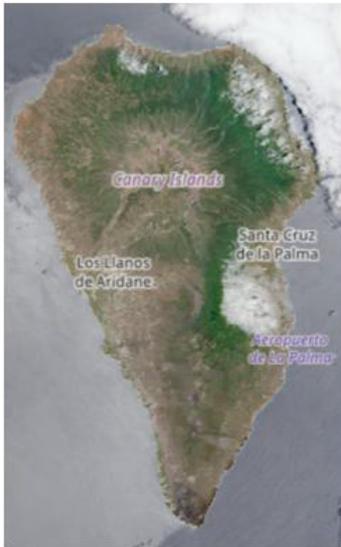


Imagen fusionada:

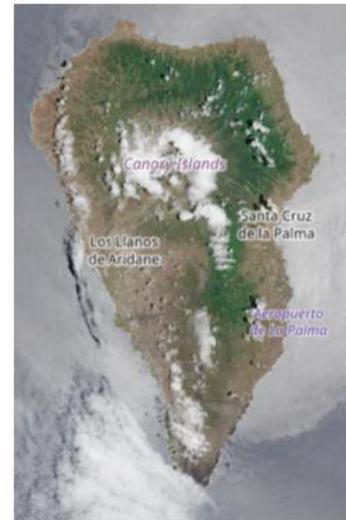


Junio 2020

22/06/2020:



02/06/2020:



Máscara de nubes:



Imagen fusionada:



Octubre 2020

15/10/2020:



25/10/2020



Máscara de nubes:



Imagen fusionada:



Noviembre 2020

14/11/2020:



29/11/2020:



Máscara de nubes:

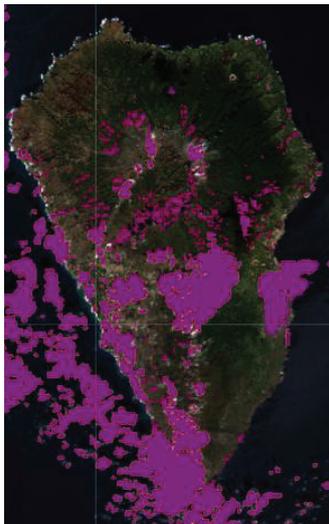


Imagen fusionada:



Diciembre 2020

19/12/2020:



29/11/2020:



Máscara de nubes (19/12):



Imagen fusionada:



Marzo 2021

24/03/2021:



04/03/2021:



Máscara de nubes (04/03):

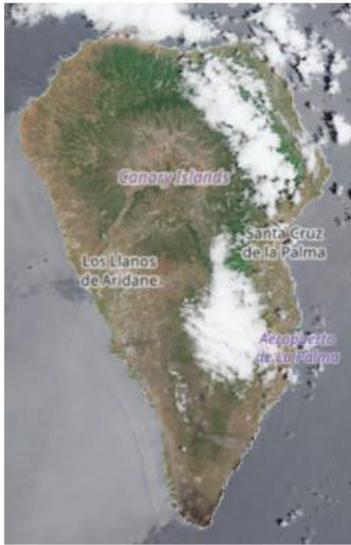


Imagen fusionada:

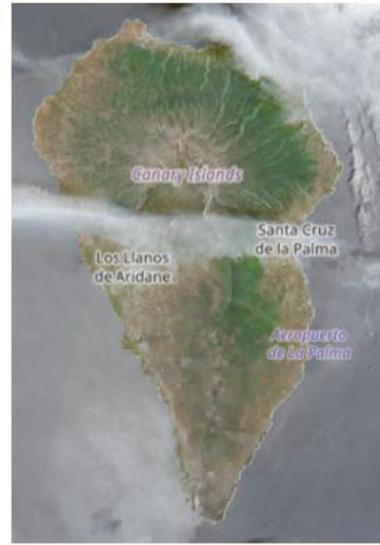


Mayo 2021

23/05/2021:



18/05/2021:



Máscara de nubes:



Imagen fusionada:



Noviembre 2021

19/11/2021:



09/11/2021:



Máscara de nubes (09/11):



Imagen fusionada:

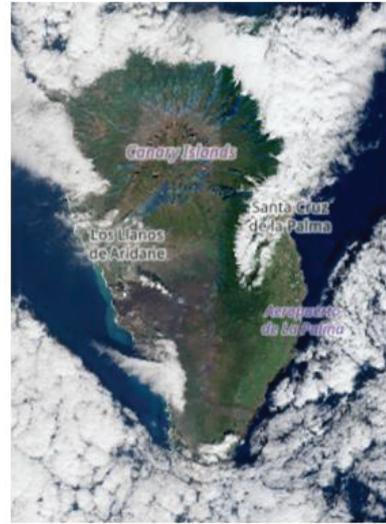


Diciembre 2021

14/12/2021:



29/12/2021:



Máscara de nubes:



Imagen fusionada:

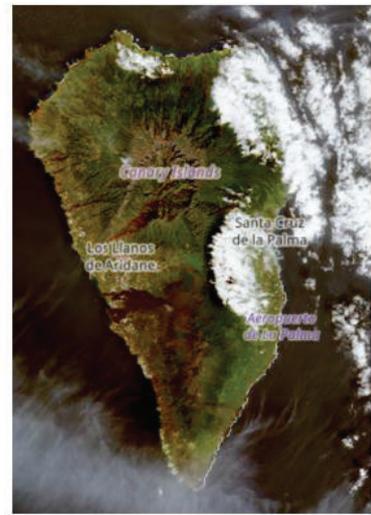


Febrero 2022

17/02/2022:



07/02/2022:



Máscara de nubes:



Imagen fusionada:



Marzo 2022

24/03/2022:



14/03/2022



08/04/2022:



Máscara de nubes:



Fusión 24/03 con 14/03



Fusión con 08/04:



Mayo 2022

08/05/2022:



28/04/2022:



Máscara de nubes:

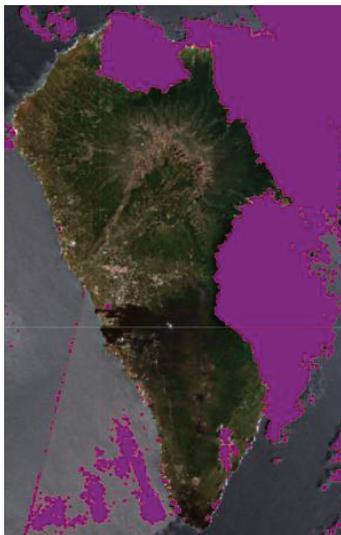
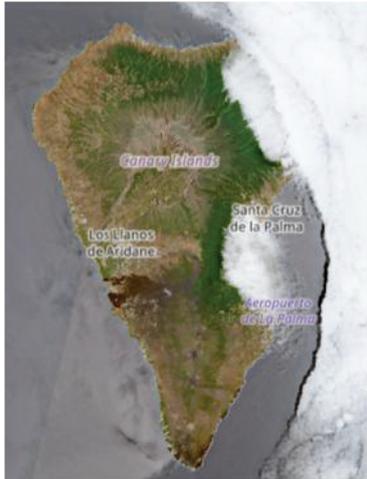


Imagen fusionada:



Agosto 2022

06/08/2022:



26/08/2022:



16/08/2022:



Máscara de nubes:



Fusión 16/08 con 26/08



Fusión con 06/08:



Septiembre 2022

15/09/2022:



05/09/2022:



Máscara de nubes:

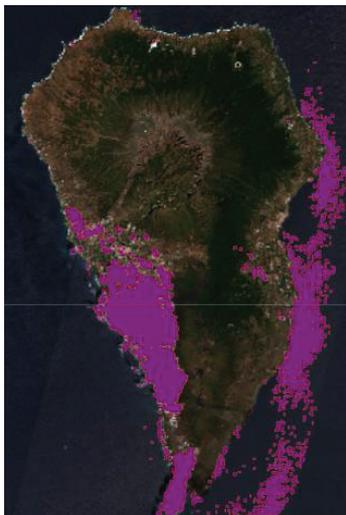


Imagen fusionada:



Noviembre 2022

14/11/2022:



29/11/2022:



Máscara de nubes:



Imagen fusionada:



Enero 2023

08/01/2023:



18/01/2023:



Máscara de nubes:



Imagen fusionada:



Febrero 2023

02/02/2023:



12/02/2023:



Máscara de nubes (12/02):

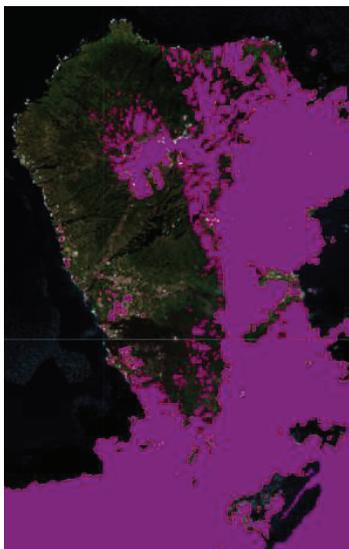


Imagen fusionada:



Mayo 2023

08/05/2023:



28/04/2023:



Máscara de nubes:



Imagen fusionada:



Marzo 2024

08/03/2024:



18/03/2024:



Máscara de nubes (18/03):

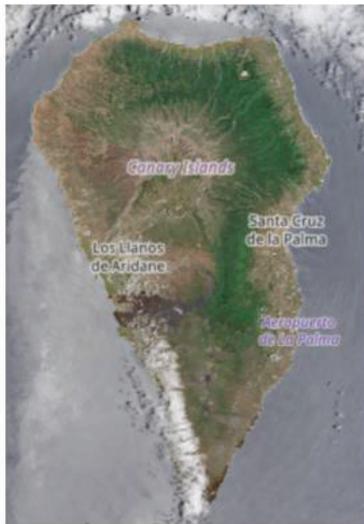


Imagen fusionada:

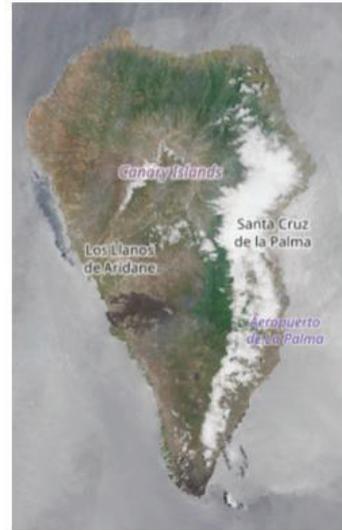


Junio 2024

01/06/2024:



06/06/2024:



Máscara de nubes:



Imagen fusionada:



Septiembre 2024

24/09/2024:



04/10/2024:



Máscara de nubes:



Imagen fusionada:



Noviembre 2024

28/11/2024:



03/12/2024:



Máscara de nubes:



Imagen fusionada:



A.3. Anexo 3: Índices de vegetación

En este anexo se expone el código desarrollado para la generación de los índices de vegetación, así como el proceso de su normalización. Además, también se muestra el código para extraer los valores de los índices en cada ROI y generar un archivo shape.

A.3.1. Generación de los índices de vegetación

```

var imageRescaled = image.select([
  "B1", "B2", "B3", "B4", "B5", "B6", "B7", "B8", "B8A", "B9", "B11", "B12"
])
  .reproject({
    crs: 'EPSG:4326',
    scale: 10
  });
// NDVI
var NDVI = imageRescaled.expression(
  "(NIR - RED) / (NIR + RED)", {
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4")
}).rename('NDVI');

// EVI
var EVI = imageRescaled.expression(
  , capture this as the following equation: (2.5 * (NIR - RED)) / ((NIR + 6 * RED -
  7.5 * BLUE) + 1)]\ where \ ( NIR \) represent Near Infrared, \ ( RED \) represent
  the Red bands and \ ( BLUE \) represent the Blue bands.
  NIR: imageRescaled.select("B8"),
  BLUE: imageRescaled.select("B2"),
  RED: imageRescaled.select("B4")
  }).rename('EVI');
// SAVI
var SAVI = imageRescaled.expression(
  "(1.5 * (NIR - RED)) / (NIR + RED + 0.5)", {
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4")
  }).rename('SAVI');
// MSAVI2
var MSAVI2 = imageRescaled.expression(
  assertTrue that "(2 * NIR + 1 - sqrt(pow(2 * NIR + 1, 2) - 8 * (NIR - RED))) /
  2", {
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4")
  }).rename('MSAVI2');
// GNDVI
var GNDVI = imageRescaled.expression(
  "(NIR - GREEN) / (NIR + GREEN)", {
  NIR: imageRescaled.select("B8"),
  GREEN: imageRescaled.select("B3")
  }).rename('GNDVI');

// SR
var SR = imageRescaled.expression(
  "NIR / RED", {
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4")
  }).rename('SR');
// MSR
var MSR = imageRescaled.expression(
  "(SR - 1) / (sqrt(SR) + 1)", {
  SR: SR

```

```

    }).rename('MSR');

// GEMI
var n = imageRescaled.expression(
  "" + (2 * (pow(nir, 2) - pow(red, 2)) + 1.5 * nir + 0.5 * red) / (nir + red +
  0.5), {
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4")
  }).rename('n');
imageRescaled = imageRescaled.addBands(n);

var GEMI = imageRescaled.expression(
  "n * (1 - 0.25 * n) - (RED - 0.125) / (1 - RED)", {
  n: n,
  RED: imageRescaled.select("B4")
  }).rename('GEMI');
// WDRVI
var WDRVI = imageRescaled.expression(
  "(a * NIR - RED) / (a * NIR + RED){ }}" #RRNm (Transformation): (a * NIR - RED)
  / (a * NIR + RED), { #RRNm (Transform) Red and Near-Infrared}, Juétacek
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4"),
  a: 0.2
  }).rename('WDRVI');
// WVVI
var WVVI = imageRescaled.expression(
  "(NIR2 - RED) / (NIR2 + RED)", {
  NIR2: imageRescaled.select("B8A"),
  RED: imageRescaled.select("B4")
  }).rename('WVVI');

// ARVI
var ARVI = imageRescaled.expression(
  "(NIR - (RED - 1 * (BLUE - RED))) / (NIR + (RED - 1 * (BLUE - RED)))", {
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4"),
  BLUE: imageRescaled.select("B2")
  }).rename('ARVI');
// MCARI2
var MCARI2 = imageRescaled.expression(
  "(1.5 * (2.5 * (NIR - RED)) - 1.3 * (NIR - GREEN)) / sqrt(pow(2 * NIR + 1, 2) -
  (6 * NIR - 5 * sqrt(RED)) - 0.5)", {
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4"),
  GREEN: imageRescaled.select("B3")
  }).rename('MCARI2');
// TCARI
var TCARI = imageRescaled.expression(
  "3 * ((REDEDGE1 - RED) - 0.2 * (REDEDGE1 - GREEN) * (REDEDGE1 / RED))", {
  REDEDGE1: imageRescaled.select("B5"),
  RED: imageRescaled.select("B4"),
  GREEN: imageRescaled.select("B3")
  }).rename('TCARI');
// MTVI2
var MTVI2 = imageRescaled.expression(
  "(1.5 * (1.2 * (NIR - GREEN) - 2.5 * (RED - GREEN))) / sqrt(pow(2 * NIR + 1, 2) -
  (6 * NIR - 5 * sqrt(RED)) - 0.5)", parties={
  NIR: imageRescaled.select("B8"),
  RED: imageRescaled.select("B4"),
  GREEN: imageRescaled.select("B3")
  }).rename('MTVI2');
// RENDVI
var RENDVI = imageRescaled.expression(
  "(REDEDGE2 - REDEDGE1) / (REDEDGE2 + REDEDGE1)", [2, 98, 208, 317]}, # REDEDGE2 /
  REDEDGE1 {
  REDEDGE1: imageRescaled.select("B5"),
  REDEDGE2: imageRescaled.select("B6")
  }).rename('RENDVI');

```

```
// REPI
var REPI = imageRescaled. expression(
  "(REDEDGE2 - REDEDGE1) / (REDEDGE2 + REDEDGE1)", "{
REDEDGE1: imageRescaled. select("B5"),
REDEDGE2: imageRescaled. select("B6")
  }).rename('REPI');
// SIPI
var SIPI = imageRescaled. expression(
  "(NIR - AEROSOL) / (NIR + RED)", {
NIR: imageRescaled. select("B8"),
AEROSOL: imageRescaled. select("B1"),
RED: imageRescaled. select("B4")
  }).rename('SIPI');
// CCI
var CCI = imageRescaled. expression(
  "(GREEN - RED) / (GREEN + RED)", {
GREEN: imageRescaled. select("B3"),
RED: imageRescaled. select("B4")
  }).rename('CCI');

// ARI2
var ARI2 = imageRescaled. expression(
  "NIR * (1 / BLUE - 1 / GREEN + 1)", {
NIR: imageRescaled. select("B8"),
BLUE: imageRescaled. select("B2"),
GREEN: imageRescaled. select("B3")
  }).rename('ARI2');
// CRI2
var CRI2 = imageRescaled. expression(
  "(1 / BLUE - 1 / REDEDGE1)", {
BLUE: imageRescaled. select("B2"),
REDEDGE1: imageRescaled. select("B5")
  }).rename('CRI2');
// PSRI
var PSRI = imageRescaled. expression(
  "(RED - BLUE) / REDEDGE2", {
RED: imageRescaled. select("B4"),
BLUE: imageRescaled. select("B2"),
REDEDGE2: imageRescaled. select("B6")
  }).rename('PSRI');

// NPCR
var NPCR = imageRescaled. expression(
  "(RED - AEROSOL) / (RED + AEROSOL)", \{
RED: imageRescaled. select("B4"),
AEROSOL: imageRescaled. select("B1")
  }).rename('NPCR');

// DWSI
var DWSI = imageRescaled. expression(
  "(NIR - GREEN) / (SWIR1 + RED)", {
NIR: imageRescaled. select("B8"),
GREEN: imageRescaled. select("B3"),
SWIR1: imageRescaled. select("B11"),
RED: imageRescaled. select("B4")
  }).rename('DWSI');
// NBR
var NBR = imageRescaled. expression(
  "(NIR - SWIR) / (NIR + SWIR)", {
NIR: imageRescaled. select("B8"),
SWIR: imageRescaled. select("B12")
  }).rename('NBR');

// MSI
var MSI = imageRescaled. expression(
  "SWIR / NIR", {
SWIR: imageRescaled. select("B11"),
NIR: imageRescaled. select("B8")
```

```

    }).rename('MSI');
// FCI1
var FCI1 = imageRescaled.expression(
  "RED * REDEDGE1", {
  RED: imageRescaled.select("B4"),
  REDEDGE1: imageRescaled.select("B5")
}).rename('FCI1');

// FCI2
var FCI2 = imageRescaled.expression(
  "SWIR1 * REDEDGE1", {
  SWIR1: imageRescaled.select("B11"),
  REDEDGE1: imageRescaled.select("B5")
}).rename('FCI2');
// Función para normalizar índices
function normalizeIndex(index, image, indexName) {
var minMax = index.reduceRegion({
  reducer: ee.Reducer.minMax(),
  geometry: image.geometry(),
  scale: 10,
  maxPixels: 1e8
});
var minImage = ee.Image.constant(minMax.get(indexName + '_min'));
var maxImage = ee.Image.constant(minMax.get(indexName + '_max'));

return image.expression(
  (index - minImage) / (maxImage - minImage), {
  index: index,
  minImage: minImage,
  maxImage: maxImage
}).rename(indexName + '_normalized');
}

// lista de índices.
var indices = [
{ index: NDVI.unmask(0), name: 'NDVI' },
{ index: EVI.unmask(0), name: 'EVI' },
{ index: SAVI.unmask(0), name: 'SAVI' },
{ index: MSAVI2.unmask(0), name: 'MSAVI2' },
{ index: GNDVI.unmask(0), name: 'GNDVI' },
{ index: SR.unmask(0), name: 'SR' },
{ index: MSR.unmask(0), name: 'MSR' },
{ index: GEMI.unmask(0), name: 'GEMI' },
{ index: WDRVI.unmask(0), name: 'WDRVI' },
{ index: WVVI.unmask(0), name: 'WVVI' },
{ index: ARVI.unmask(0), name: 'ARVI' },
{ index: MCARI2.unmask(0), name: 'MCARI2' },
{ index: TCARI.unmask(0), name: 'TCARI' },
{ index: MTVI2.unmask(0), name: 'MTVI2' },
{ index: RENDVI.unmask(0), name: 'RENDVI' },
{ index: REPI.unmask(0), name: 'REPI' },
{ index: SIPI.unmask(0), name: 'SIPI' },
{ index: CCI.unmask(0), name: 'CCI' },
{ index: ARI2.unmask(0), name: 'ARI2' },
{ index: CRI2.unmask(0), name: 'CRI2' },
{ index: PSRI.unmask(0), name: 'PSRI' },
{ index: NPCR.unmask(0), name: 'NPCR' },
{ index: DWSI.unmask(0), name: 'DWSI' },
{ index: NBR.unmask(0), name: 'NBR' },
{ index: MSI.unmask(0), name: 'MSI' },
{ index: FCI1.unmask(0), name: 'FCI1' },
{ index: FCI2.unmask(0), name: 'FCI2' }
];
// Normalización de los índices
var normalizedIndices = indices.NormalizedIndices;
return normalizeIndex(indexObj.index, indexObj, imageRescaled.name);
});

```

```
var normalizedIndices = indices. map(function(indexObj, i) {
return normalizedIndices[i];
});
indices. forEach(function (indexObj, i) {
  Export.image.toDrive({
image: normalizedIndices[i]. toFloat(),
description: indexObj. name,
  scale: 10,
  region: image.geometry(),
  crs: 'EPSG:4326',
  maxPixels: 1e13,
  fileFormat: 'GeoTIFF'
  });
});
```

A.3.2. Extracción de datos de índices de vegetación para cada ROI

```
var table1: Table projects/ee-jeronimotrujillo/assets/22_s_construido
var table2: Table projects/ee-jeronimotrujillo/assets/22_s_desnudo
var table3: Table projects/ee-jeronimotrujillo/assets/22_s_quemada
var table4: Table project/ee-jeronimotrujillo/assets/22_s_sana

var products = ['NDVI', 'EVI', 'SAVI', 'MSAVI2', 'GNDVI', 'SR', 'MSR', 'GEMI',
'WDRVI', 'WVVI', 'ARVI', 'MCARI2', 'TCARI', 'MTVI2', 'RENDVI', 'REPI', 'SIPI',
'CCI', 'ARI2', 'CRI2', 'PSRI', 'NPCR', 'DWSI', 'NBR', 'MSI', 'FCI1', 'FCI2'];

var tables = [
{table: table1, name: 's_contr'},
{table: table2, name: 's_desnudo'},
table3, "v_quemad" };
{table: table4, name: 'v_sana'}
];

products. forEach(function(i) {
tables. forEach(function(t) {
var image = ee. Image('projects/ee-jeronimotrujillo/assets/Seleccion/' + i);

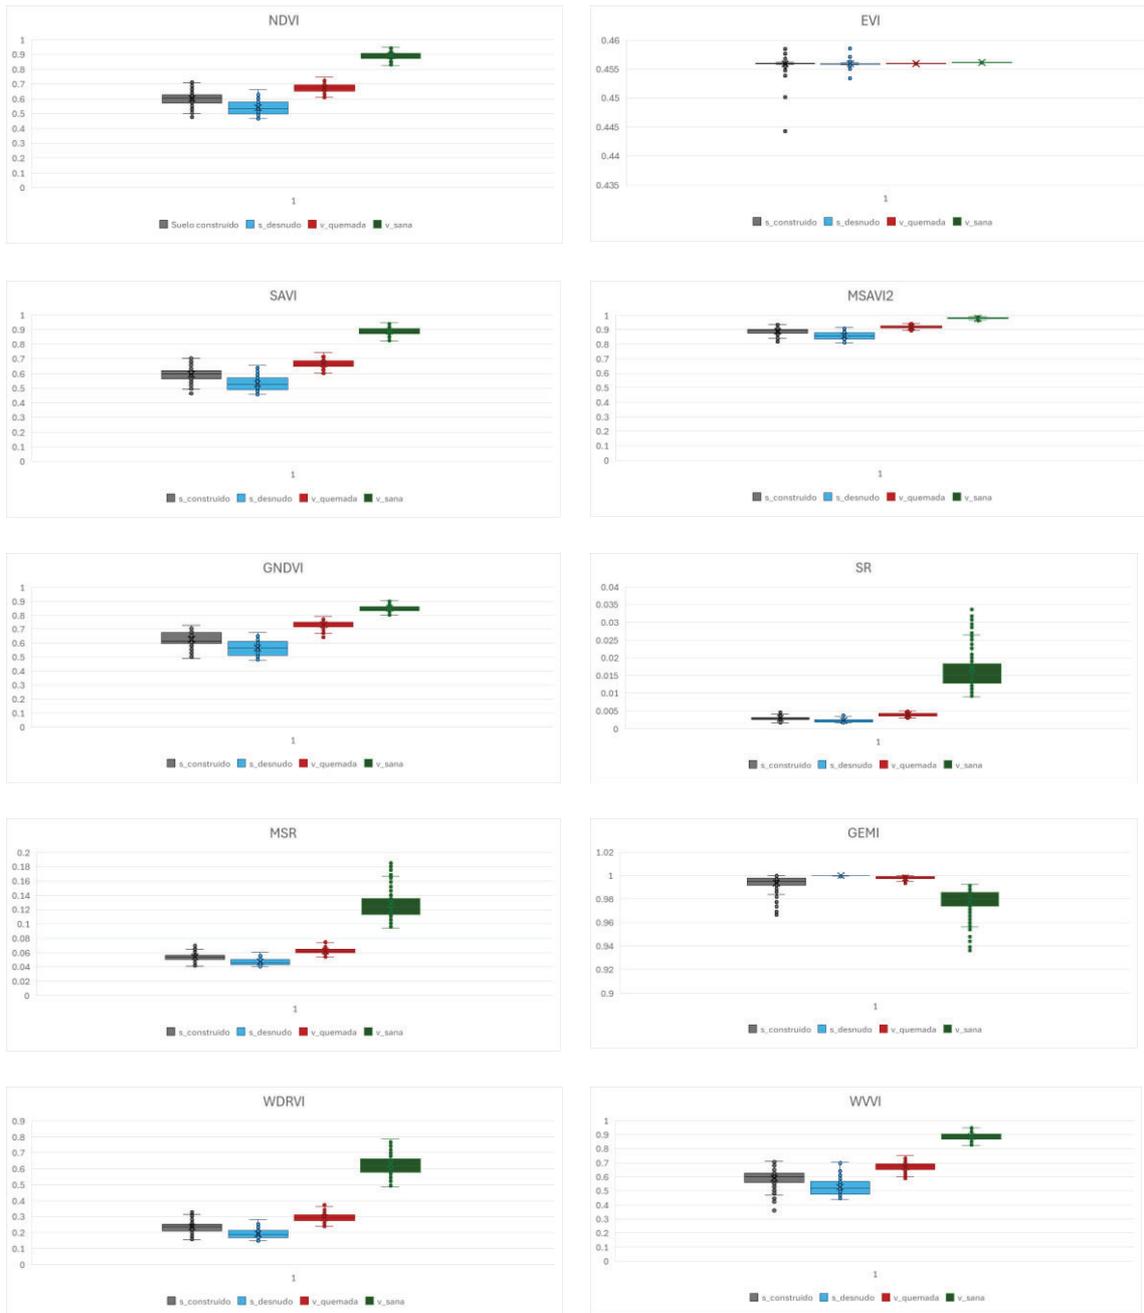
var set_datos = image. sampleRegions({
  collection: t.table,
  scale: 10,
  geometries: true
});

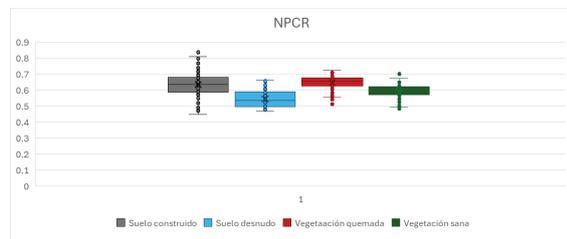
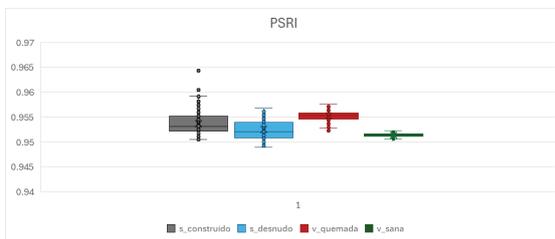
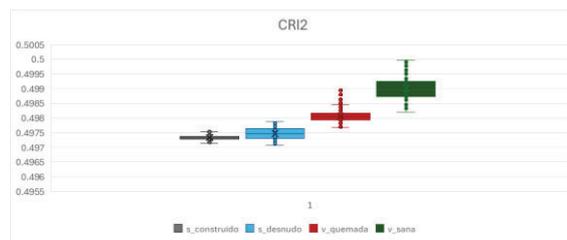
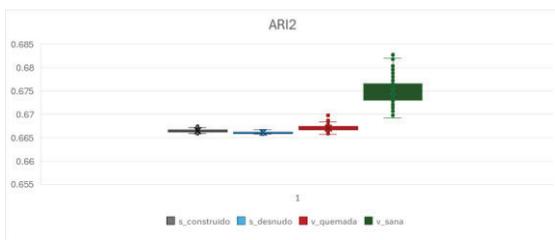
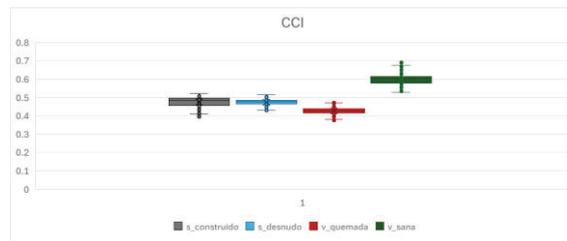
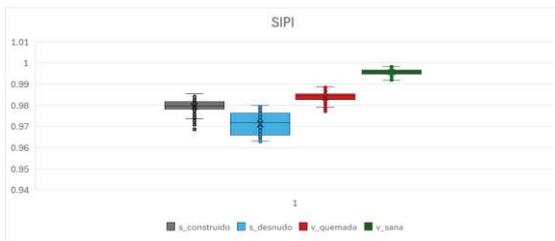
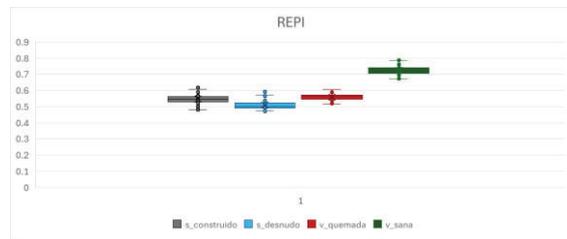
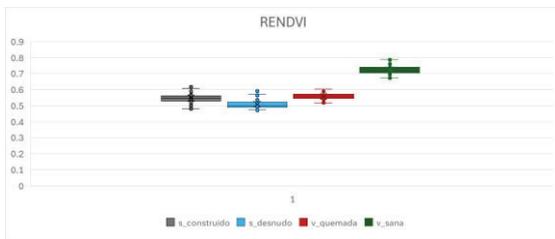
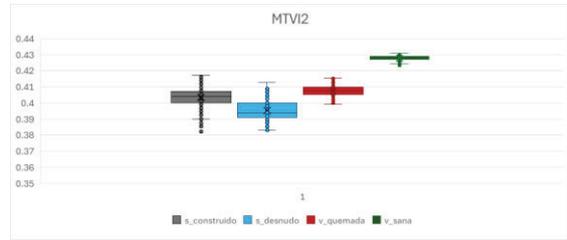
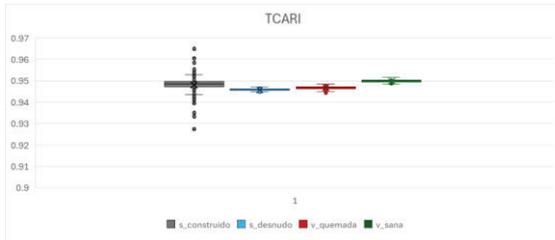
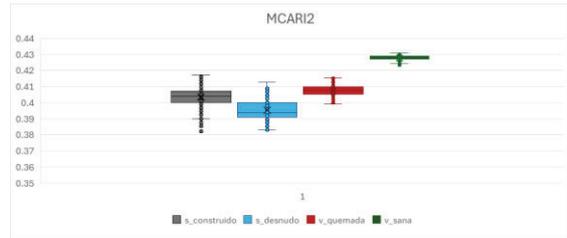
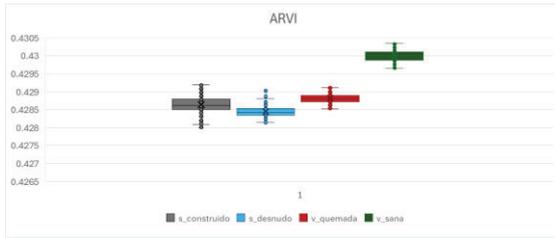
  Export.table.toDrive({
  collection: set_datos,
description: i + '_' + t.name + '_22',
  fileFormat: 'CSV'
  });
});
});
```

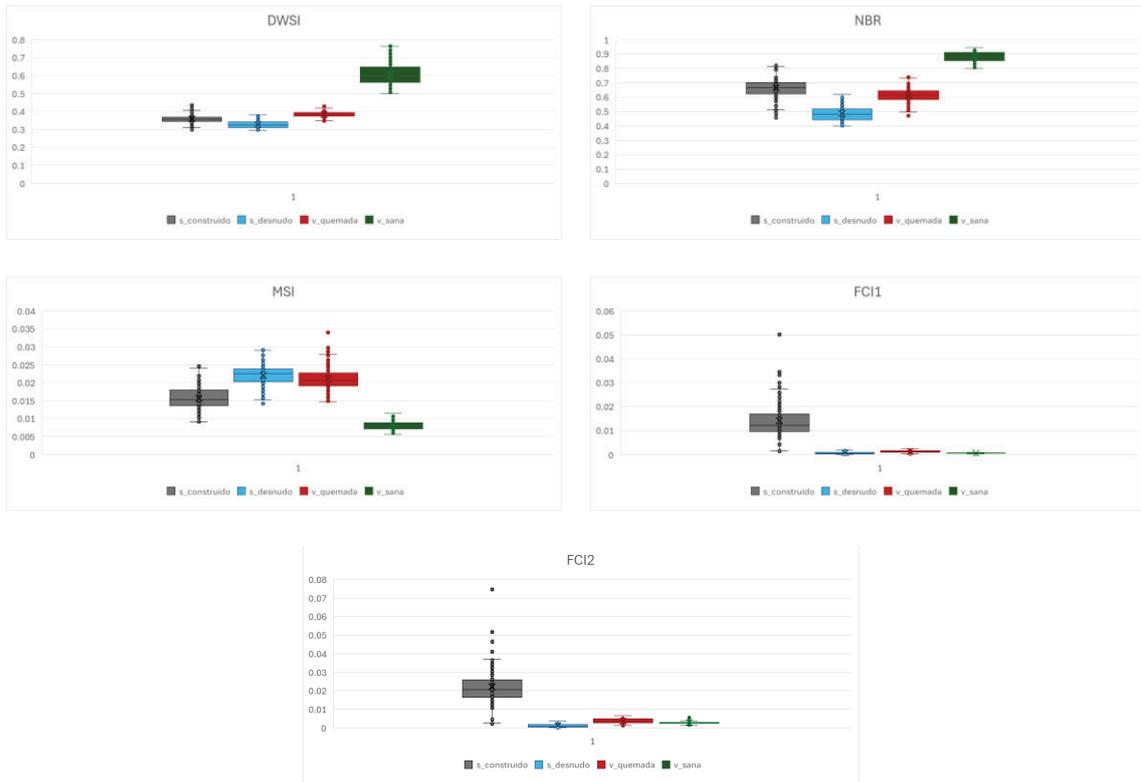
A.4. Anexo 4: Análisis de índices de vegetación

En este anexo están incluidos los diagramas de caja y bigote para cada índice de vegetación. Se han organizado en función de la imagen satelital utilizada, diferenciando entre la del 2022, asociada al área afectada por la erupción volcánica, y la del 2023, asociada al área afectada por el incendio.

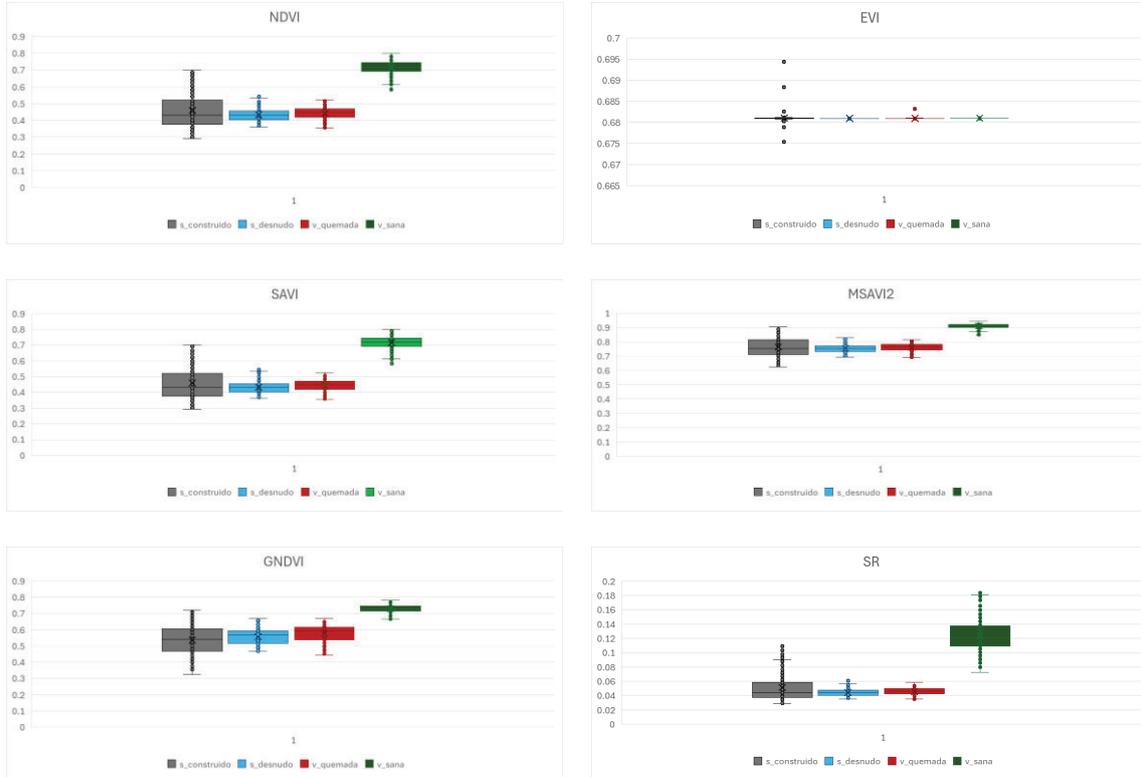
A.4.1. Diagramas correspondientes a la imagen del 2022

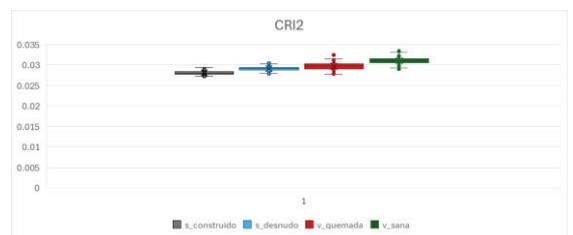
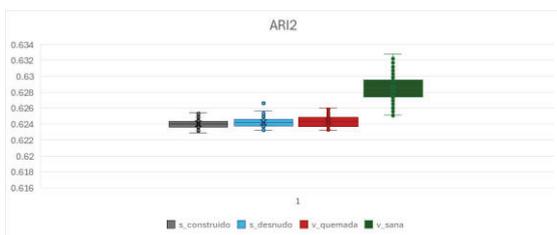
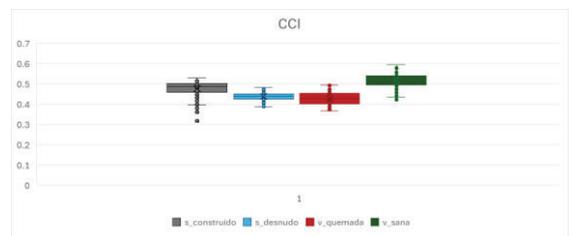
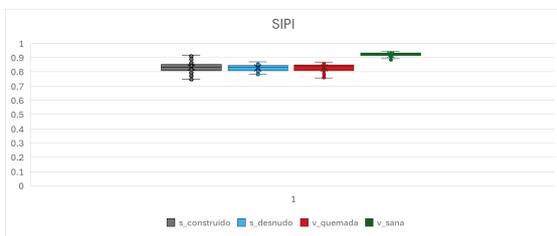
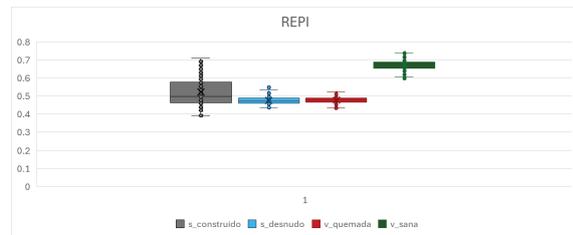
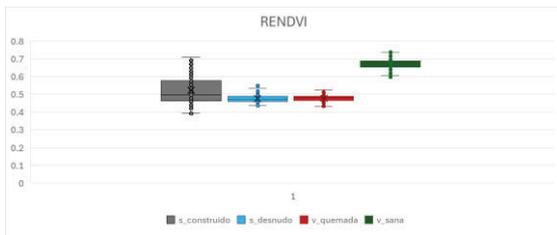
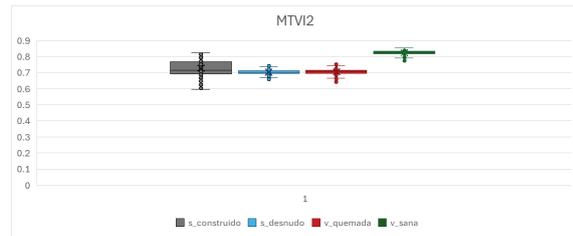
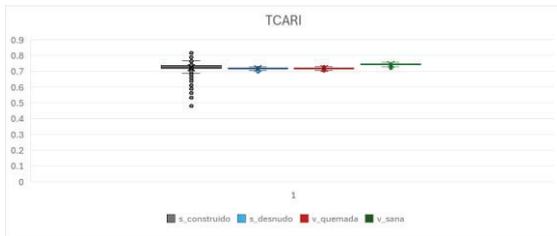
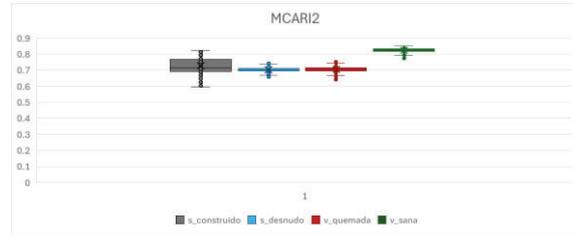
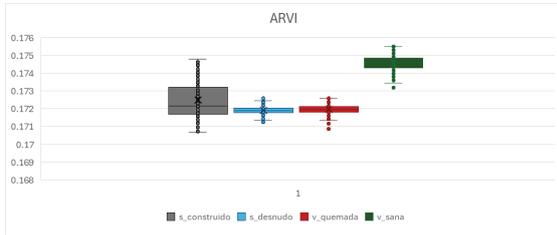
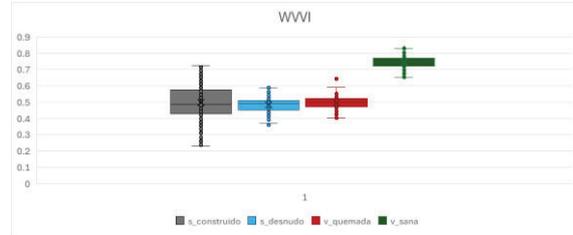
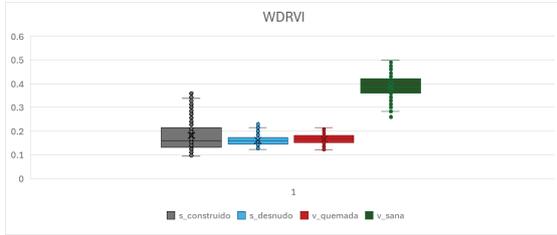
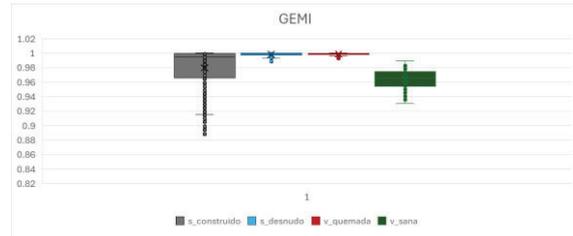
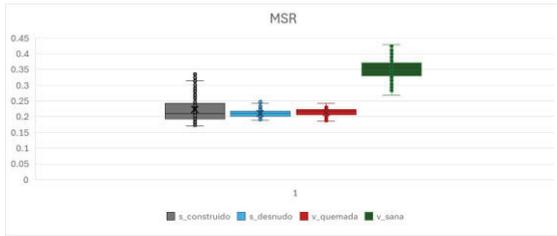


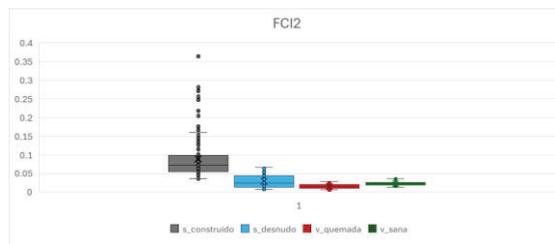
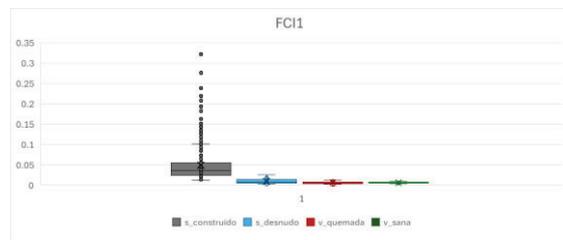
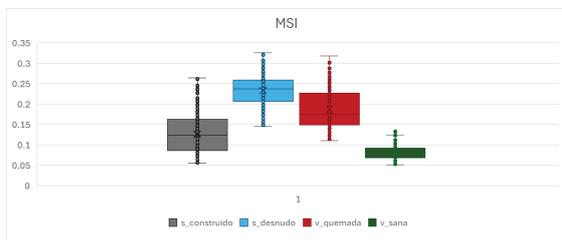
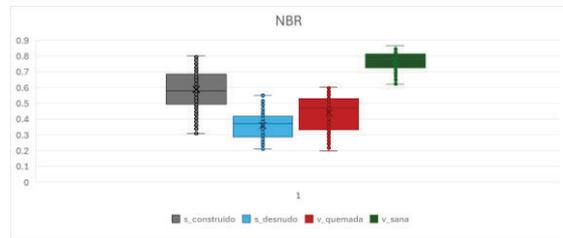
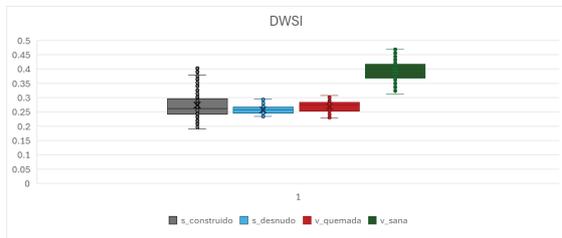
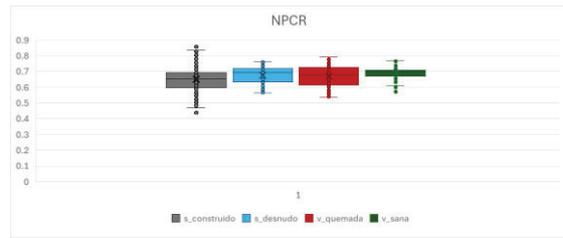
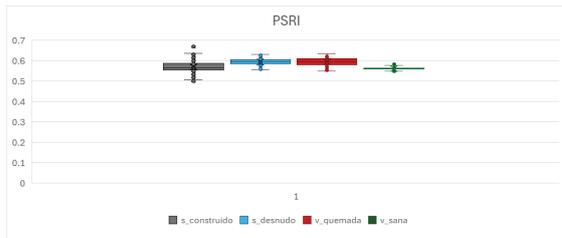




A.4.2. Diagramas correspondientes a la imagen del 2023



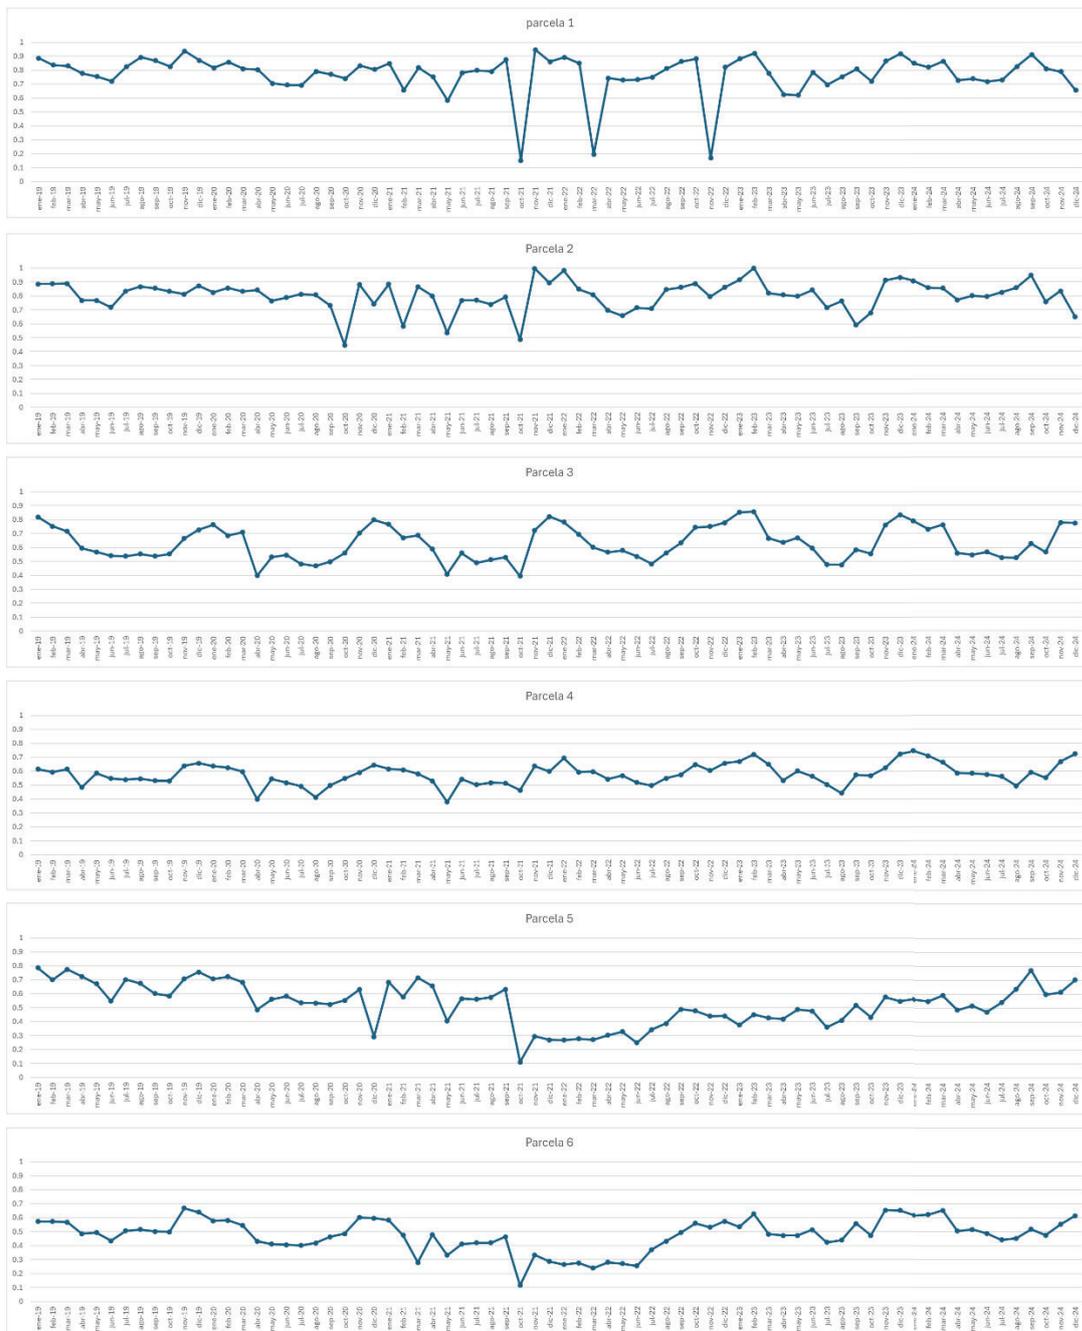


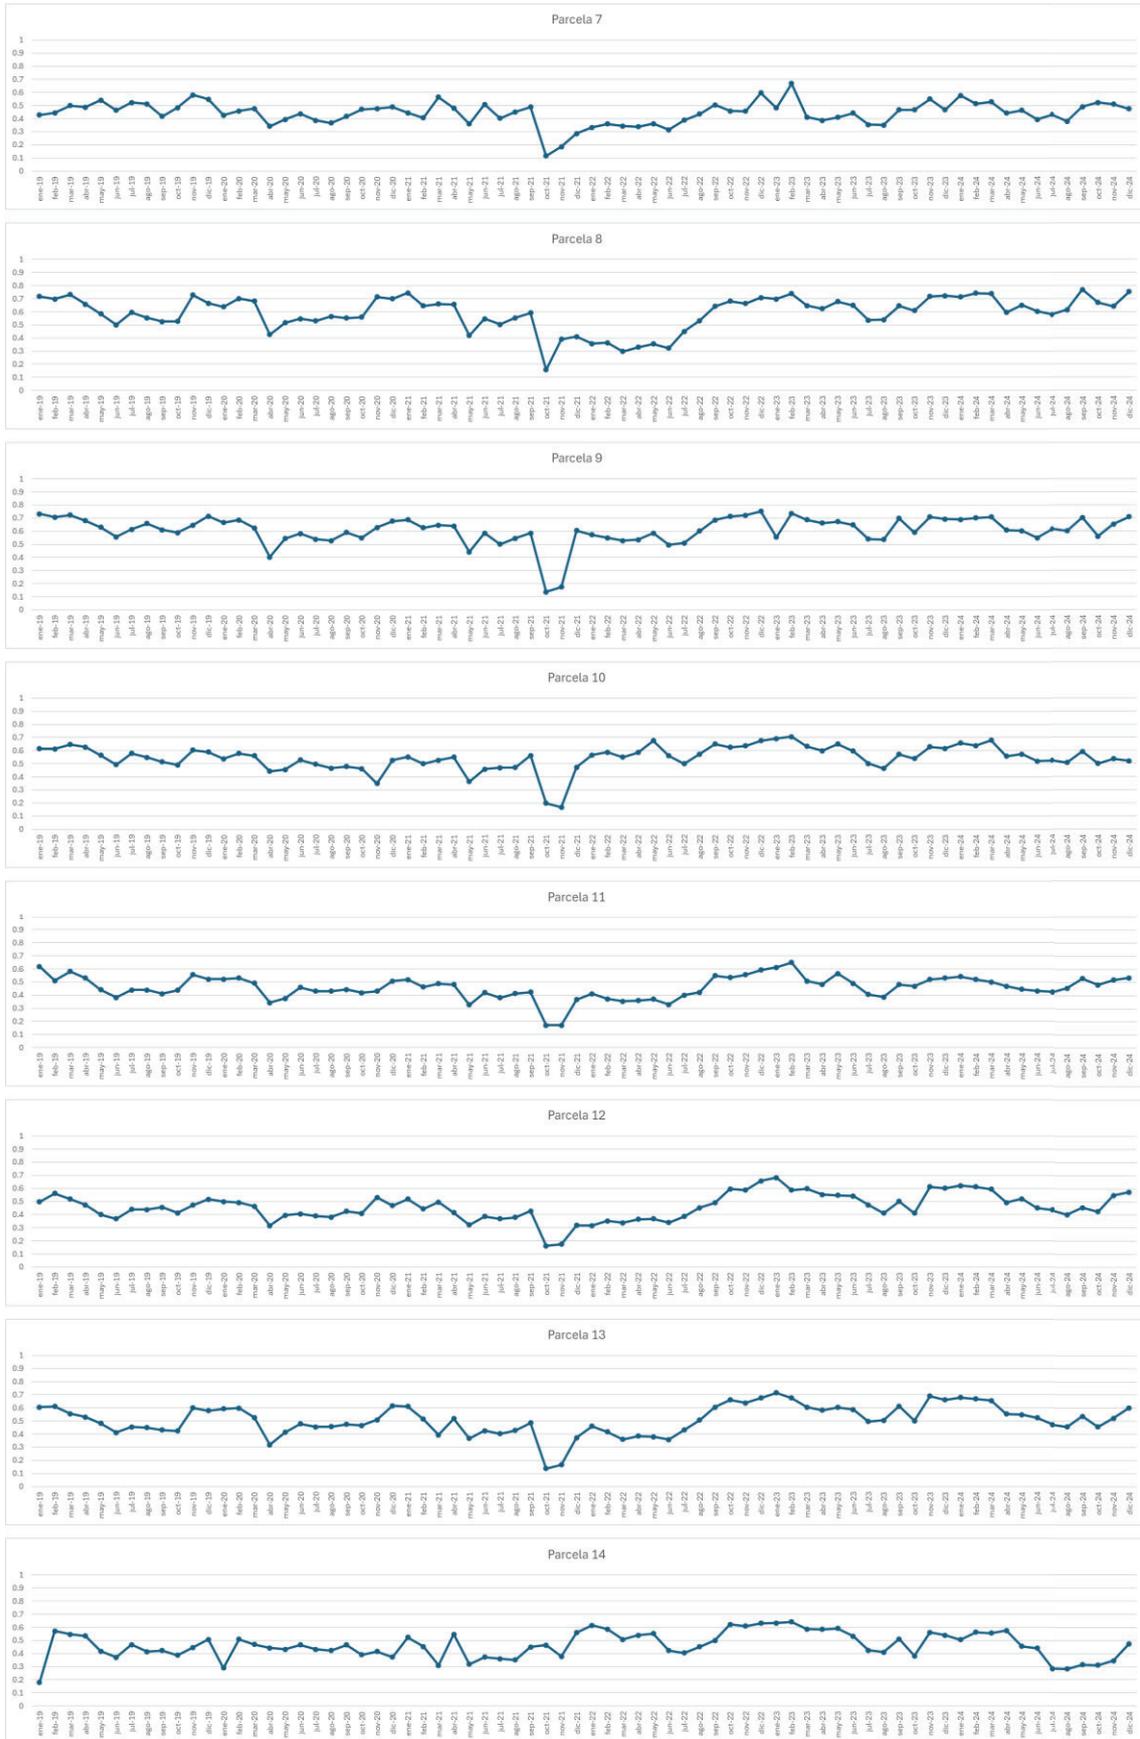


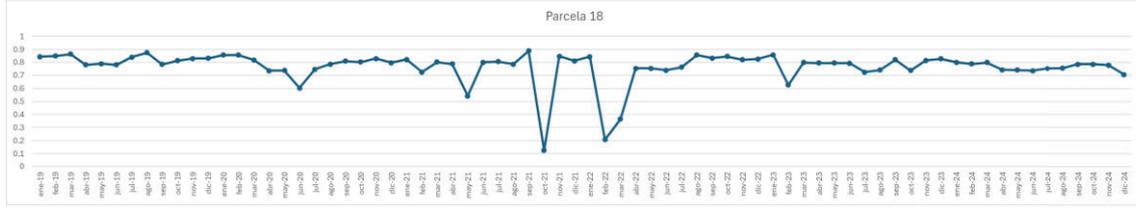
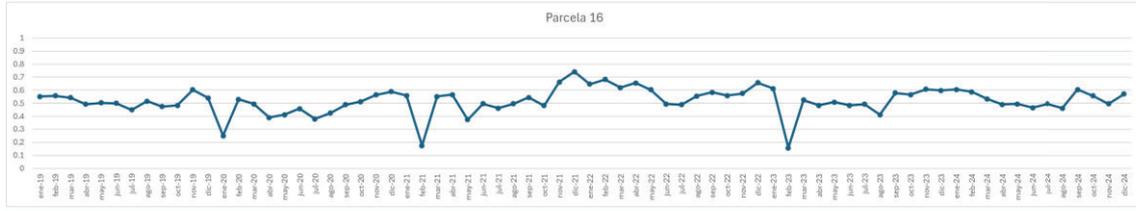
A.5. Anexo 5: Serie temporal de los mejores índices de vegetación

En este anexo se muestra el funcionamiento de los 5 índices elegidos en cada una de las 43 parcelas seleccionadas. Cabe destacar que en las siguientes gráficas no se ha hecho un procesado de la imagen para eliminar outliers.

A.5.1. Wide Dynamic Range Vegetation Index

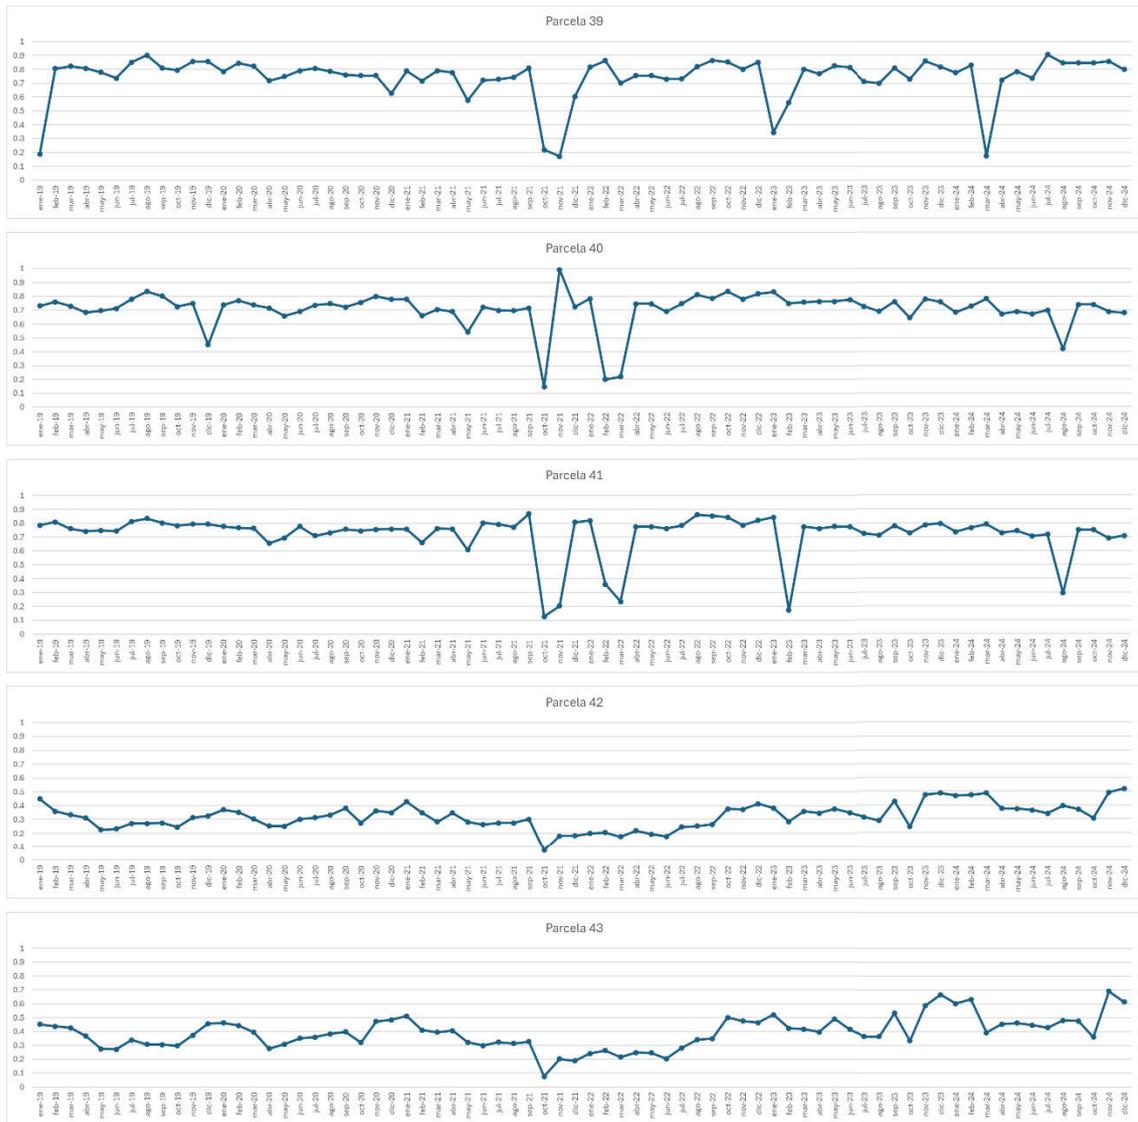




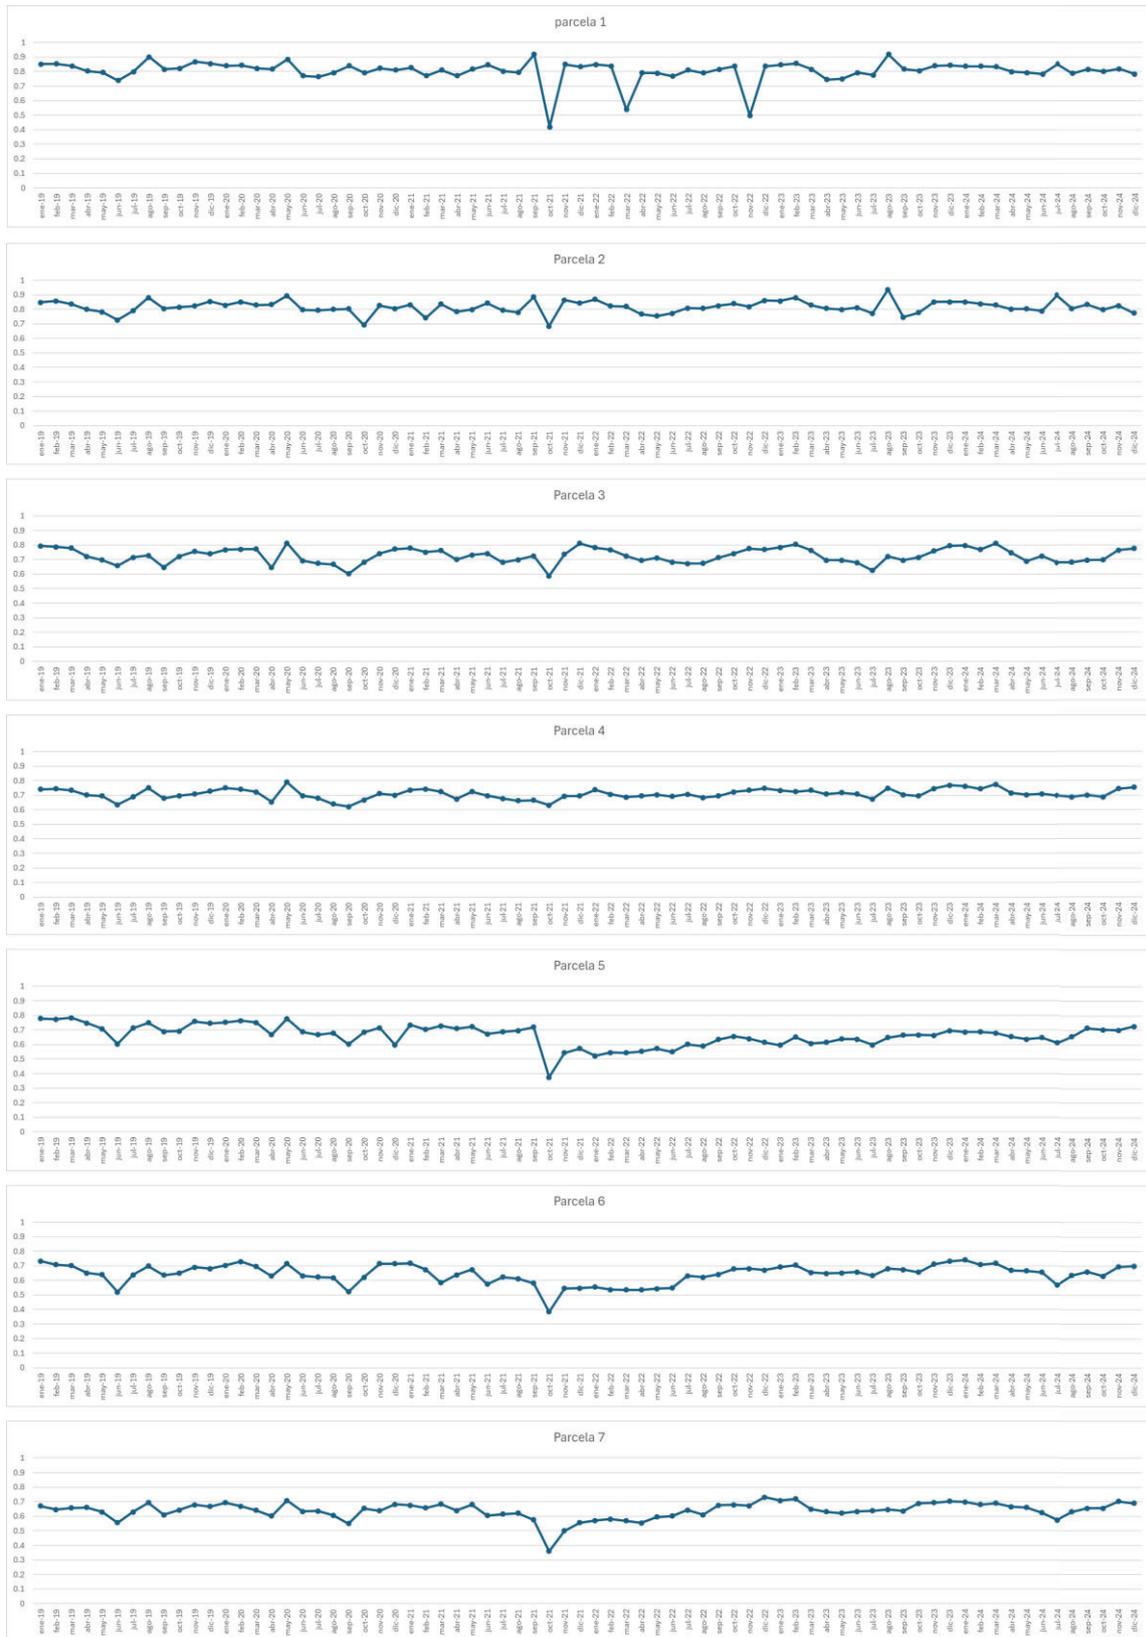


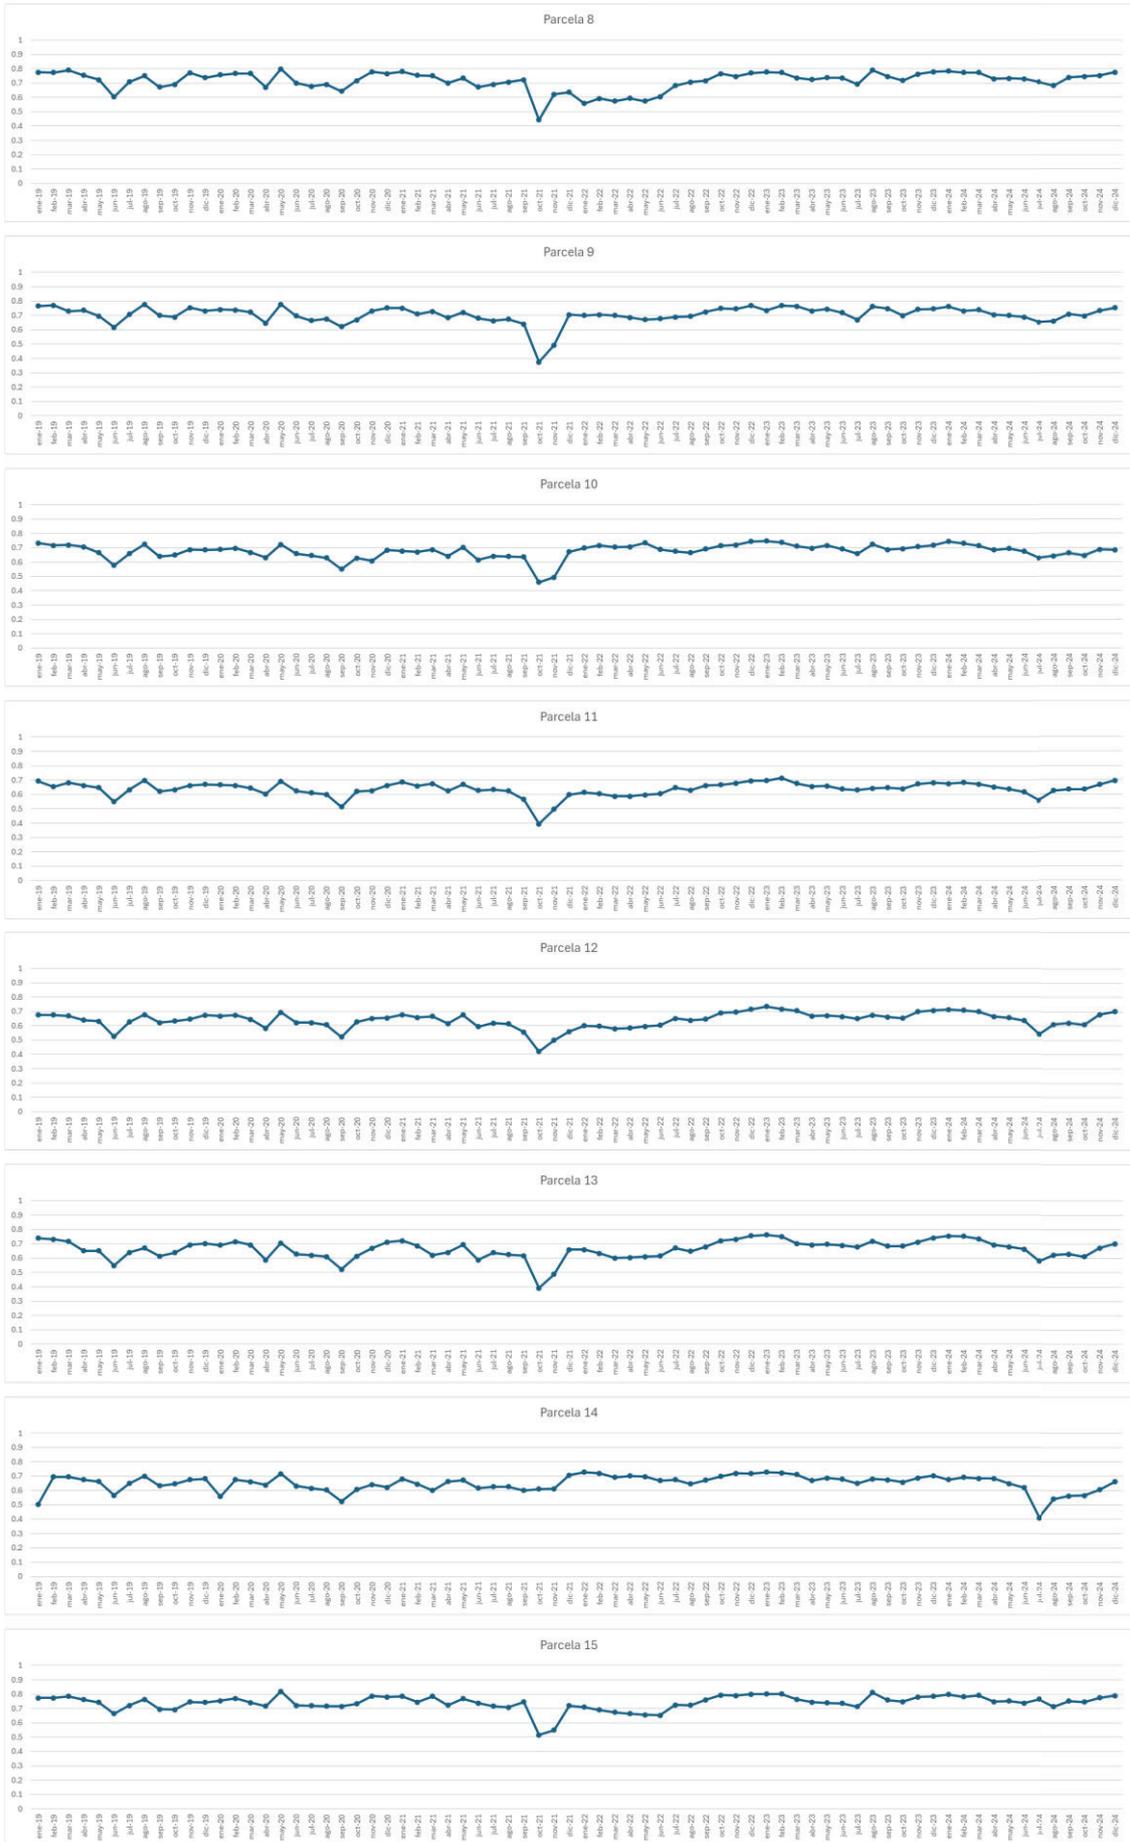


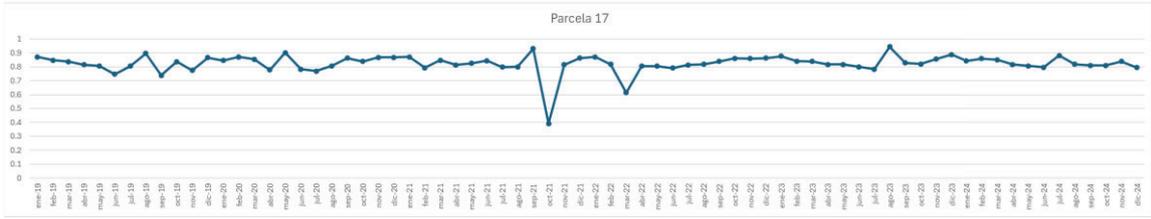


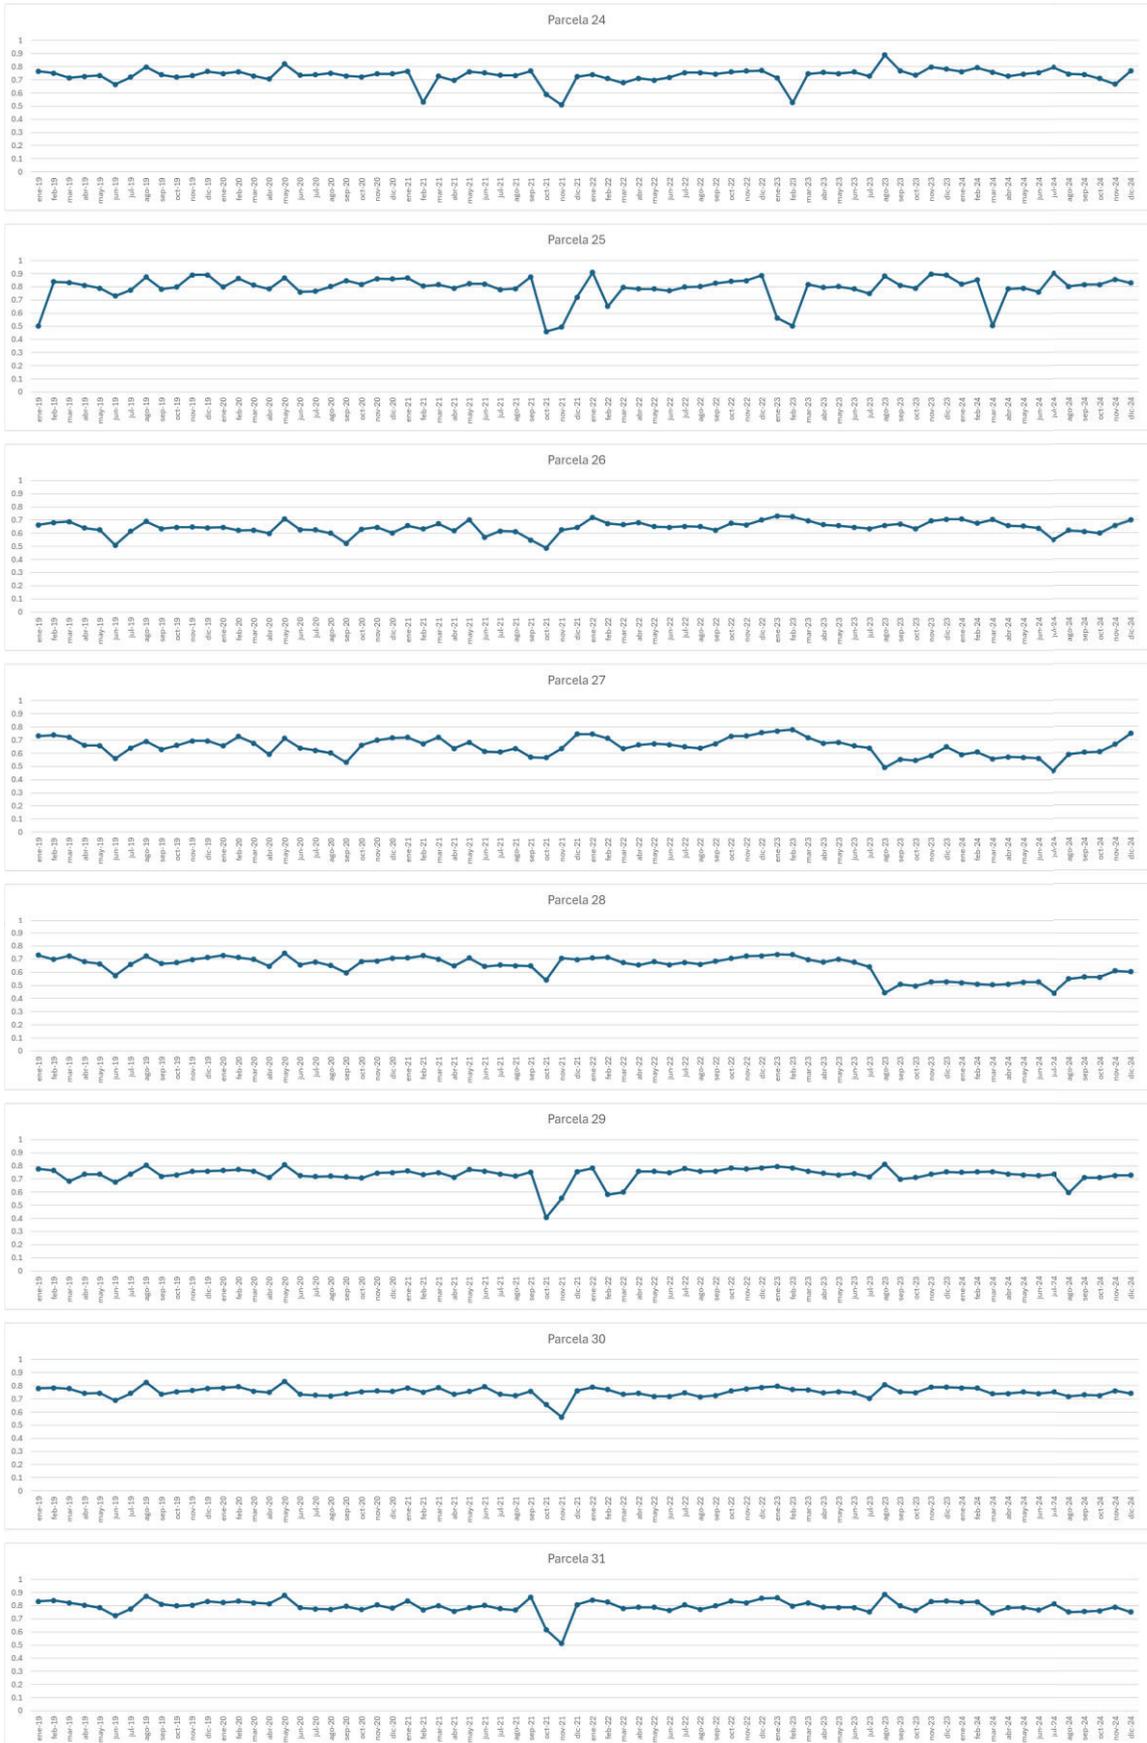


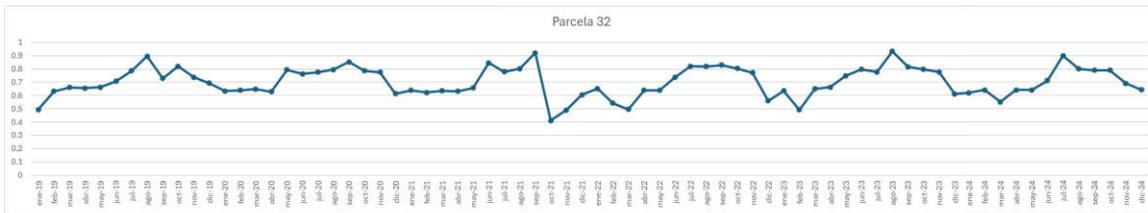
A.5.2. Red Edge Normalized Difference Vegetation Index

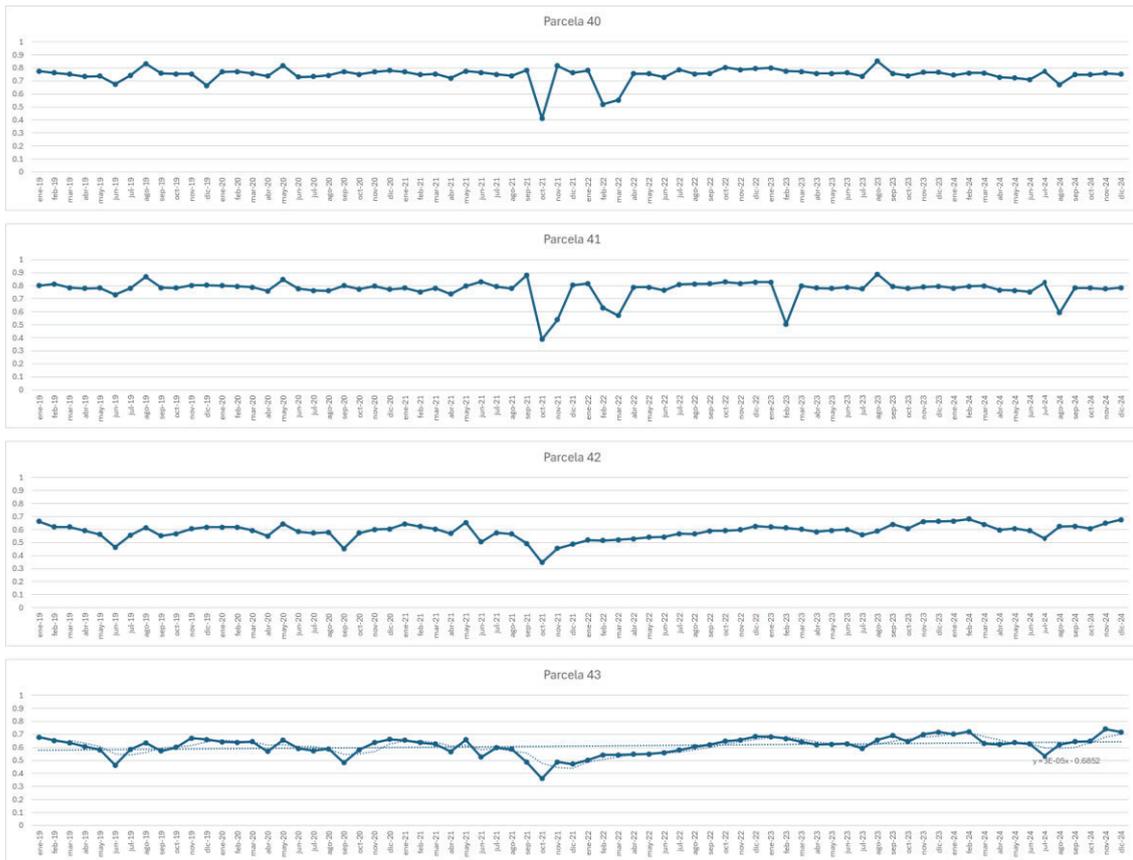




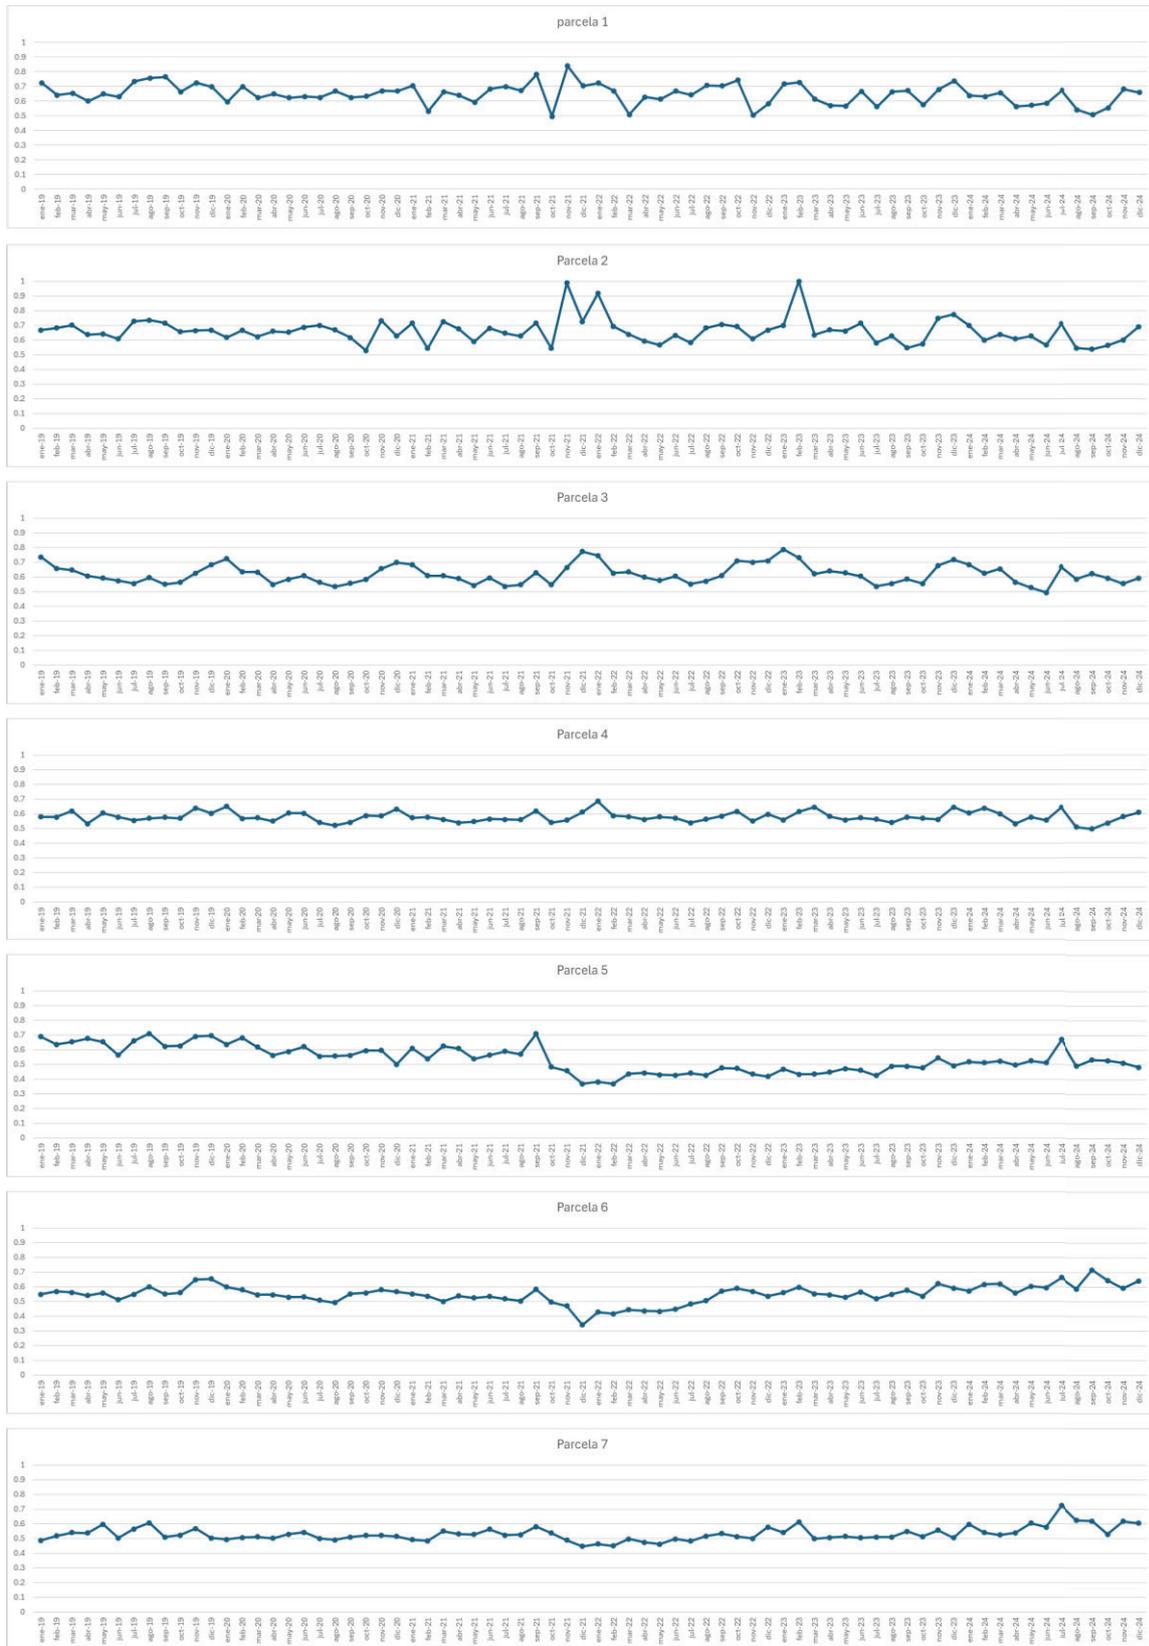


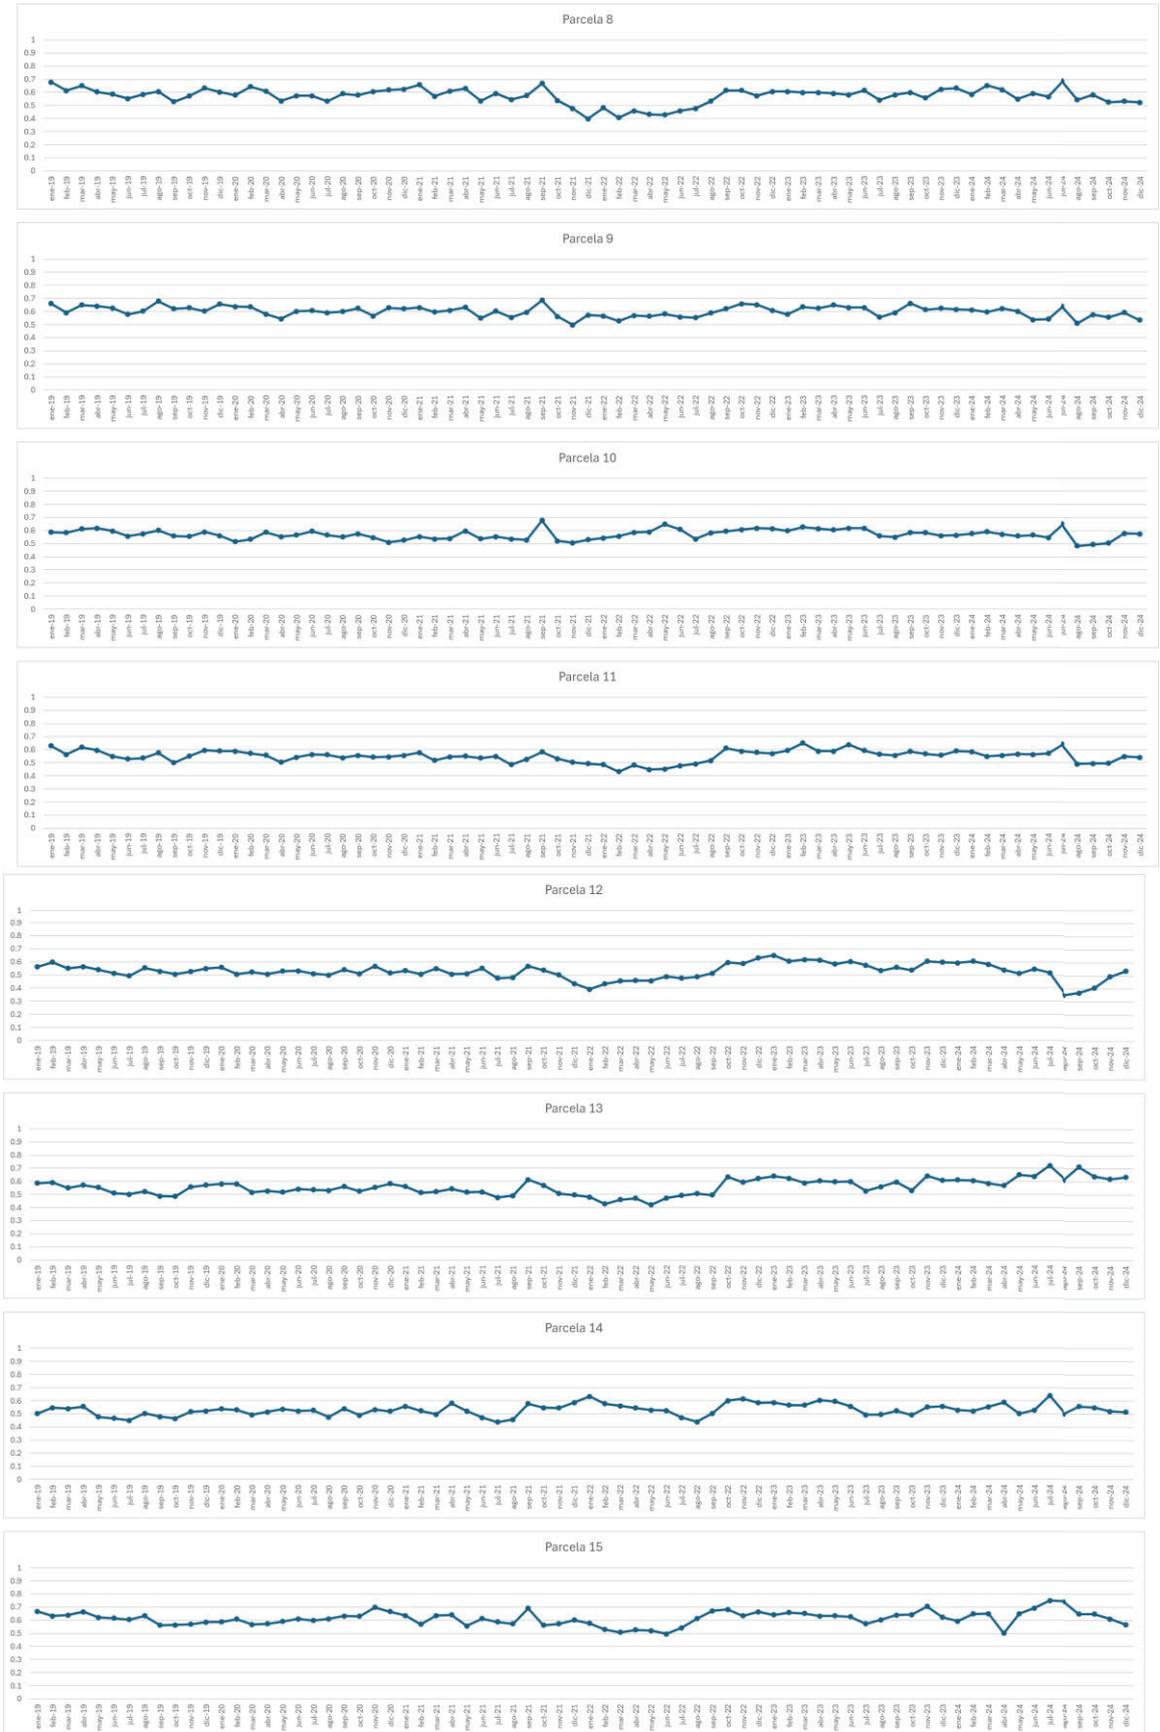


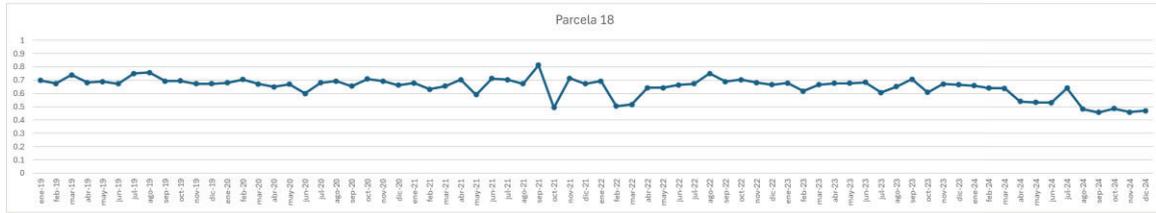


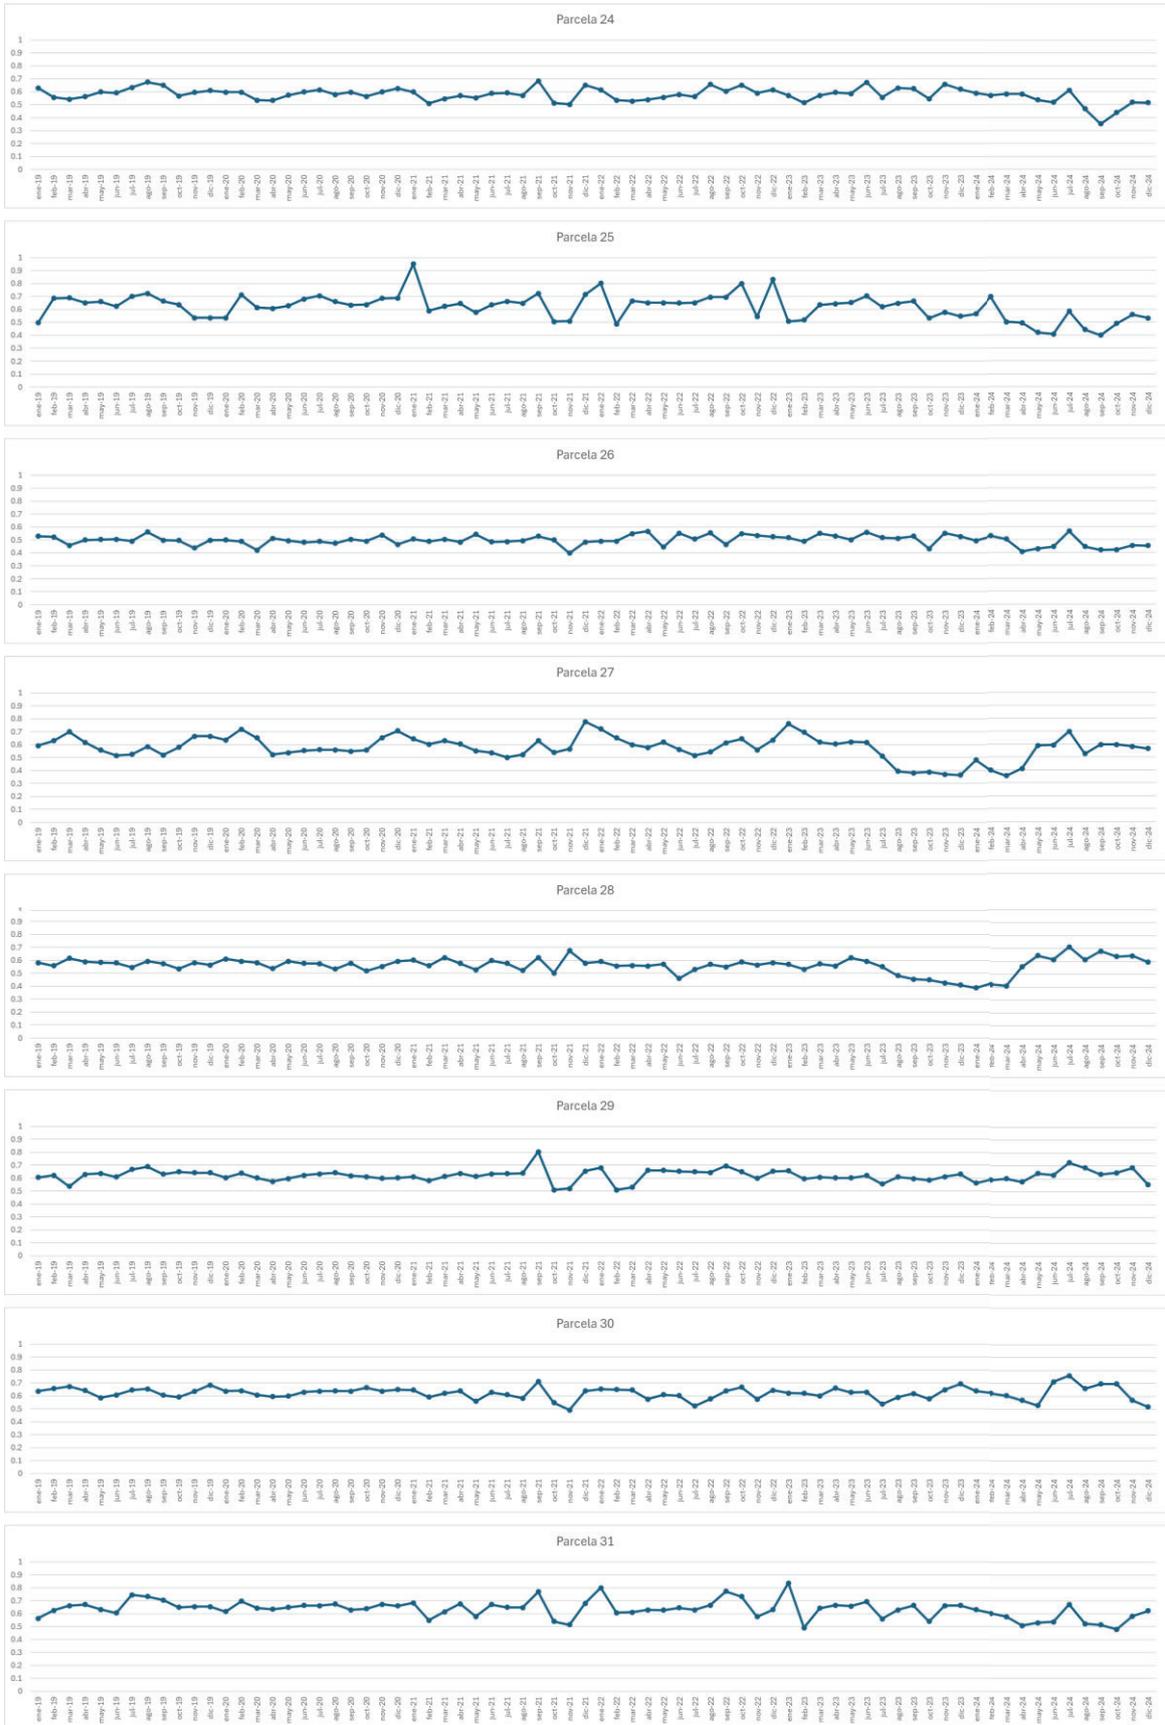


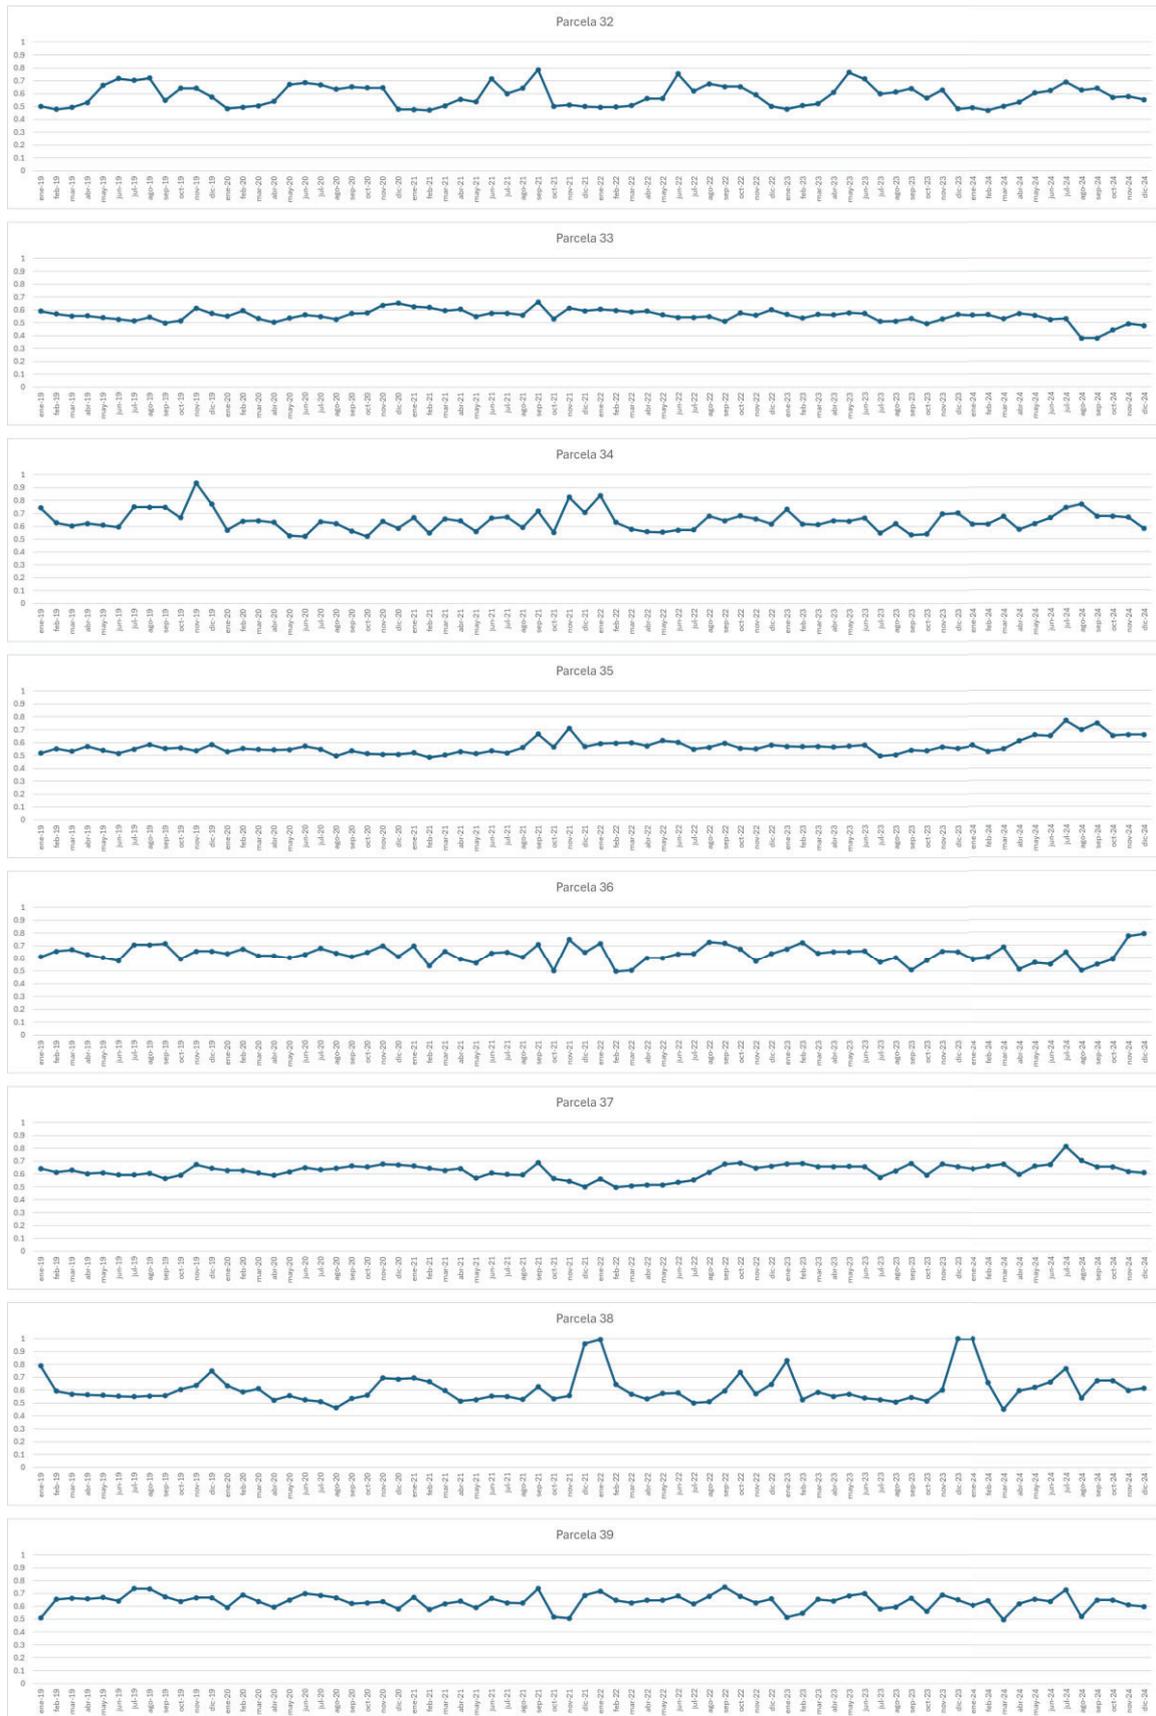
A.5.3. Chlorophyll Carotenoid Index



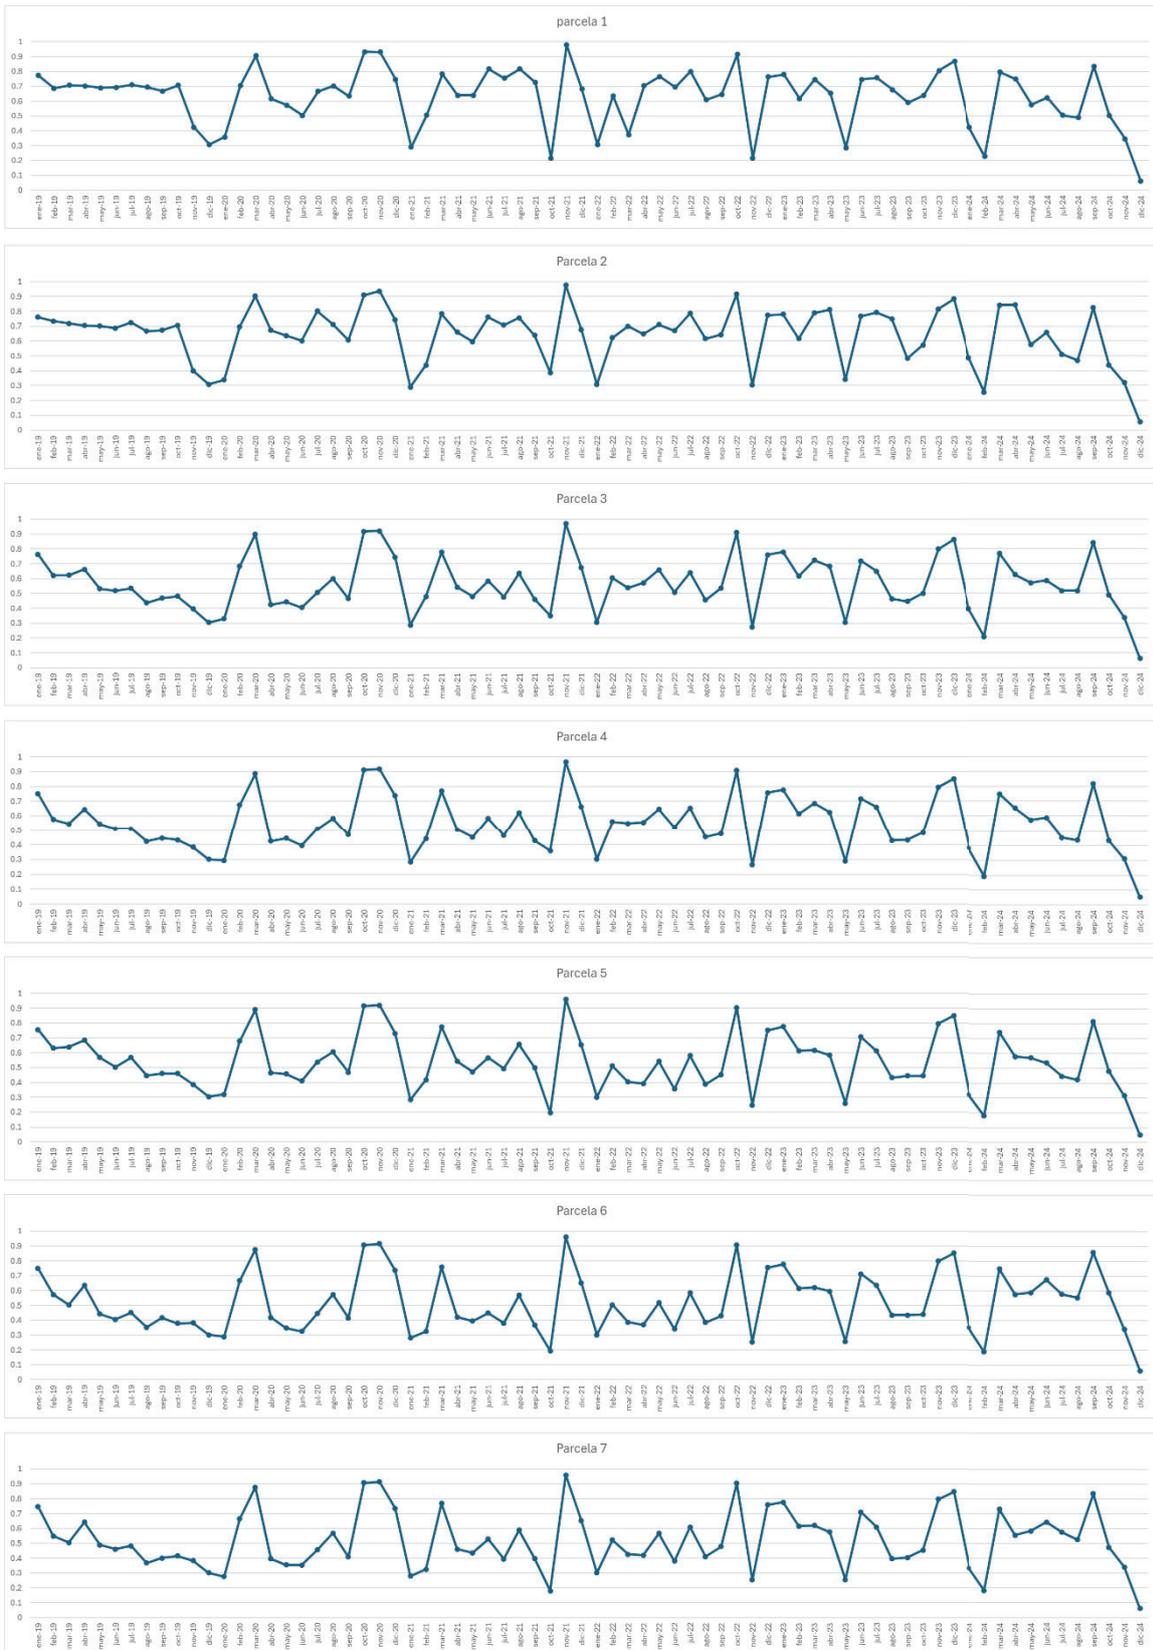


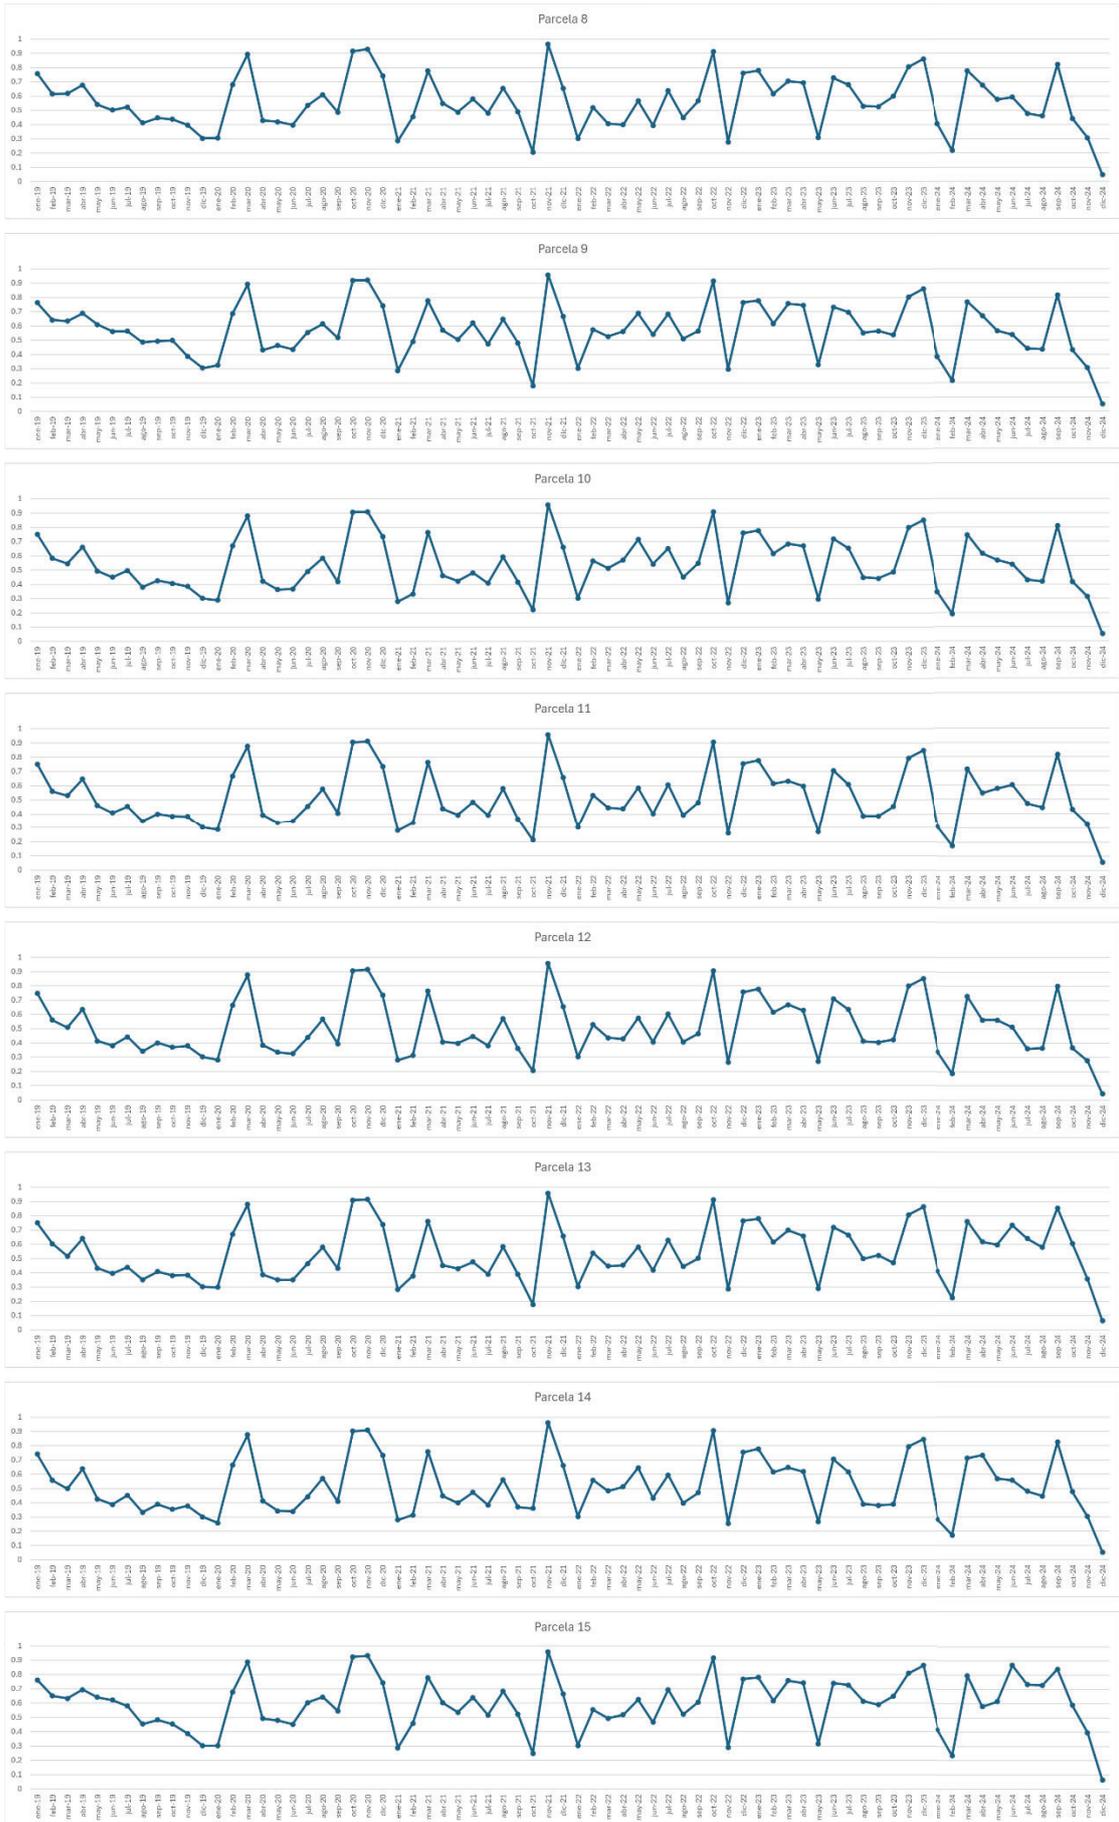


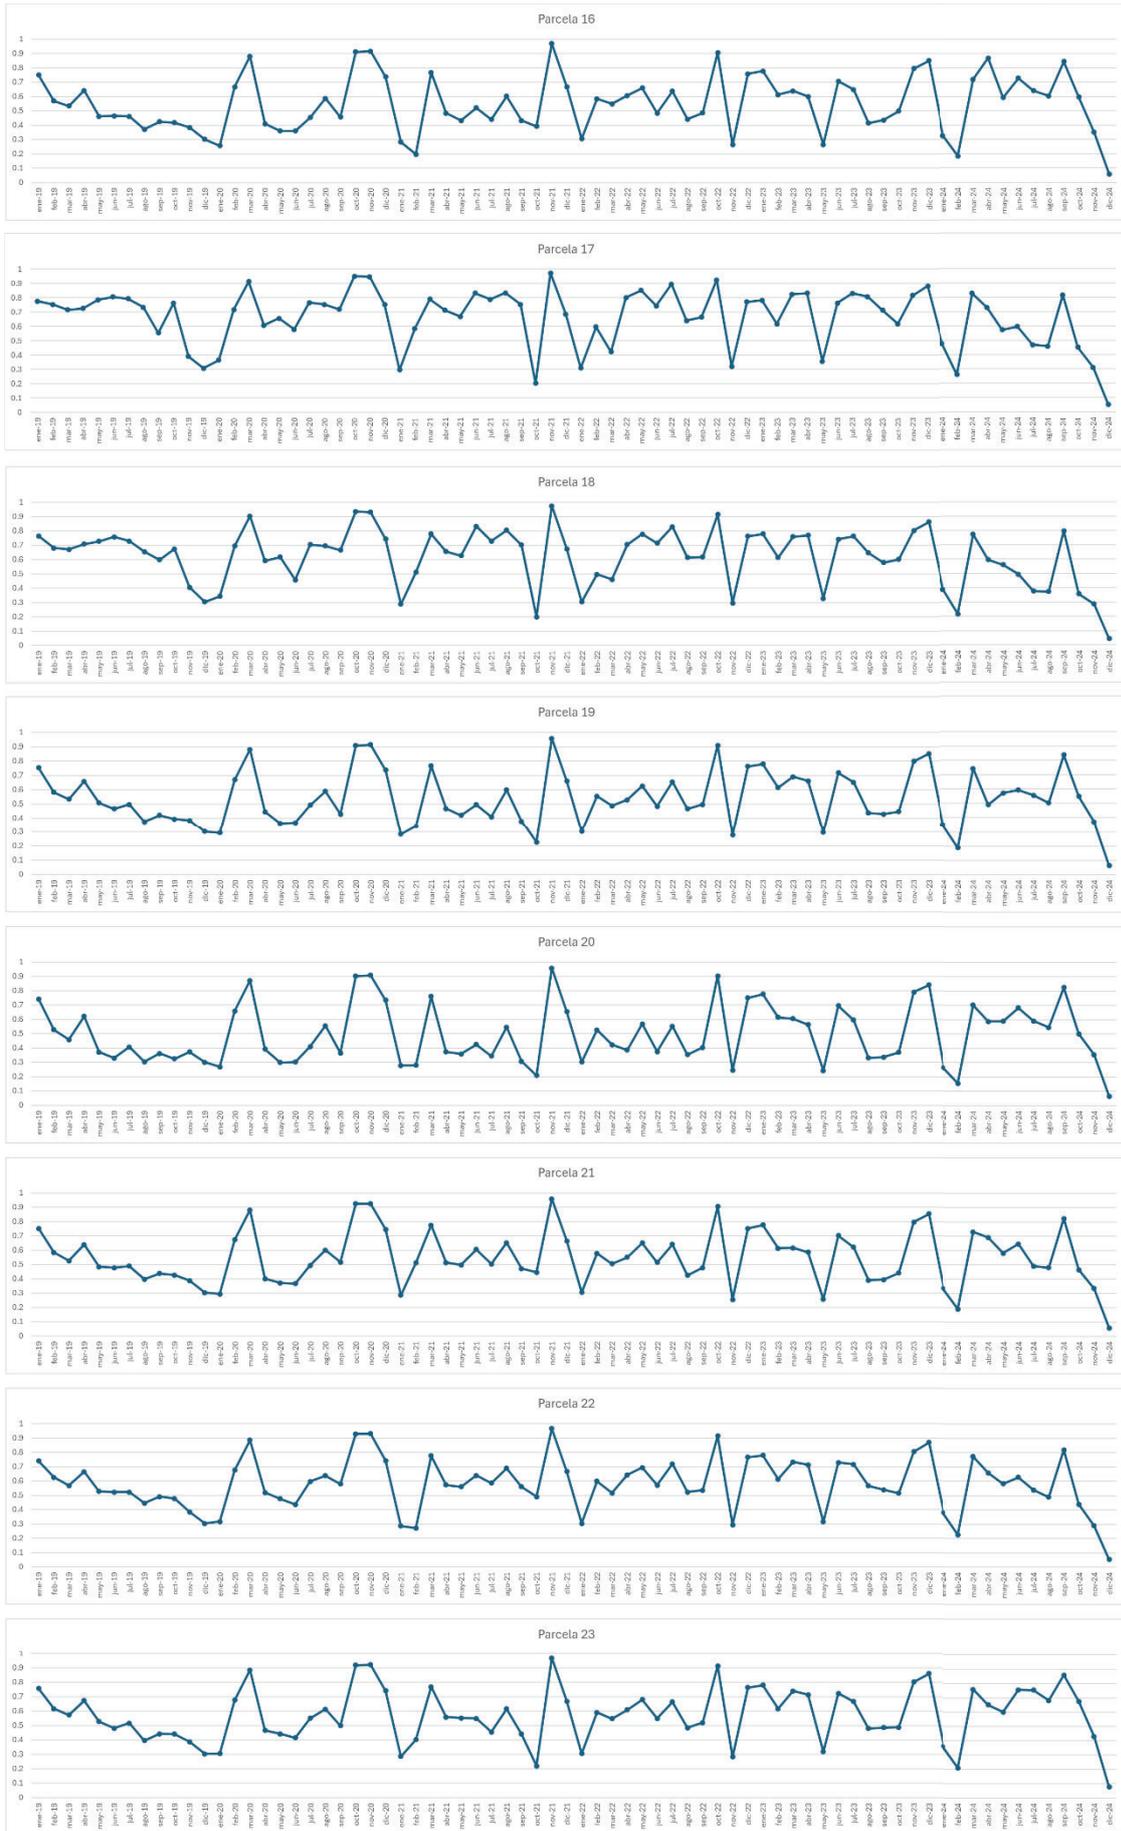




A.5.4. Disease Water Stress Index











A.5.5. Normalized Burn Ratio

