

Teledetección Aplicada con QGIS: Casos Prácticos

Isabel Robalo Cabrera
Francisco Manzano Agugliaro

Teledetección Aplicada con QGIS: Casos Prácticos

texto:

Isabel Robalo Cabrera
Francisco Manzano Agugliaro

Textos Docentes n.º 215

edición:

Editorial Universidad de Almería, 2025

editorial@ual.es

www.ual.es/editorial

Telf/Fax: 950 015459

α

ISBN: 978-84-1351-412-3



Esta obra se edita bajo una licencia Creative Commons
[CC BY-NC-ND Atribución-NoComercial-SinObraDerivada 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)



En este libro puede volver al índice
pulsando el pie de la página

Índice

1.	Introducción	5
2.	Imágenes satélite	7
2.1.	Imágenes Landsat.....	7
2.2.	Imágenes Sentinel	9
2.3.	Bandas espectrales de los programas Landsat y Sentinel-2	10
3.	Conceptos fundamentales	14
3.1.	Firmas espectrales	14
3.2.	Índices espectrales.....	17
4.	Recursos web	22
4.1.	EarthExplorer.....	22
4.1.1.	Guía básica de EarthExplorer.....	22
4.2.	Copernicus Browser	27
4.2.1.	Guía básica de Copernicus Browser.....	27
5.	Herramientas software	30
5.1.	Guía básica de instalación de QGIS y sus complementos	31
6.	Ejercicios propuestos	33
6.1.	Guion 1	33
6.2.	Guion 2	35
6.3.	Guion 3	38
6.4.	Guion 4	39
6.5.	Guion 5	42
7.	Solucionario	44
7.1.	Guion 1	44
7.2.	Guion 2	48
7.3.	Guion 3	53
7.4.	Guion 4	58
7.5.	Guion 5	64
8.	Bibliografía	68

Acrónimo	Definición
dNBR	Índice de Diferencia Normalizado de Área Quemada (delta NBR)
ESA	Agencia Espacial Europea
ETM+	Sensor Thematic Mapper Mejorado
L	Factor de corrección del índice SAVI
LiDAR	Detección y Medición por Luz Láser (Light Detection and Ranging o Laser Imaging Detection and Ranging)
NBR	Índice de Área Quemada Normalizado
NDVI	Índice de Vegetación de Diferencia Normalizada
NIR	Infrarrojo Cercano (Near Infrared)
OLI	Sensor de Imágenes Ópticas Operacional (Operational Land Imager)
RBV	Cámara de Retorno de Haz de Luz (Return Beam Vidicon)
SAR	Radar de Apertura Sintética
SAVI	Índice de Vegetación Ajustado al Suelo (Soil Adjusted Vegetation Index)
SCP	Complemento de Clasificación Semiautomática (Semi-Automatic Classification Plugin)
SWIR	Infrarrojo de Onda Corta (Shortwave Infrared)
TIRS	Sensor Térmico de Infrarrojo (Thermal Infrared Sensor)
TM	Sensor Thematic Mapper
USGS	Servicio Geológico de los Estados Unidos

1. Introducción

La Teledetección es una disciplina que permite obtener información sobre la superficie terrestre sin necesidad de contacto físico directo, mediante el análisis de la radiación electromagnética reflejada o emitida por los objetos. Esta información es captada por sensores ubicados en plataformas como satélites, aeronaves, drones o estaciones terrestres.

Desde una perspectiva amplia, la Teledetección incluye un conjunto de técnicas destinadas a observar y cuantificar características del suelo, la vegetación, el agua, y otros elementos del entorno natural o construido. Los sensores pueden ser pasivos (figura 1), cuando dependen de fuentes naturales como la radiación solar, o activos, cuando generan su propia energía, como ocurre con los sistemas radar o LiDAR (Light Detection and Ranging o Laser Imaging Detection and Ranging).




Figura 1. Sensor pasivo y sensor activo (Adaptado de:

<https://www.yellowscan.com/es/knowledge/how-does-lidar-work/>)

Los datos obtenidos se procesan para generar imágenes o mapas temáticos, útiles en múltiples escalas espaciales y temporales. En el ámbito agrícola, por ejemplo, la Teledetección se ha consolidado como una herramienta clave para la gestión eficiente de cultivos, la evaluación del estado nutricional de las plantas, el monitoreo del riego, la detección temprana de plagas y enfermedades, y la estimación de rendimientos (figura 2).



Figura 2. Dron DJI PH4 Multiespectral (<https://ag.dji.com/es/p4-multispectral>)

La Teledetección no debe confundirse con la fotogrametría, disciplina centrada en la obtención de información geométrica precisa a partir de imágenes. La

fotogrametría se enfoca en la medición y reconstrucción tridimensional de objetos, mientras que la Teledetección se orienta al análisis espectral y a la caracterización de patrones sobre la superficie terrestre.

Un sistema de Teledetección permite captar información en distintas longitudes de onda del espectro electromagnético (figura 3), lo cual es fundamental para identificar y clasificar los distintos tipos de cobertura terrestre.




Figura 3. Espectro electromagnético

(<https://www.comunidad.madrid/servicios/salud/campos-electromagneticos>)

Para captar dicha información, el sistema de Teledetección incluye diversos componentes: una fuente de energía (natural o artificial), una plataforma portadora (satélites o drones), sensores especializados (multiespectrales e hiperspectrales, figura 4), y un sistema de recepción y procesamiento de datos.




Figura 4. Cobertura de bandas de imágenes monocromo, RGB, multiespectrales e hiperspectrales

(<https://bcnvision.es/blog-vision-artificial/camaras-hiperspectrales/>)

Por último, los productos visuales se obtienen como resultado tras el procesamiento de los datos recogidos por los sistemas de Teledetección, incluyendo correcciones radiométricas y atmosféricas, así como técnicas de clasificación e interpretación.

2. Imágenes satélite

En el contexto de la agricultura moderna y de precisión, las imágenes satelitales se han convertido en herramientas fundamentales para la observación, análisis y gestión de los cultivos y recursos naturales. Estas imágenes permiten monitorear grandes extensiones de terreno con gran frecuencia y nivel de detalle. Los satélites de observación terrestre capturan datos multiespectrales en distintas resoluciones espaciales, temporales y espectrales, facilitando el análisis de variables como la cobertura vegetal, el estrés hídrico, el uso del suelo y el desarrollo de los cultivos.

Entre las plataformas más relevantes y utilizadas en agricultura destacan los programas Landsat y Sentinel, cuyos datos son gratuitos, de acceso abierto y ampliamente validados por la comunidad científica.

2.1. Imágenes Landsat

El programa Landsat, desarrollado por la NASA y operado junto con el Servicio Geológico de los Estados Unidos (USGS), es el proyecto de observación terrestre más longevo del mundo (figura 5). Desde 1972, sus satélites han proporcionado un archivo histórico para el estudio del cambio en la superficie terrestre, incluyendo el uso agrícola, la deforestación, la disponibilidad de agua y la salud del suelo y la vegetación.




Figura 5. Evolución histórica de programa Landsat, desde 1972 a la actualidad
(<https://landsat.gsfc.nasa.gov/satellites/timeline/>)

El lanzamiento del Landsat 1 en 1972 marcó un hito en la observación de la Tierra al introducir el uso de sensores multiespectrales. Este satélite fue pionero en la captura de imágenes con fines agrícolas, forestales y de gestión ambiental, ofreciendo una resolución espacial de 80 metros. A este primer esfuerzo le siguieron los satélites Landsat 2 y Landsat 3, lanzados entre 1975 y 1978. Ambos mantuvieron los sensores multiespectrales de imagen y RBV (Return Beam Vidicon) de video.

El verdadero salto tecnológico llegó con Landsat 4 (1982) y Landsat 5 (1984), que incorporaron el sensor Thematic Mapper (TM). Este sensor introdujo nuevas bandas espectrales, incluidas en el infrarrojo térmico, y mejoró significativamente la resolución espacial a 30 metros. De todos, Landsat 5 destacó especialmente por su longevidad, ya que operó durante casi tres décadas, convirtiéndose en uno de los satélites más duraderos jamás lanzados.

Más tarde, en 1993, el intento de lanzar el Landsat 6 resultó fallido. Sin embargo, el programa se retomó con éxito en 1999 con el lanzamiento del Landsat 7, que incorporó el sensor Enhanced Thematic Mapper (ETM+), que añadió una banda pancromática con resolución de 15 metros y mejoró notablemente la calidad geométrica de las imágenes del sensor ETM.

La octava misión del programa, Landsat 8 (figura 6.a), fue lanzada en 2013 y supuso una mejora significativa al incorporar dos sensores modernos: el Operational Land Imager (OLI) y el Thermal Infrared Sensor (TIRS). Estos sensores introdujeron nuevas bandas espectrales diseñadas para el análisis de aerosoles atmosféricos, la calidad del agua y la temperatura de la superficie terrestre, ampliando considerablemente el potencial analítico del sistema.

Finalmente, en 2021 fue lanzado el Landsat 9 (figura 6.b), equipado con los sensores OLI-2 y TIRS-2, este satélite mejora la precisión de calibración y la capacidad de captura de datos, asegurando la continuidad del legado Landsat en estudios de largo plazo relacionados con el cambio climático, el uso del suelo y la gestión ambiental global.

Los satélites Landsat actuales capturan imágenes multiespectrales y térmicas con una resolución espacial media (30 m), lo que los hace ideales para estudios regionales. Gracias a su frecuencia de revisita de 16 días y su cobertura global, ofrecen información actualizada y comparativa para detectar cambios a lo largo del tiempo.

La próxima generación del programa Landsat, Landsat Next, busca mejorar aún más la resolución espacial, espectral y temporal. Esta evolución ampliará las posibilidades de análisis agrícola, integrando más bandas y mayor frecuencia de observación, elementos clave para una agricultura basada en datos.




Figura 6. Satélites Landsat 8 (a) y Landsat 9 (b)
(<https://landsat.gsfc.nasa.gov/satellites/>)

2.2. Imágenes Sentinel

El programa Copernicus es el Programa de Observación de la Tierra de la Unión Europea desarrollado por la Agencia Espacial Europea (ESA). Está conformado por una serie de misiones satelitales diseñadas para proporcionar datos continuos y de alta calidad sobre distintos aspectos del medio ambiente terrestre, oceánico y atmosférico. Cada familia Sentinel (figura 7) cumple funciones específicas mediante diferentes tipos de sensores. Sentinel-1, con radar de apertura sintética (SAR), permite observar la superficie terrestre independientemente de las condiciones meteorológicas o de luz. Sentinel-3, equipado con sensores ópticos y de altimetría, se orienta al estudio de los océanos y el cambio climático global. Por otro lado, Sentinel-5P, junto con los futuros Sentinel-4 y Sentinel-5, están dedicados a la vigilancia de la composición atmosférica.




Figura 7. Satélites del programa Copernicus

(https://www.esa.int/Applications/Observing_the_Earth/Copernicus/The_Sentinel_missions)

Entre las familias Sentinel, destacan los satélites Sentinel-2, debido a que sus sensores ópticos multiespectrales de alta resolución están especialmente diseñados para el monitoreo detallado de la cobertura terrestre, la vegetación y el uso del suelo, siendo particularmente relevantes para aplicaciones en agricultura, medio ambiente y planificación territorial.

Una de las principales ventajas de los satélites Sentinel-2 es la combinación de alta resolución espacial, frecuencia de observación corta (5 días) y una amplia variedad espectral. Concretamente, su sensor multiespectral cubre 13 bandas, incluyendo bandas para clorofila, contenido de agua y aerosoles, con una franja de cobertura

de 290 km. Esto lo que lo convierte en una herramienta fundamental para la agricultura de precisión, el análisis ambiental y la gestión de recursos naturales.

El primer satélite, Sentinel-2A, fue lanzado en 2015 y comenzó a registrar imágenes multiespectrales de 10 m, 20 m y 60 m de resolución, cubriendo toda la superficie terrestre junto al mar cada diez días. Dos años después, en 2017, despegó el segundo satélite idéntico, Sentinel-2B, que junto con Sentinel-2A redujo el intervalo de revisita a cinco días, permitiendo capturar cambios rápidos en los cultivos con mayor frecuencia.

El impulso más reciente llegó con el lanzamiento de Sentinel-2C en 2024, que sustituye gradualmente a Sentinel-2A tras un periodo de observaciones paralelas, reforzando la constelación y mejorando la disponibilidad de imágenes con menos cobertura nubosa, ver figura 8.

Próximamente, Sentinel-2D reemplazará a Sentinel-2B entre 2028 y 2029, y, además, se prevé la misión Sentinel-2 Next Generation, diseñada para garantizar la continuidad de los datos ópticos de alta resolución más allá de 2035.



Figura 8. Satélites de la familia Sentinel-2

(https://www.esa.int/Space_in_Member_States/Spain/Sentinel_2B_-_Dosier_de_Prensa)

2.3. Bandas espectrales de los programas Landsat y Sentinel-2

Tanto la serie de satélites Landsat como el programa Sentinel-2 están equipados con sensores ópticos diseñados para captar distintas regiones del espectro electromagnético, desde la luz visible hasta el infrarrojo térmico. Estos sensores dividen el espectro en lo que se conocen como bandas espectrales, que registran información a distintas longitudes de onda. Esta información es crucial para interpretar fenómenos biofísicos como la salud de la vegetación, la presencia de humedad en el suelo, o la temperatura superficial.

En cuanto a los satélites Landsat, cada nuevo satélite incorpora ampliación en el número de bandas espectrales captadas por sus sensores y su resolución. Destaca que, con Landsat 7 se añadió una banda pancromática (banda 8) de alta resolución y mejoras en la calidad geométrica gracias al sensor ETM+. Luego, Landsat 8 y

Landsat 9 incorporaron los sensores OLI, que capta nueve bandas. y TIRS, que aporta dos bandas térmicas.

Las bandas más comúnmente utilizadas en aplicaciones agrícolas, ambientales y de recursos naturales incluyen:

- Banda 2 (Azul). Con longitudes de onda entre los 0,45 y 0,51 μm . Útil para el análisis de cuerpos de agua y detección de nubes.
- Banda 3 (Verde). Con longitudes de onda entre los 0,53 y 0,59 μm . Se usa en combinación con el rojo y azul para generar imágenes en color natural.
- Banda 4 (Rojo). Con longitudes de onda entre los 0,64 y 0,67 μm . Importante para analizar la cobertura vegetal.
- Banda 5 (NIR). Con longitudes de onda entre los 0,85 y 0,88 μm . Clave para el cálculo del índice NDVI y estudios de biomasa vegetal.
- Bandas 6 y 7 (SWIR 1 y 2). Con longitudes de onda entre los 1,57 y 2,29 μm . Muy sensibles a la humedad del suelo y vegetación, útiles en análisis de sequía y estrés hídrico.
- Bandas 10 y 11 (Térmicas). Con longitudes de onda entre los 10,60 y 12,51 μm . Usadas para detectar anomalías térmicas, evaluar islas de calor urbano o necesidades de riego.

La figura 9 resume la evolución de las bandas espectrales a lo largo de la serie Landsat.




Figura 9. Bandas espectrales de los satélites Landsat desde Landsat 1 hasta Landsat Next (<https://www.usgs.gov/landsat-missions/landsat-9>)

Por otro lado, el sistema Sentinel-2 emplea el sensor MSI, que captura información en 13 bandas espectrales. Estas incluyen bandas en el visible (RGB), el infrarrojo cercano y de onda corta, así como bandas diseñadas específicamente para estudiar la vegetación (red-edge) y la atmósfera (vapor de agua, aerosoles). Las bandas principales de Sentinel-2 incluyen:

- Bandas 2, 3 y 4 (Visible: Azul, Verde y Rojo). Cubren el espectro visible, utilizadas para composiciones en color verdadero y estudios visuales básicos.

- Banda 8 (NIR). Con longitud de onda alrededor de los 0,84 μm . De alta resolución (10 m), empleada en el cálculo del NDVI, fundamental para evaluar la salud de la vegetación.
- Bandas 5, 6, 7 y 8A (Red-Edge). Con longitudes de onda entre los 0,705 y 0,865 μm . Estas bandas permiten detectar variaciones sutiles en la vegetación antes de que sean visibles en el espectro tradicional, siendo especialmente valiosas para monitorear el estrés de cultivos.
- Bandas 11 y 12 (SWIR). Con longitudes de onda entre los 1,61 y 2,19 μm . Sensibles al contenido de humedad en el suelo y vegetación, útiles para estimar necesidades hídricas.
- Bandas 1, 9 y 10. Diseñadas para aplicaciones atmosféricas (corrección de aerosoles y detección de vapor de agua). La banda 10 no se utiliza debido a su mala calidad radiométrica.

Una de las grandes ventajas del Sentinel-2 frente a Landsat es su mayor resolución espacial y temporal, con imágenes disponibles cada 5 días, lo que permite una monitorización más frecuente de fenómenos rápidos como el crecimiento de cultivos, incendios o inundaciones. Las figuras 10 a 12 muestran las bandas del sistema Sentinel-2 atendiendo a sus diferentes resoluciones.




Figura 10. Bandas espectrales del sistema Sentinel-2 con resolución de 10m
(<https://sentiwiki.copernicus.eu/web/s2-mission>)




Figura 11. Bandas espectrales del sistema Sentinel-2 con resolución de 20m
(<https://sentiwiki.copernicus.eu/web/s2-mission>)




Figura 12. Bandas espectrales del sistema Sentinel-2 con resolución de 60m
<https://sentiwiki.copernicus.eu/web/s2-mission>

Tanto el programa Landsat como el Sentinel-2 son altamente complementarios. Mientras Landsat ha sido fundamental en el análisis multitemporal de largo plazo (desde los años 70), Sentinel-2 ofrece datos más recientes, pero con una resolución espacial y temporal mejorada. La tabla 1 señala las diferencias entre ambos programas.

Tabla 1. Comparación de características de los sensores Landsat y Sentinel-2

Característica	Landsat 8/9 (OLI/TIRS)	Sentinel-2 (MSI)
Bandas totales	11	13
Resolución espacial	15–30–100 m	10–20–60 m
Cobertura temporal	16 días	5 días
Alcance espectral	Visible a térmico	Visible a SWIR
Bandas red-edge	No	Sí (3 bandas)
Bandas térmicas	Sí (2 bandas)	No

Las distintas bandas espectrales permiten abordar una amplia variedad de estudios. Por un lado, el NIR y las bandas Red-Edge permiten distinguir vegetación sana de estresada mediante índices como el NDVI. Además, las bandas NIR y verde se usan para calcular el NDWI y detectar cuerpos de agua o su humedad.

Por otro lado, las bandas SWIR permiten diferenciar suelos secos de húmedos, así como determinar la composición mineral. Y las bandas térmicas de Landsat son útiles para detectar islas de calor, necesidades de riego o actividad volcánica.

3. Conceptos fundamentales

En el análisis de imágenes satelitales es esencial comprender ciertos conceptos clave que permiten interpretar correctamente la información registrada por los sensores. Entre estos conceptos destacan las firmas espectrales y los índices espectrales, fundamentales para evaluar el estado de la vegetación, detectar cambios ambientales o realizar estudios de uso del suelo.

3.1. Firmas espectrales

Las firmas espectrales representan el patrón característico de reflectancia o emisión de una superficie a lo largo del espectro electromagnético. Cada tipo de cobertura del suelo, ya sea vegetación, agua, suelo desnudo, plástico o construcciones, refleja y absorbe la radiación solar de manera distinta en cada banda del espectro, lo que permite su identificación y clasificación a partir de imágenes multiespectrales u hiperespectrales.

Una firma espectral típica se representa mediante un gráfico en el que el eje X corresponde a la longitud de onda (en micrómetros o nanómetros) y el eje Y a la reflectancia. Este gráfico permite observar las diferencias entre materiales según cómo interactúan con la energía solar (figura 13).




Figura 13. Firmas espectrales del agua, vegetación, hormigón y nieve

(<https://pnt.ign.es/firmas-espectrales>)

Entre las distintas cubiertas del terreno, cada tipo de superficie presenta un comportamiento espectral único que permite su identificación a través de imágenes satelitales. Por ejemplo, la vegetación saludable se caracteriza por absorber gran parte de la radiación en la región del rojo (alrededor de los 660 nanómetros), debido a la presencia de clorofila, mientras que refleja intensamente en el infrarrojo cercano (NIR, en torno a los 850 nanómetros), donde las estructuras internas de las hojas dispersan eficazmente la luz (figuras 14 y 15).




Figura 14. Firma espectral de una cubierta vegetal (<https://pnt.ign.es/firmas-espectrales>)




Figura 15. Reflectancia de la vegetación dañada y sana (<https://dstfotografia.com/ndvi/>)

En cambio, cuando la vegetación está estresada, seca o dañada, su firma espectral cambia notablemente. La reflectancia en el rojo tiende a aumentar como consecuencia de la pérdida de clorofila y la del infrarrojo cercano disminuye, al degradarse la estructura interna de las hojas. Esto permite detectar áreas con vegetación en mal estado.

Los suelos desnudos, por su parte, muestran un patrón espectral más uniforme. Su reflectancia suele ser intermedia y aumenta gradualmente desde el espectro

visible hacia el infrarrojo. No obstante, factores como la humedad, la textura o la composición mineral del suelo (ya sea arenoso, arcilloso o limo-arenoso) pueden generar variaciones sutiles en su firma. A diferencia de la vegetación, el suelo no presenta un salto brusco en la reflectancia entre bandas, lo que puede dificultar su distinción en zonas con escasa cobertura vegetal (figura 16).




Figura 16. Firmas espectrales del suelo arenoso y arcilloso

(<https://continuemosestudiando.abc.gob.ar/contenido/explorando-la-vegetacion-desde-el-espacio/>)

En el caso de los cuerpos de agua, su comportamiento espectral es claramente diferenciado. El agua absorbe la mayor parte de la radiación tanto en el espectro visible como en el infrarrojo, con valores especialmente bajos en el NIR y en el SWIR, donde prácticamente no refleja luz (figura 17).




Figura 17. Firmas espectrales agua y la nieve

(<https://www.gisandbeers.com/tecnicas-analisis-masas-de-agua-teledeteccion/>)

Las áreas quemadas también presentan firmas espectrales distintivas. Tras un incendio, la vegetación se ve sustituida por suelos oscuros, cenizas o restos carbonizados, lo que produce un descenso marcado en la reflectancia del NIR y un aumento en el SWIR (figura 18).




Figura 18. Firmas espectral de área quemada

(<https://angroman.wordpress.com/2022/05/30/deteccion-y-monitoreo-de-incendios-en-la-cuenca-del-amazonas-empleando-sensores-remotos-y-google-earth-engine/>)

3.2. Índices espectrales

Los índices espectrales son expresiones matemáticas que combinan la información de distintas bandas espectrales para destacar fenómenos o propiedades biofísicas específicas, como la salud de la vegetación, la humedad del suelo o los efectos de incendios forestales.

Uno de los indicadores más ampliamente utilizados en Teledetección para evaluar el estado de la vegetación es el Índice de Vegetación de Diferencia Normalizada (NDVI, por sus siglas en inglés). Este índice se calcula a partir de la diferencia entre la reflectancia del infrarrojo cercano (NIR) y la del rojo visible (Red), normalizada por la suma de ambas según la fórmula (1).

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

En imágenes obtenidas por sensores satelitales, como Sentinel-2 y Landsat 8/9, estas bandas corresponden a la B8 y B4 en el caso de Sentinel-2, y a las B5 y B4 respectivamente en Landsat. El NDVI genera valores que oscilan entre -1 y +1, y su interpretación permite distinguir distintas condiciones del terreno (figura 19).

- NDVI > 0,5: vegetación densa y saludable,
- NDVI entre 0,2 y 0,5: vegetación escasa o en crecimiento,
- NDVI < 0,2: suelo desnudo, áreas urbanas o vegetación degradada,
- NDVI < 0: presencia de agua o superficies altamente reflectantes como nieve.




Figura 19. Ejemplo de resultados del NDVI (<https://eos.com/es/make-an-analysis/ndvi/>)

Por ejemplo, en un cultivo donde la reflectancia del NIR es de 0,7 y la del rojo de 0,2, el NDVI resultante sería 0,56, lo que indicaría una vegetación moderadamente saludable. Este índice es fundamental en aplicaciones agrícolas, monitoreo del estado de los cultivos, detección de estrés hídrico y en la planificación territorial.

Sin embargo, en áreas donde la vegetación es escasa o está en etapas iniciales de crecimiento, el NDVI puede verse fuertemente influenciado por el brillo del suelo. Para corregir esta limitación, se desarrolló el Índice de Vegetación Ajustado al Suelo (SAVI, Soil Adjusted Vegetation Index). El SAVI introduce un factor de corrección, denominado L , que atenúa la interferencia del suelo en la señal espectral, especialmente útil en regiones semiáridas o en cultivos incipientes, como se muestra en la ecuación (2).

$$SAVI = \frac{NIR - Red}{NIR + Red + L} * (1 + L) \quad (2)$$

Dependiendo de la densidad de la vegetación, el valor de L puede ajustarse:

- $L = 1$: vegetación escasa
- $L = 0,5$: vegetación moderada
- $L = 0,25$: vegetación densa

Por ejemplo, si se registran valores de $NIR = 0,6$ y $Red = 0,3$, con un L de 0,5, el valor de SAVI será de 0,321. Este índice ofrece una mejor caracterización del estado

vegetal en paisajes mixtos donde la señal del suelo puede distorsionar los análisis basados únicamente en NDVI. La figura 20 muestra un ejemplo de situaciones donde se recomienda usar el índice NDVI o el SAVI.




Figura 20. Situaciones donde usar el índice NDVI o SAVI

(<https://eos.com/es/make-an-analysis/ndvi/>)

En la tabla 2 se resumen las principales diferencias entre los índices NDVI y SAVI, haciendo hincapié en las bandas usadas por cada uno y su aplicación.

Tabla 2. Comparación entre de características de los índices NDVI y SAVI

Índice	Bandas usadas	Rango de valores	Aplicación principal	Ventaja clave
NDVI	Red y NIR	-1 a +1	Evaluación de la salud y vigor de la vegetación	Muy sensible a cambios en la biomasa vegetal
SAVI	Red y NIR+ factor L	-1 a +1	Análisis en zonas con poca vegetación o suelo expuesto	Corrige el efecto del fondo del suelo

Por otro lado, cuando se trata de evaluar el impacto de incendios forestales, se recurre al Índice de Quemado Normalizado (NBR, Normalized Burn Ratio), diseñado específicamente para detectar áreas quemadas y medir la severidad del daño. Este índice explota el hecho de que la vegetación sana refleja intensamente

en el infrarrojo cercano, mientras que las superficies quemadas absorben más en el infrarrojo de onda corta (SWIR), como se muestra en la fórmula (3).

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} \quad (3)$$

En este caso, se utilizan las bandas B5 y B7 en Landsat 8/9, o las bandas B8 y B12 en Sentinel-2. Los valores altos del NBR indican vegetación viva y no afectada, mientras que los valores bajos o negativos suelen señalar zonas quemadas. Este índice resulta especialmente útil para el seguimiento de incendios en áreas protegidas, reservas naturales o cultivos vulnerables al fuego. La figura 21 muestra un ejemplo del cálculo del NBR.




Figura 21. NBR en comparación con la imagen en el espectro visible

(<https://www.gisandbeers.com/analisis-severidad-incendios-indice-nbr/>)

Para complementar este análisis, se utiliza el dNBR (delta NBR), que consiste en la resta entre los valores de NBR obtenidos antes y después de un incendio. Su propósito es cuantificar la severidad de la quema y clasificar el grado de impacto sobre la vegetación (ecuación 4).

$$dNBR = NBR_{anteior} - NBR_{posterior} \quad (3)$$

Los valores resultantes se interpretan según umbrales establecidos:

- < -0,25: Alto crecimiento de vegetación posterior al fuego
- -0,25; - 0,1: Bajo crecimiento de vegetación posterior al fuego
- -0,1; 0,1: Zonas estables o sin quemar
- 0,1; 0,27: Zonas quemadas con gravedad baja
- 0,27; 0,44: Zonas quemadas con gravedad moderada-baja
- 0,44; 0,66: Zonas quemadas con gravedad moderada-alta
- > 0,66: Zonas quemadas con gravedad alta




Figura 22. NBR anterior a un incendio (1), NBR posterior a un incendio (b) y dNBR resultante (c) (<https://www.earthdatascience.org/courses/earth-analytics/multispectral-remote-sensing-modis/normalized-burn-index-dNBR/>)

La figura 22 muestra un ejemplo del cálculo del dNBR a partir de los NBR anterior y posterior a un incendio.

4. Recursos web

Existen diversas plataformas online que permiten acceder de manera gratuita a imágenes satelitales provenientes de diferentes programas de observación de la Tierra, como las imágenes Landsat o Sentinel. Estos recursos web son herramientas fundamentales para trabajar en Teledetección, análisis territorial o seguimiento ambiental. Dos de los principales portales web son el EarthExplorer, USGS, y el Copernicus Browser, desarrollado por la ESA, en el marco del programa Copernicus.

4.1. EarthExplorer

EarthExplorer (<https://earthexplorer.usgs.gov/>) es un portal desarrollado por el USGS que permite consultar, visualizar y descargar datos geoespaciales de múltiples misiones satelitales, incluyendo la serie Landsat, así como imágenes de radar, fotografías aéreas y datos de elevación (figura 23). Se ha consolidado como una de las herramientas más completas para acceder a imágenes históricas y actuales.

La interfaz ofrece herramientas para delimitar áreas de interés, seleccionar rangos temporales y aplicar filtros por tipo de sensor o misión. También permite ajustar el nivel de nubes y seleccionar fechas. Una vez definidos estos parámetros, EarthExplorer muestra los resultados disponibles, los cuales pueden visualizarse en un visor interactivo. Para descargar los datos es necesario registrarse con una cuenta gratuita.




Figura 23. EarthExplorer web (<https://earthexplorer.usgs.gov/>)

4.1.1. Guía básica de EarthExplorer

Primero, se debe acceder a la plataforma EarthExplorer a través del siguiente enlace web: <https://earthexplorer.usgs.gov>. Después, para descargar imágenes es necesario iniciar sesión o registrarse de forma gratuita (figuras 24 a 26).




Figura 24. Acceso a registro de EarthExplorer




Figura 25. Inicio de sesión o registro en EarthExplorer




Figura 26. Registro EarthExplorer

Una vez iniciada sesión en la web, se define un área de interés. Esta representa la zona que queremos que incluya la imagen satélite. Se ha de tener en cuenta que las imágenes satélites Landsat tienen una resolución espacial del orden de varios kilómetros. Para definir el área de interés se debe acceder a la pestaña “Search Criteria”. En ella, el área de interés se puede definir en forma de polígono o círculo clicando en el visualizador de mapas de la plataforma o introduciendo sus coordenadas geográficas (figuras 27 y 28).



Figura 27. Definición del área de interés




Figura 28. Definición del área de interés en forma de polígono (a) o círculo (b)

Tras definir el área de interés, se define el rango temporal de búsqueda de imágenes satélite (figura 29). Este apartado define la fecha de las imágenes satelitales que se obtendrán como resultado de la búsqueda. Este rango de fechas es flexible, pudiendo abarcar un día o varios años.




Figura 29. Definición del rango temporal de búsqueda

Además, se recomienda limitar la cobertura de nubes a un 10% o menos para que las imágenes seleccionadas no contengan un alto porcentaje de superficie terrestre cubierta por nubes. Así, se obtienen imágenes de mayor calidad. A esta opción también se accede desde la pestaña “Search Criteria” (figura 30).




Figura 30. Limitación de la cobertura de nubes

Después, se debe elegir la procedencia de los datos, pudiendo ser de la colección de imágenes del Landsat con nivel de procesamiento 1 o 2 procedentes de los satélites Landsat 1 al 9. A esta opción se accede a través de la pestaña “Data sets” → Landsat → Landsat Collection 2 Level 1 o 2 (figura 31).

La diferencia entre los niveles de procesamiento 1 y 2 es que el primero de ellos incluye imágenes corregidas geométricamente para que coincidan con proyecciones cartográficas. Además, están corregidas radiométricamente de forma que los valores digitales de los píxeles de las imágenes están calibrados. Como resultado se tienen imágenes con los valores de reflectancia tal y como se

observarían desde el satélite, antes de atravesar la atmósfera. A estos datos también se les llama top-of-atmosphere (TOA).

Por otro lado, el nivel de procesamiento 2 proporciona imágenes con los valores de reflectancia reflejadas por el suelo, sin la distorsión de la atmósfera.




Figura 31. Elección de la colección de imágenes

Por último, se visualizan los resultados y se escoge la imagen que se prefiere descargar dentro de todas las imágenes encontradas limitadas al rango de fechas, tipo de satélite y porcentaje de cobertura de nubes. Desde la pestaña de “Results” se observan estos resultados (figura 32) y se pueden descargar las bandas de la imagen seleccionada (figura 33).




Figura 32. Elección de la colección de imágenes




Figura 33. Descarga de datos satélite seleccionados

4.2. Copernicus Browser

El Copernicus Browser (<https://browser.dataspace.copernicus.eu/>) es la plataforma oficial de acceso a los datos del programa Copernicus, gestionado por la ESA. A través de esta herramienta, los usuarios pueden visualizar y descargar imágenes de los satélites Sentinel.

Una de sus funcionalidades más valoradas es la posibilidad de visualizar las imágenes en diferentes combinaciones de bandas espectrales, como el color verdadero (figura 34) o falso color infrarrojo, útil para analizar vegetación o identificar cuerpos de agua. Además, permite obtener series temporales de la evolución de imágenes en un lugar determinado. Al igual que la plataforma EarthExplorer, permite ajustar el nivel de nubes, seleccionar fechas y consultar metadatos detallados.




Figura 34. Buscador de Copernicus web
(<https://browser.dataspace.copernicus.eu/>)

4.2.1. Guía básica de Copernicus Browser

Primero, se debe acceder a la plataforma Copernicus Browser a través del siguiente enlace web: <https://browser.dataspace.copernicus.eu/>. Después, para descargar imágenes es necesario iniciar sesión o registrarse de forma gratuita (figura 35).




Figura 35. Inicio de sesión o registro en Copernicus Browser

Una vez iniciada sesión en la web, se debe ajustar el tamaño de la ventana de visualización al área que se desea consultar y se concretan los criterios de búsqueda. En la pestaña “Búsqueda” se puede escoger la familia Sentinel-2 y se concreta el porcentaje de cobertura de nubes (figuras 36 y 37). Además, se establece el rango de fechas entre las que se quiere buscar la imagen satélite.



Figura 36. Elección de familia Sentinel y cobertura de nubes



Figura 37. Elección del rango de fechas de imágenes satélite

Una vez seleccionados los criterios de búsqueda, los resultados aparecen tras pulsar el botón “Buscar” al final de la pestaña de “Búsqueda”. Se observan así las cuadrículas representando las imágenes que cumplen los criterios seleccionados y se puede descargar la información de la que se desee (figura 38).




Figura 38. Selección de imagen satélite a descargar

5. Herramientas software

El análisis de imágenes satelitales requiere herramientas que permitan visualizar los datos, procesarlos, analizarlos e integrarlos con información geográfica. En este contexto, QGIS destaca como una plataforma de software libre y de código abierto que ha evolucionado hasta convertirse en una potente herramienta también para la Teledetección, especialmente gracias a su compatibilidad con formatos ráster, su ecosistema de complementos y su capacidad de integración con otras herramientas.

QGIS permite trabajar con una amplia variedad de formatos de imágenes satelitales, como GeoTIFF, NetCDF, HDF, entre otros. Esta compatibilidad facilita la importación directa de datos de satélite como Landsat o Sentinel-2 sin necesidad de convertir previamente los archivos.

Una de las funcionalidades más útiles es la visualización de imágenes multibanda, lo que permite aplicar combinaciones espectrales para analizar distintos aspectos del paisaje. Por ejemplo, es posible destacar la vegetación mediante composiciones de infrarrojo cercano, o detectar cuerpos de agua y áreas urbanas con combinaciones específicas de bandas. Esta capacidad es especialmente valiosa en estudios agrícolas y ambientales, donde se requiere interpretar características del suelo, los cultivos o la cobertura vegetal.

Uno de los mayores atractivos de QGIS es su sistema de complementos (plugins), que amplían enormemente sus capacidades básicas. Algunos de los más relevantes para el análisis de imágenes satelitales son el Semi-Automatic Classification Plugin (SCP) (figura 39.a) y el Sentinel Hub (figura 39.b). El SCP permite descargar imágenes de satélite (como Landsat y Sentinel-2), realizar corrección atmosférica, llevar a cabo clasificaciones de imágenes supervisadas y no supervisadas, y calcular índices espectrales como el NDVI. Es especialmente útil en el monitoreo agrícola, la clasificación de uso del suelo y el seguimiento de cambios en la cobertura terrestre. Por otro lado, Sentinel Hub permite acceder directamente a imágenes del programa Copernicus Sentinel y visualizar datos en diferentes combinaciones espectrales.



Figura 39. SCP plugin (a) y Sentinel Hub plugin (b)

(a: <https://plugins.QGIS.org/plugins/SemiAutomaticClassificationPlugin/>;
b: <https://www.sentinel-hub.com/develop/integrate/desktopgis/QGIS-plugin/>)

5.1. Guía básica de instalación de QGIS y sus complementos

Primero se debe acceder a la web oficial de descarga de QGIS (<https://QGIS.org/>). Después, se debe descargar la última versión según el sistema operativo. Por último, una vez abierto un proyecto nuevo en QGIS, para instalar los complementos SCP y Sentinel Hub en QGIS, se debe acceder al menú de “Complementos” → “Administrar e instalar complementos” (figura 40).




Figura 40. Administrador de complementos de QGIS

Se abrirá la ventana del administrador de complementos, donde se deberá escribir en el buscador de la parte superior de la ventana el nombre de los complementos a instalar, en este caso, los pugin SCP y Sentinel Hub (figuras 41 y 42). Para instalar cada complemento se debe pulsar sobre el botón “Instalar complemento” en la esquina inferior derecha de la ventana.




Figura 41. SCP plugin buscado en el administrador de complementos de QGIS




Figura 42. Sentinel Hub plugin buscado en el administrador de complementos de QGIS

6. Ejercicios propuestos

6.1. Guion 1

El tratamiento de imágenes satélite es útil para analizar las propiedades de grandes extensiones de terreno sin necesidad de entrar en contacto con él. Esta actividad consiste en analizar el uso y propiedades del suelo en la zona de Almería a partir de una imagen del satélite.

Satélites como los de la serie Landsat ofrecen bancos de imágenes públicas tomadas en diferentes bandas del espectro electromagnético (infrarrojo, azul, verde, etc.), como se muestra en la Tabla 1. La combinación de estas bandas espectrales permite traducir la información de una imagen en “blanco y negro” a imágenes que clasifiquen zonas urbanas y agrarias, o zonas con mayor o menor vegetación.

Para completar esta actividad, se debe seguir el presente guion y contestar a todas las cuestiones.




Figura 6.1.1. El espectro electromagnético

Fuente: <https://politecnicodeavila.usal.es/2020/02/03/maria-sanchez-aparicio-aplicacion-de-la-teledeteccion-indices-espectrales/>

Tabla 1. Bandas electromagnéticas de satélites Landsat

	LANDSAT 8	
	Longitud de onda (μm)	Resolución (m)
Banda 1 - Coastal Aerosol	0,435 - 0,451	30
Banda 2 - Blue	0,452 - 0,512	30
Banda 3 - Green	0,533 - 0,590	30
Banda 4 - Red	0,636 - 0,673	30
Banda 5 - Near Infrared (NIR)	0,851 - 0,879	30
Banda 6 - Short-wave Infrared (SWIR) 1	1,566 - 1,651	30
Banda 7 - Short-wave Infrared (SWIR) 2	2,107 - 2,294	30
Banda 8 - Panchromatic	0,503 - 0,676	15
Banda 9 - Cirrus	1,363 - 1,384	30
Banda 10 - TIR 1	10,60 - 11,19	100
Banda 11 - TIR 2	11,50 - 12,51	100

Fuente: <http://www.gisandbeers.com/lo-deberias-saber-imagenes-landsat/>

1. Descargar una imagen satelital Landsat con poca presencia de nubes y cargar sus bandas espectrales en QGIS. Incluir una imagen del proyecto nuevo en QGIS con las bandas espectrales de la 1 a la 7. ¿En qué sistema de coordenadas se cargan los archivos?

[Descarga de cuadrículas](#)

[Descarga de imágenes](#)

2. Crear la imagen satélite a color natural combinando las bandas del espectro visible, rojo, verde y azul (bandas 4, 3 y 2) en ese orden. Incluir una imagen del resultado.
3. Crear la imagen satélite de detección de zonas urbanas, construcciones e invernaderos combinando las bandas del infrarrojo y rojo (bandas 7, 6 y 4) en ese orden. Incluir una imagen del resultado. ¿En qué color se observan las construcciones, zonas urbanas o invernaderos?
4. Crear la imagen satélite infrarroja combinando las bandas del infrarrojo cercano, rojo y verde (bandas 5, 4 y 3) en ese orden. Incluir una imagen del resultado. En esta combinación de bandas, el color rojo indica una vegetación sana y bien desarrollada. Señala una zona de la imagen donde se observe este color, incluir una nueva imagen a menor escala si es necesario.
5. Escribe para qué se utilizaría cada una de las combinaciones anteriores. ¿Cuál le parece más interesante y por qué?

6.2. Guion 2

Esta actividad consiste en analizar el uso y propiedades del suelo en la zona de Almería a partir de una imagen satélite de la constelación Sentinel-2. Satélites como los de la serie Sentinel-2 ofrecen bancos de imágenes públicas tomadas en diferentes bandas del espectro electromagnético (infrarrojo, azul, verde, etc.), como se muestra en la Tabla 2 y en la figura 6.2.1.

Para completar esta actividad, se debe seguir el presente guion y contestar a todas las cuestiones.

Tabla 2. Bandas electromagnéticas de satélites Sentinel

Banda	Resolución	Longitud de onda central	Descripción
B1	60 m	443 nm	Ultra azul (Costa y Aerosol)
B2	10 m	490 nm	Azul
B3	10 m	560 nm	Verde
B4	10 m	665 nm	rojo
B5	20 m	705 nm	Visible e Infrarrojo Cercano (VNIR)
B6	20 m	740 nm	Visible e Infrarrojo Cercano (VNIR)
B7	20 m	783 nm	Visible e Infrarrojo Cercano (VNIR)
B8	10 m	842 nm	Visible e Infrarrojo Cercano (VNIR)
B8a	20 m	865 nm	Visible e Infrarrojo Cercano (VNIR)
B9	60 m	940 nm	Onda Corta Infrarroja (SWIR)
B10	60 m	1375 nm	Onda Corta Infrarroja (SWIR)
B11	20 m	1610 nm	Onda Corta Infrarroja (SWIR)
B12	20 m	2190 nm	Onda Corta Infrarroja (SWIR)

Fuente: <https://mappinggis.com/2019/05/combinaciones-de-bandas-en-imagenes-de-satelite-landsat-y-sentinel/>




Figura 6.2.1. Resolución espectral de Sentinel-2

1. Buscar una imagen satelital Sentinel-2 con poca presencia de nubes y combinar sus bandas 4, 3 y 2 a través de la plataforma oficial del programa Copernicus. ¿Qué imagen se obtiene como resultado de combinar estas bandas? Incluir una imagen del resultado.

[Descarga de teselas](#) → contenido auxiliar

[Descarga de imágenes](#)

2. Cargar la imagen satélite en QGIS incluyendo las bandas espectrales de la 1 a la 12. Incluir una imagen del resultado. ¿Qué bandas tienen resolución de 60m, 20m y 10m?
3. Crear la imagen satélite a color natural combinando las bandas del espectro visible, rojo, verde y azul (bandas 4, 3 y 2) en ese orden. Realizar la combinación tanto en resolución de 60m como de 10m e incluir imágenes de los resultados.
4. Crear la imagen satélite de detección de zonas urbanas, construcciones e invernaderos combinando las bandas del infrarrojo y rojo (bandas 12, 11 y 4) en ese orden. Incluir una imagen del resultado. ¿Qué diferencia tiene esta combinación de bandas con la necesaria para obtener esta imagen con información del satélite Landsat 8?

5. Crear la imagen satélite infrarroja combinando las bandas del infrarrojo cercano, rojo y verde (bandas 8, 4 y 3) en ese orden. Incluir una imagen del resultado. En esta combinación de bandas, el color rojo indica una vegetación sana y bien desarrollada. Señala una zona de la imagen donde se observe este color, incluir una nueva imagen a menor escala si es necesario. ¿La banda 8 del satélite Sentinel-2 tiene resolución de 60m?
6. Escribir las diferencias que observas entre consultar imágenes satélites Landsat y Sentinel. ¿Cuál le parece más interesante y por qué?

6.3. Guion 3

Esta actividad consiste en el cálculo del índice espectral NDVI (1) para identificar propiedades espectrales como la calidad de la vegetación a partir de la combinación de bandas de imágenes satélite de la familia Sentinel-2.

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

Para completar esta actividad, se debe seguir el presente guion y contestar a todas las cuestiones.




Figura 6.3.1. Definición de valores del NDVI

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

1. El índice NDVI de una zona se puede visualizar desde la página de [Copernicus browser](#). Crear un archivo de visualización a cámara rápida del índice NDVI en una misma zona y adjuntar el archivo generado a la entrega de esta actividad.
2. Descargar una imagen de la constelación Sentinel y calcular el índice NDVI de un término municipal en QGIS combinando las bandas del infrarrojo cercano y rojo. Incluir una imagen del resultado. Incluir una imagen de una zona con vegetación saludable.
3. Calcular el índice NDVI a partir de una imagen de la constelación Sentinel utilizando el plugin SCP de QGIS. Incluir una imagen del resultado.
4. Crear un índice de clasificación de los valores de NDVI atendiendo a la clasificación de la figura 1. Incluir una imagen del resultado.
5. Identificar zonas con vegetación sana ($NDVI > 0,33$) e incluir una imagen del resultado. Incluir una imagen del resultado.

6.4. Guion 4

Esta actividad consiste en la comparación del índice NDVI (1) en dos fechas diferentes para localizar mejora o detrimento de la calidad de la vegetación en una misma zona. Además, se comparará el uso del índice NDVI con el índice de calidad de la vegetación ajustado al suelo, SAVI (2).

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

$$SAVI = \frac{NIR - Red}{NIR + Red + L} * (1 + L) \quad (2)$$

Para completar esta actividad, se debe seguir el presente guion y contestar a todas las cuestiones.

Tabla 3. Bandas electromagnéticas de satélites Sentinel

Banda	Resolución	Longitud de onda central	Descripción
B1	60 m	443 nm	Ultra azul (Costa y Aerosol)
B2	10 m	490 nm	Azul
B3	10 m	560 nm	Verde
B4	10 m	665 nm	rojo
B5	20 m	705 nm	Visible e Infrarrojo Cercano (VNIR)
B6	20 m	740 nm	Visible e Infrarrojo Cercano (VNIR)
B7	20 m	783 nm	Visible e Infrarrojo Cercano (VNIR)
B8	10 m	842 nm	Visible e Infrarrojo Cercano (VNIR)
B8a	20 m	865 nm	Visible e Infrarrojo Cercano (VNIR)
B9	60 m	940 nm	Onda Corta Infrarroja (SWIR)
B10	60 m	1375 nm	Onda Corta Infrarroja (SWIR)
B11	20 m	1610 nm	Onda Corta Infrarroja (SWIR)
B12	20 m	2190 nm	Onda Corta Infrarroja (SWIR)

Fuente: <https://mappinggis.com/2019/05/combinaciones-de-bandas-en-imagenes-de-satelite-landsat-y-sentinel/>




Figura 6.4.1. Valores del coeficiente SAVI

1. Descargar dos imagen satelital Sentinel desde la página de [Copernicus browser](#), con poca presencia de nubes. Las imágenes podrán ser de dos meses distintos del mismo año o del mismo mes en años distintos. Calcular el índice NDVI de ambas imágenes y recortar a uno o varios términos municipales. Incluir una imagen del resultado.

2. Calcular la diferencia en el NDVI entre las dos imágenes descargadas. Clasificar lo resultado en las siguientes categorías e incluir imágenes de los resultados.

Clasificación:

- [-1; 0]: Peor calidad vegetal
- [0; 1]: Mejor calidad vegetal

3. Calcular el índice SAVI de una de las imágenes descargadas. Comparar el resultado del índice SAVI con el resultado del índice NDVI clasificándolos en las siguientes categorías. Incluir imágenes de los resultados.

Clasificación SAVI:

- [0; 0,1]: Sin vegetación
- [0,1; 0,4]: Vegetación pobre
- [0,4; 1]: Arbusto o hierba

Clasificación NDVI:

- [0; 0,1]: Sin vegetación
- [0,1; 0,4]: Arbusto o hierba
- [0,4; 1]: Bosque

4. Realizar un plano de localización del municipio de estudio. Adjuntar imagen o pdf del resultado.
5. Realizar un plano de resultados con el valor comparado y clasificado del índice NDVI. Incluir una imagen o pdf del resultado.
6. Realizar un plano de comparación de los resultados obtenidos con el índice SAVI y NDVI. Incluir una imagen o pdf del resultado.

6.5. Guion 5

Esta actividad consiste en la evaluación de la severidad del incendio y su impacto en la vegetación a través del índice normalizado de área quemada, NBR (1), y la comparación del NBR antes del incendio y tras un par de meses del mismo, para estudiar la rapidez de la recuperación de la vegetación, dNBR (2).

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} \quad (1)$$

$$dNBR = PreNBR - PostNBR \quad (2)$$

Para completar esta actividad, se debe seguir el presente guion y contestar a todas las cuestiones.




Figura 6.5.1. Firma espectral de área quemada y severidad del incendio
<https://angroman.wordpress.com/2022/05/30/deteccion-y-monitoreo-de-incendios-en-la-cuenca-del-amazonas-empleando-sensores-remotos-y-google-earth-engine/>

1. Localizar un área de incendio de interés utilizando la plataforma [FIRMS de la NASA](#) y descargar dos imágenes Sentinel, una previa al incendio y otra un par de meses posterior. Describir brevemente la zona escogida.
2. Calcular el índice de severidad del incendio para ambas imágenes utilizando las bandas 8a y 12 de la constelación Sentinel. Utilizar la plantilla de plano comparativo de la práctica anterior para representar los resultados. Incluir una imagen o pdf del resultado.
3. Calcular la severidad del incendio y clasificar la información ofrecida atendiendo al siguiente índice. Utilizar la plantilla de plano de estudio de la

práctica anterior para representar los resultados obtenidos. Incluir una imagen o pdf del resultado.

Clasificación:

- $< -0,25$: Alto crecimiento de vegetación posterior al fuego
- $[-0,25; -0,1]$: Bajo crecimiento de vegetación posterior al fuego
- $[-0,1; 0,1]$: Zonas estables o sin quemar
- $[0,1; 0,27]$: Zonas quemadas con gravedad baja
- $[0,27; 0,44]$: Zonas quemadas con gravedad moderada-baja
- $[0,44; 0,66]$: Zonas quemadas con gravedad moderada-alta
- $> 0,66$: Zonas quemadas con gravedad alta

4. Añadir el plano de localización del incendio al conjunto de planos anteriores. Adjuntar imagen o pdf del resultado.

7. Solucionario

7.1. Guion 1

1. Descargar una imagen satelital Landsat con poca presencia de nubes y cargar sus bandas espectrales en QGIS. Incluir una imagen del proyecto nuevo en QGIS con las bandas espectrales de la 1 a la 7. ¿En qué sistema de coordenadas se cargan los archivos?




Figura 7.1.1. Ejemplo de imagen satelital Landsat en QGIS

Los archivos correspondientes a los archivos de la imagen satélite de la zona de Almería están en coordenadas UTM Zona 30N, EPSG:32630.

2. Crear la imagen satélite a color natural combinando las bandas del espectro visible, rojo, verde y azul (bandas 4, 3 y 2) en ese orden. Incluir una imagen del resultado.




Figura 7.1.2. Ejemplo de imagen satélite a color natural combinando las bandas del espectro visible, rojo, verde y azul (bandas 4, 3 y 2)

3. Crear la imagen satélite de detección de zonas urbanas, construcciones e invernaderos combinando las bandas del infrarrojo y rojo (bandas 7, 6 y 4) en ese orden. Incluir una imagen del resultado. ¿En qué color se observan las construcciones, zonas urbanas o invernaderos?




Figura 7.1.3. Ejemplo de imagen satélite de detección de zonas urbanas

En esta composición, las zonas urbanas y construcciones se visualizan en tonos cian, azulados o blanquecinos, lo que permite diferenciarlas con claridad del entorno rural o natural.

4. Crear la imagen satélite infrarroja combinando las bandas del infrarrojo cercano, rojo y verde (bandas 5, 4 y 3) en ese orden. Incluir una imagen del resultado. En esta combinación de bandas, el color rojo indica una vegetación sana y bien desarrollada. Señala una zona de la imagen donde se observe este color, incluir una nueva imagen a menor escala si es necesario.




Figura 7.1.4. Ejemplo de imagen infrarroja combinando las bandas del infrarrojo cercano, rojo y verde (bandas 5, 4 y 3). Imagen a menor escala.

5. Escribe para qué se utilizaría cada una de las combinaciones anteriores. ¿Cuál le parece más interesante y por qué?

Cada una de las combinaciones espectrales tiene aplicaciones específicas. Las bandas 4-3-2 (color natural) son útiles para interpretación visual general, cartografía básica y comunicación de resultados a audiencias no técnicas. Por otro lado, las bandas 7-6-4 (detección urbana) se emplean en estudios de urbanismo, expansión de ciudades, detección de materiales artificiales e invernaderos. Por último, las bandas 5-4-3 (infrarroja) son ideales para análisis agrícola, evaluación de salud vegetal, detección de estrés hídrico o plagas.

Desde el punto de vista analítico, la combinación 5-4-3 resulta especialmente interesante por su potencial para el monitoreo ambiental y agrícola, ya que permite identificar cambios sutiles en la cobertura vegetal que podrían pasar desapercibidos en el espectro visible.

7.2. Guion 2

1. Buscar una imagen satelital Sentinel-2 con poca presencia de nubes y combinar sus bandas 4, 3 y 2 a través de la plataforma oficial del programa Copernicus. ¿Qué imagen se obtiene como resultado de combinar estas bandas? Incluir una imagen del resultado.




Figura 7.2.1. Ejemplo de imagen satelital Sentinel-2 con poca presencia de nubes.

Esta combinación genera una imagen que simula la visión humana, facilitando la identificación visual de elementos como vegetación, cuerpos de agua y estructuras urbanas.

2. Cargar la imagen satélite en QGIS incluyendo las bandas espectrales de la 1 a la 12. Incluir una imagen del resultado. ¿Qué bandas tienen resolución de 60m, 20m y 10m?




Figura 7.2.2. Ejemplo de imagen satelital Sentinel-2 con las bandas espectrales de la 1 a la 12.

Las bandas de Sentinel-2 presentan distintas resoluciones espaciales:

- 10 metros: Bandas 2 (azul), 3 (verde), 4 (rojo) y 8 (infrarrojo cercano).
- 20 metros: Bandas 5, 6, 7, 8A, 11 y 12 (NIR y SWIR).
- 60 metros: Bandas 1 (ultravioleta), 9 (vapor de agua) y 10 (nubes).

3. Crear la imagen satélite a color natural combinando las bandas del espectro visible, rojo, verde y azul (bandas 4, 3 y 2) en ese orden. Realizar la combinación tanto en resolución de 60m como de 10m e incluir imágenes de los resultados.




Figura 7.2.3. Imagen a color verdadero y resolución de 60m




Figura 7.2.4. Imagen a color verdadero y resolución de 60m

4. Crear la imagen satélite de detección de zonas urbanas, construcciones e invernaderos combinando las bandas del infrarrojo y rojo (bandas 12, 11 y 4) en ese orden. Incluir una imagen del resultado. ¿Qué diferencia tiene esta combinación de bandas con la necesaria para obtener esta imagen con información del satélite Landsat 8?




Figura 7.2.5. Ejemplo de la imagen satélite de detección de zonas urbanas, construcciones e invernaderos

La composición equivalente con Landsat 8 utiliza las bandas 7, 6 y 4, que cumplen funciones similares (SWIR2, SWIR1, rojo), pero con una resolución

espacial menor (30 m) en comparación con la capacidad combinada del Sentinel-2, que permite interpolar a 20 m.

5. Crear la imagen satélite infrarroja combinando las bandas del infrarrojo cercano, rojo y verde (bandas 8, 4 y 3) en ese orden. Incluir una imagen del resultado. En esta combinación de bandas, el color rojo indica una vegetación sana y bien desarrollada. Señala una zona de la imagen donde se observe este color, incluir una nueva imagen a menor escala si es necesario. ¿La banda 8 del satélite Sentinel-2 tiene resolución de 60m?

La banda 8 no tiene resolución de 60 metros, sino de 10 metros, lo que permite un análisis detallado del vigor vegetal.




Figura 7.2.6. Ejemplo de la imagen satélite infrarroja combinando las bandas del infrarrojo cercano, rojo y verde (bandas 8, 4 y 3)

6. Escribir las diferencias que observas entre consultar imágenes satélites Landsat y Sentinel. ¿Cuál le parece más interesante y por qué?

Al comparar imágenes de Landsat 8/9 con las de Sentinel-2, se observan varias diferencias en cuanto a resolución espacial, temporal, espectral y accesibilidad:

- Resolución espacial: Sentinel-2 ofrece bandas de 10, 20 y 60 m, con mayor detalle en las bandas visibles y NIR, mientras que Landsat tiene resolución uniforme de 30 m (excepto la pancromática a 15 m).

- Resolución temporal: Sentinel-2 tiene una mayor frecuencia de revisita (5 días con los dos satélites S2A y S2B), frente a los 16 días de Landsat.
- Rango espectral: Aunque ambos cubren bandas similares, Sentinel-2 incluye bandas adicionales para análisis de clorofila y aerosol, como la banda 8A o la 1.
- Accesibilidad: Ambas misiones permiten acceso gratuito.

Sentinel-2 resulta más interesante por su resolución superior, frecuencia de paso y cobertura espectral ampliada, lo que lo hace ideal para aplicaciones agrícolas, urbanas y de monitoreo ambiental más detallado.

7.3. Guion 3

1. El índice NDVI de una zona se puede visualizar desde la página de [Copernicus browser](https://copernicus-browser.esa.int/). Adjuntar una imagen de esta funcionalidad.




Figura 7.3.1. Ejemplo visualización del índice NDVI

2. Descargar una imagen de la constelación Sentinel y calcular el índice NDVI de un término municipal en QGIS combinando las bandas del infrarrojo cercano y rojo. Incluir una imagen del resultado. Incluir una imagen de una zona con vegetación saludable.






Figura 7.3.2. Ejemplo de imagen de la constelación Sentinel y cálculo en QGIS del índice NDVI de un término municipal (Almería)

3. Calcular el índice NDVI a partir de una imagen de la constelación Sentinel utilizando el plugin SCP de QGIS. Incluir una imagen del resultado.






Figura 7.3.3. Ejemplo de cálculo del índice NDVI a partir de una imagen de la constelación Sentinel utilizando el plugin SCP de QGIS

4. Crear un índice de clasificación de los valores de NDVI atendiendo a la clasificación de la figura 7.3.4. Incluir una imagen del resultado.





Figura 7.3.4. Ejemplo de cálculo del índice de clasificación de los valores de NDVI

5. Identificar zonas con vegetación sana (NDVI > 0,33) e incluir una imagen del resultado. Incluir una imagen del resultado.




Figura 7.3.5. Ejemplo de identificación con zonas con vegetación sana (NDVI > 0,33)

7.4. Guion 4

1. Descargar dos imagen satelital Sentinel desde la página de [Copernicus browser](#), con poca presencia de nubes. Las imágenes podrán ser de dos meses distintos del mismo año o del mismo mes en años distintos. Calcular el índice NDVI de ambas imágenes y recortar a uno o varios términos municipales. Incluir una imagen del resultado.




Figura 7.4.1. NDVI en junio de 2025




Figura 7.4.2. NDVI en febrero de 2025

2. Calcular la diferencia en el NDVI entre las dos imágenes descargadas. Clasificar lo resultado en las siguientes categorías e incluir imágenes de los resultados.

Clasificación:

- [-1; 0]: Peor calidad vegetal
- [0; 1]: Mejor calidad vegetal




Figura 7.4.3. Diferencia en el NDVI entre las dos imágenes

3. Calcular el índice SAVI de una de las imágenes descargadas. Comparar el resultado del índice SAVI con el resultado del índice NDVI clasificándolos en las siguientes categorías. Incluir imágenes de los resultados.

Clasificación SAVI:

- [0; 0,1]: Sin vegetación
- [0,1; 0,4]: Vegetación pobre
- [0,4; 1]: Arbusto o hierba

Clasificación NDVI:

- [0; 0,1]: Sin vegetación
- [0,1; 0,4]: Arbusto o hierba
- [0,4; 1]: Bosque




Figura 7.4.4. Clasificación del índice SAVI




Figura 7.4.5. Clasificación del índice NDVI

4. Realizar un plano de localización del municipio de estudio. Adjuntar imagen o pdf del resultado.




Figura 7.4.6. Ejemplo de plano de localización del municipio de estudio

- Realizar un plano de resultados con el valor comparado y clasificado del índice NDVI. Incluir una imagen o pdf del resultado.




Figura 7.4.7. Ejemplo de plano de resultados con el valor comparado y clasificado del índice NDVI

- Realizar un plano de comparación de los resultados obtenidos con el índice SAVI y NDVI. Incluir una imagen o pdf del resultado.




Figura 7.4.8. Ejemplo de plano de comparación de los resultados obtenidos con el índice SAVI y NDVI

7.5. Guion 5

1. Localizar un área de incendio de interés utilizando la plataforma [FIRMS de la NASA](#) y descargar dos imágenes Sentinel, una previa al incendio y otra un par de meses posterior. Describir brevemente la zona escogida.




Figura 7.5.1. Ejemplo de localización de un área de incendio

Se estudia la zona de Almuñecar (Granada) y el incendio que ocurrió en agosto de 2024. Se descargan imágenes antes de la ocurrencia del incendio (5 de agosto de 2024) y varios meses después de la ocurrencia del incendio (23 de diciembre de 2024).




Figura 7.5.2. Ejemplo de imágenes de un área de incendio

2. Calcular el índice de severidad del incendio para ambas imágenes utilizando las bandas 8a y 12 de la constelación Sentinel. Utilizar la plantilla de plano

comparativo de la práctica anterior para representar los resultados. Incluir una imagen o pdf del resultado.




Figura 7.5.3. Ejemplo de cálculo el índice de severidad del incendio

3. Calcular el crecimiento de vegetación posterior al incendio y clasificar la información ofrecida atendiendo al siguiente índice. Utilizar la plantilla de plano de estudio de la práctica anterior para representar los resultados obtenidos. Incluir una imagen o pdf del resultado.

Clasificación:

- $< -0,25$: Alto crecimiento de vegetación posterior al fuego
- $[-0,25; -0,1]$: Bajo crecimiento de vegetación posterior al fuego
- $[-0,1; 0,1]$: Zonas estables o sin quemar
- $[0,1; 0,27]$: Zonas quemadas con gravedad baja
- $[0,27; 0,44]$: Zonas quemadas con gravedad moderada-baja
- $[0,44; 0,66]$: Zonas quemadas con gravedad moderada-alta
- $> 0,66$: Zonas quemadas con gravedad alta




Figura 7.5.4. Ejemplo de crecimiento de vegetación posterior al incendio y clasificación

4. Añadir el plano de localización del incendio al conjunto de planos anteriores. Adjuntar imagen o pdf del resultado.




Figura 7.5.5. Ejemplo de plano de localización del incendio

8. Bibliografía

- Aguilar, M.A.; Aguilar, F.J.; Agüera, F.; Sánchez, J.A. Geometric accuracy assessment of QuickBird Basic Imagery using different operational approaches. *Photogramm. Eng. Remote Sens.* **2007**, *73*(12), 1321–1332.
- Abebe, G.; Tadesse, T.; Gessesse, B. Combined Use of Landsat 8 and Sentinel 2A Imagery for Improved Sugarcane Yield Estimation in Wonji-Shoa, Ethiopia. *J. Indian Soc. Remote Sens.* **2022**, *50*, 143–157.
- Amankulova, K.; Farmonov, N.; Mucsi, L. Time-series analysis of Sentinel-2 satellite images for sunflower yield estimation. *Smart Agric. Technol.* **2023**, *3*, 100098.
- Ashourloo, D.; Manafifard, M.; Behifar, M.; Kohandel, M. Wheat yield prediction based on Sentinel-2, regression, and machine learning models in Hamedan, Iran. *Sci. Iran.* **2022**, *29*, 3230–3243.
- Azimi, S.; Gandhi, T.K. Water Stress Identification in Chickpea Images using Machine Learning. In Proceedings of the 2020 IEEE 8th R10 Humanitarian Technology Conference (R10-HTC), Kuching, Malaysia, 1–3 December 2020; pp. 1–6.
- Bebie, M.; Cavalaris, C.; Kyparissis, A. Assessing Durum Wheat Yield through Sentinel-2 Imagery: A Machine Learning Approach. *Remote Sens.* **2022**, *14*, 3880.
- Bhise, D.; Kumar, S.; Mohapatra, H. Review on deep learning-based plant disease detection. In Proceedings of the 2022 6th International Conference on Electronics, Communication and Aerospace Technology, Coimbatore, India, 1–3 December 2022; pp. 1106–1111.
- Bhumiphan, N.; Nontapon, J.; Kaewplang, S.; Srihanu, N.; Koedsin, W.; Huete, A. Estimation of Rubber Yield Using Sentinel-2 Satellite Data. *Sustainability* **2023**, *15*, 7223.
- Chandel, N.S.; Chakraborty, S.K.; Chandel, A.K.; Dubey, K.; Subeesh, A.; Jat, D.; Rajwade, Y.A. State-of-the-art AI-enabled mobile device for real-time water stress detection of field crops. *Eng. Appl. Artif. Intell.* **2024**, *131*, 107863.
- Chehata, N.; Guo, L.; Mallet, C. Airborne lidar feature selection for urban classification using random forests. *Laser Scanning* **2009**, *XXXVIII*, 207–212. Available online: <https://hal.science/hal-02384719>
- Christovam, L.E.; Pessoa, G.G.; Shimabukuro, M.H.; Galo, M.L.B.T. Land use and land cover classification using hyperspectral imagery: Evaluating the performance of spectral angle mapper, support vector machine and random forest. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.-ISPRS Arch.* **2019**, *XLII-2/W13*, 1841–1847.
- Clark, M.L. Comparison of multi-seasonal Landsat 8, Sentinel-2 and hyperspectral images for mapping forest alliances in Northern California. *ISPRS J. Photogramm. Remote Sens.* **2020**, *159*, 26–40.

- Crusiol, L.G.T.; Sun, L.; Sibaldelli, R.N.R.; Junior, V.F.; Furlaneti, W.X.; Chen, R.; Sun, Z.; Wuyun, D.; Chen, Z.; Nanni, M.R.; et al. Strategies for monitoring within-field soybean yield using Sentinel-2 Vis-NIR-SWIR spectral bands and machine learning regression methods. *Precis. Agric.* **2022**, *23*, 1093–1123.
- Darra, N.; Espejo-Garcia, B.; Kasimati, A.; Kriezi, O.; Psomiadis, E.; Fountas, S. Can Satellites Predict Yield? Ensemble Machine Learning and Statistical Analysis of Sentinel-2 Imagery for Processing Tomato Yield Prediction. *Sensors* **2023**, *23*, 2586.
- de Freitas, R.G.; Oldoni, H.; Joaquim, L.F.; Pozzuto, J.V.F.; do Amaral, L.R. Predicting on-farm soybean yield variability using texture measures on Sentinel-2 image. *Precis. Agric.* **2024**.
- del Rio, M.S.; Cicuéndez, V.; Yagüe, C. Characterisation of Two Vineyards in Mexico Based on Sentinel-2 and Meteorological Data. *Remote Sens.* **2024**, *16*, 2538. <https://doi.org/10.3390/rs16142538>
- Desloires, J.; Ienco, D.; Botrel, A. Out-of-year corn yield prediction at field-scale using Sentinel-2 satellite imagery and machine learning methods. *Comput. Electron. Agric.* **2023**, *209*, 107807.
- Dharani, M.K.; Thamilselvan, R.; Natesan, P.; Kalaivaani, P.C.D.; Santhoshkumar, S. Review on Crop Prediction Using Deep Learning Techniques. *J. Phys. Conf. Ser.* **2021**, *1767*, 012026.
- Domingues, T.; Brandão, T.; Ferreira, J.C. Machine Learning for Detection and Prediction of Crop Diseases and Pests: A Comprehensive Survey. *Agriculture* **2022**, *12*, 1350.
- Dorbu, F.; Hashemi-Beni, L. Detection of Individual Corn Crop and Canopy Delineation from Unmanned Aerial Vehicle Imagery. *Remote Sens.* **2024**, *16*, 2679. <https://doi.org/10.3390/rs16142679>
- Elshehbiny, O.; Zhou, L.; He, Y.; Qiu, Z. A novel hybrid deep network for diagnosing water status in wheat crop using IoT-based multimodal data. *Comput. Electron. Agric.* **2022**, *203*, 107453.
- Faqe Ibrahim, G.R.; Rasul, A.; Abdullah, H. Sentinel-2 accurately estimated wheat yield in a semi-arid region compared with Landsat 8. *Int. J. Remote Sens.* **2023**, *44*, 4115–4136.
- Fernandez-Beltran, R.; Baidar, T.; Kang, J.; Pla, F. Rice-Yield Prediction with Multi-Temporal Sentinel-2 Data and 3D CNN: A Case Study in Nepal. *Remote Sens.* **2021**, *13*, 1391.
- Franch, B.; Bautista, A.S.; Fita, D.; Rubio, C.; Tarrazó-Serrano, D.; Sánchez, A.; Skakun, S.; Vermote, E.; Becker-Reshef, I.; Uris, A. Within-Field Rice Yield Estimation Based on Sentinel-2 Satellite Data. *Remote Sens.* **2021**, *13*, 4095.
- Ghorbanian, A.; Kakooei, M.; Amani, M.; Mahdavi, S.; Mohammadzadeh, A.; Hasanlou, M. Improved land cover map of Iran using Sentinel imagery within Google Earth Engine and a novel automatic workflow for land cover

- classification using migrated training samples. *ISPRS J. Photogramm. Remote Sens.* **2020**, 167, 276–288.
- Gómez, D.; Salvador, P.; Sanz, J.; Casanova, J.L. Potato Yield Prediction Using Machine Learning Techniques and Sentinel 2 Data. *Remote Sens.* **2019**, 11, 1745.
- Gu, H.; Mills, C.; Ritchie, G.L.; Guo, W. Water Stress Assessment of Cotton Cultivars Using Unmanned Aerial System Images. *Remote Sens.* **2024**, 16, 2609. <https://doi.org/10.3390/rs16142609>
- Haapanen, R.; Ek, A.R.; Bauer, M.E.; Finley, A.O. Delineation of forest/nonforest land use classes using nearest neighbor methods. *Remote Sens. Environ.* **2004**, 89, 265–271.
- Hunt, M.L.; Blackburn, G.A.; Carrasco, L.; Redhead, J.W.; Rowland, C.S. High resolution wheat yield mapping using Sentinel-2. *Remote Sens. Environ.* **2019**, 233, 111410.
- Hunt, M.L.; Blackburn, G.A.; Carrasco, L.; Redhead, J.W.; Rowland, C.S. High resolution wheat yield mapping using Sentinel-2. *Remote Sens. Environ.* **2019**, 233, 111410. [
- Ienco, D.; Gaetano, R.; Dupaquier, C.; Maurel, P. Land Cover Classification via Multitemporal Spatial Data by Deep Recurrent Neural Networks. *IEEE Geosci. Remote Sens. Lett.* **2017**, 14, 1685–1689.
- Jayakumar, S. Support Vector Machine and Spectral Angle Mapper Classifications of High Resolution Hyper Spectral Aerial Image. *Korean J. Remote Sens.* **2009**, 25, 233–242. Available online: <https://www.researchgate.net/publication/263440372>
- Jiménez, J.C.; Miranda, V.; Trigo, I.; Libonati, R.; Albuquerque, R.; Peres, L.F.; Espinoza, J.-C.; Marengo, J.A. Vegetation Warming and Greenness Decline across Amazonia during the Extreme Drought of 2023. *Remote Sens.* **2024**, 16, 2519. <https://doi.org/10.3390/rs16142519>
- Jjagwe, P.; Chandel, A.K.; Langston, D.B. Impact Assessment of Nematode Infestation on Soybean Crop Production Using Aerial Multispectral Imagery and Machine Learning. *Appl. Sci.* **2024**, 14, 5482. <https://doi.org/10.3390/app14135482>
- Jogekar, R.N.; Tiwari, N. A Review of Deep Learning Techniques for Identification and Diagnosis of Plant Leaf Disease. *Smart Innov. Syst. Technol.* **2020**, 183, 435–441.
- Kadavi, P.R.; Lee, C.-W. Land cover classification analysis of volcanic island in Aleutian Arc using an artificial neural network (ANN) and a support vector machine (SVM) from Landsat imagery. *Geosci. J.* **2018**, 22, 653–665.
- Kamenova, I.; Chanev, M.; Dimitrov, P.; Filchev, L.; Bonchev, B.; Zhu, L.; Dong, Q. Crop Type Mapping and Winter Wheat Yield Prediction Utilizing Sentinel-2: A Case Study from Upper Thracian Lowland, Bulgaria. *Remote Sens.* **2024**, 16, 1144.

- Karthick, M.; Vijayalakshmi, D.; Kumar Nath, M.; Mathumathi, M. Machine Learning Approaches for Automatic Disease Detection from Paddy Crops—A Review. *Int. J. Eng. Trends Technol.* **2022**, *70*, 392–405.
- Kayad, A.; Sozzi, M.; Gatto, S.; Marinello, F.; Pirotti, F. Monitoring Within-Field Variability of Corn Yield using Sentinel-2 and Machine Learning Techniques. *Remote Sens.* **2019**, *11*, 2873.
- Kayad, A.; Sozzi, M.; Gatto, S.; Marinello, F.; Pirotti, F. Monitoring Within-Field Variability of Corn Yield using Sentinel-2 and Machine Learning Techniques. *Remote Sens.* **2019**, *11*, 2873.
- Khairunniza-Bejo, S.; Mustaffha, S.; Ismail, W.I.W. Application of artificial neural network in predicting crop yield: A review. *J. Food Sci. Eng.* **2014**, *4*, 1. [
- Kim, K.-H.; Pauleit, S. Landscape character, biodiversity and land use planning: The case of Kwangju City Region, South Korea. *Land Use Policy* **2007**, *24*, 264–274.
- KTanji, K.K.; Kielen, N.C. *Agricultural Drainage Water Management in Arid and Semi-Arid Areas*; FAO Irrigation and drainage paper 61; FAO: Rome, Italy, 2002.
- Kulithalai Shiyam Sundar, P.; Deka, P.C. Spatio-Temporal Classification and Prediction of Land Use and Land Cover Change for the Vembanad Lake System, Kerala—a Machine Learning Approach. *Environ. Sci. Pollut. Res.* **2021**, *29*, 86220–86236.
- Kumar, R.; Chug, A.; Singh, A.P.; Singh, D. A Systematic Analysis of Machine Learning and Deep Learning Based Approaches for Plant Leaf Disease Classification: A Review. *J. Sens.* **2022**, *2022*, 3287561.
- Kumar, V.; Laxmi, V. Pests Detection Using Artificial Neural Network and Image Processing: A Review. In Proceedings of the 2022 International Conference on Sustainable Computing and Data Communication Systems (ICSCDS), Erode, India, 7–9 April 2022; pp. 462–467.
- Li, L.; Zhang, S.; Wang, B. Plant Disease Detection and Classification by Deep Learning—A Review. *IEEE Access* **2021**, *9*, 56683–56698.
- Liang, J.; Ren, C.; Li, Y.; Yue, W.; Wei, Z.; Song, X.; Zhang, X.; Yin, A.; Lin, X. Using Enhanced Gap-Filling and Whittaker Smoothing to Reconstruct High Spatiotemporal Resolution NDVI Time Series Based on Landsat 8, Sentinel-2, and MODIS Imagery. *ISPRS Int. J. Geo-Inf.* **2023**, *12*, 214.
- Lima, M.C.F.; Leandro, M.E.D.D.A.; Valero, C.; Coronel, L.C.P.; Bazzo, C.O.G. Automatic Detection and Monitoring of Insect Pests—A Review. *Agriculture* **2020**, *10*, 161.
- Luo, L.; Sun, S.; Xue, J.; Gao, Z.; Zhao, J.; Yin, Y.; Gao, F.; Luan, X. Crop yield estimation based on assimilation of crop models and remote sensing data: A systematic evaluation. *Agric. Syst.* **2023**, *210*, 103711.
- Mabdeh, A.N.; Ajin, R.S.; Razavi-Termeh, S.V.; Ahmadlou, M.; Al-Fugara, A. Enhancing the Performance of Machine Learning and Deep Learning-Based Flood Susceptibility Models by Integrating Grey Wolf Optimizer (GWO) Algorithm. *Remote Sens.* **2024**, *16*, 2595. <https://doi.org/10.3390/rs16142595>

- Madugundu, R.; Al-Gaadi, K.A.; Tola, E.; Edrris, M.K.; Edrees, H.F.; Alameen, A.A. Optimal Timing of Carrot Crop Monitoring and Yield Assessment Using Sentinel-2 Images: A Machine-Learning Approach. *Appl. Sci.* **2024**, *14*, 3636.
- Makinde, E.O.; Salami, A.T.; Olaleye, J.B.; Okewusi, O.C. Object Based and Pixel Based Classification Using Rapideye Satellite Imager of ETI-OSA, Lagos, Nigeria. *Geoinform. FCE CTU* **2016**, *15*, 59–70.
- Manavalan, R. Automatic identification of diseases in grains crops through computational approaches: A review. *Comput. Electron. Agric.* **2020**, *178*, 105802.
- Manavalan, R. Towards an intelligent approaches for cotton diseases detection: A review. *Comput. Electron. Agric.* **2022**, *200*, 107255.
- Mancini, A.; Solfanelli, F.; Coviello, L.; Martini, F.M.; Mandolesi, S.; Zanolli, R. Time Series from Sentinel-2 for Organic Durum Wheat Yield Prediction Using Functional Data Analysis and Deep Learning. *Agronomy* **2024**, *14*, 109.
- Marshall, M.; Belgiu, M.; Boschetti, M.; Pepe, M.; Stein, A.; Nelson, A. Field-level crop yield estimation with PRISMA and Sentinel-2. *ISPRS J. Photogramm. Remote Sens.* **2022**, *187*, 191–210.
- McCallum, I.; Walker, J.; Fritz, S.; Grau, M.; Hannan, C.; Hsieh, I.-S.; Lape, D.; Mahone, J.; McLester, C.; Mellgren, S.; et al. Crowd-Driven Deep Learning Tracks Amazon Deforestation. *Remote Sens.* **2023**, *15*, 5204. <https://doi.org/10.3390/rs15215204>
- Munthali, M.G.; Davis, N.; Adeola, A.M.; Botai, J.O.; Kamwi, J.M.; Chisale, H.L.W.; Orimoogunje, O.O.I. Local Perception of Drivers of Land-Use and Land-Cover Change Dynamics across Dedza District, Central Malawi Region. *Sustainability* **2019**, *11*, 832.
- Mwita, E.; Menz, G.; Misana, S.; Becker, M.; Kisanga, D.; Boehme, B. Mapping small wetlands of Kenya and Tanzania using remote sensing techniques. *Int. J. Appl. Earth Obs. Geoinf.* **2012**, *21*, 173–183.
- Nagaraju, M.; Chawla, P. Systematic review of deep learning techniques in plant disease detection. *Int. J. Syst. Assur. Eng. Manag.* **2020**, *11*, 547–560.
- Narin, O.G.; Sekertekin, A.; Saygin, A.; Balik Sanli, F.; Gullu, M. Yield Estimation of Sunflower Plant with CNN and ANN Using Sentinel-2. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2021**, *46*, 385–389.
- Nazir, A.; Ullah, S.; Saqib, Z.A.; Abbas, A.; Ali, A.; Iqbal, M.S.; Hussain, K.; Shakir, M.; Shah, M.; Butt, M.U. Estimation and Forecasting of Rice Yield Using Phenology-Based Algorithm and Linear Regression Model on Sentinel-II Satellite Data. *Agriculture* **2021**, *11*, 1026.
- Ngugi, L.C.; Abelwahab, M.; Abo-Zahhad, M. Recent advances in image processing techniques for automated leaf pest and disease recognition—A review. *Inf. Process. Agric.* **2020**, *8*, 27–51.

- Nuraeni, D.; Manessa, M.D.M. Spatial machine learning for monitoring tea leaves and crop yield estimation using sentinel-2 imagery, (A Case of Gunung Mas Plantation, Bogor). *Int. J. Remote Sens. Earth Sci. (IJReSES)* **2023**, *19*, 133–142.
- Oikonomidis, A.; Catal, C.; Kassahun, A. Deep learning for crop yield prediction: A systematic literature review. *N. Z. J. Crop Hortic. Sci.* **2023**, *51*, 1–26.
- Otukey, J.R.; Blaschke, T. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *Int. J. Appl. Earth Obs. Geoinf.* **2010**, *12* (Suppl. S1), S27–S31.
- Pal, M.; Mather, P.M. An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sens. Environ.* **2003**, *86*, 554–565.
- Pardede, H.F.; Suryawati, E.; Krisnandi, D.; Yuwana, R.S.; Zilvan, V. Machine Learning Based Plant Diseases Detection: A Review. In Proceedings of the 2020 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET), Tangerang, Indonesia, 8–20 November 2020; pp. 212–217.
- Perea-Moreno, A.J.; Aguilera-Ureña, M.J.; Larriva, M.D.; Manzano-Agugliaro, F. Assessment of the potential of UAV video image analysis for planning irrigation needs of golf courses. *Water* **2016**, *8*, 584.
- Perich, G.; Turkoglu, M.O.; Graf, L.V.; Wegner, J.D.; Aasen, H.; Walter, A.; Liebisch, F. Pixel-based yield mapping and prediction from Sentinel-2 using spectral indices and neural networks. *Field Crops Res.* **2023**, *292*, 108824.
- Pesaresi, S.; Mancini, A.; Quattrini, G.; Casavecchia, S. Evaluation and Selection of Multi-Spectral Indices to Classify Vegetation Using Multivariate Functional Principal Component Analysis. *Remote Sens.* **2024**, *16*, 1224. <https://doi.org/10.3390/rs16071224>
- Revel, C.; Lonjou, V.; Marcq, S.; Desjardins, C.; Fougny, B.; Coppolani-Delle Luche, C.; Guillemot, N.; Lacamp, A.-S.; Lourme, E.; Miquel, C.; et al. Sentinel-2A and 2B absolute calibration monitoring. *Eur. J. Remote Sens.* **2019**, *52*, 122–137.
- Roznik, M.; Boyd, M.; Porth, L. Improving crop yield estimation by applying higher resolution satellite NDVI imagery and high-resolution cropland masks. *Remote Sens. Appl. Soc. Environ.* **2022**, *25*, 100693.
- San-Antonio-Gómez, C.; Velilla, C.; Manzano-Agugliaro, F. Photogrammetric techniques and surveying applied to historical map analysis. *Surv. Rev.* **2015**, *47*, 115–128.
- Saifi, S.; Mukund, B.; Alam, D.; Khanam, R. A Review on Plant Leaf Disease Detection using Deep Learning. In Proceedings of the 2022 International Conference on Computational Intelligence and Sustainable Engineering Solutions (CISES), Greater Noida, India, 20–21 May 2022; pp. 101–1073.
- Scott, G.J.; England, M.R.; Starns, W.A.; Marcum, R.A.; Davis, C.H. Training Deep Convolutional Neural Networks for Land-Cover Classification of High-Resolution Imagery. *IEEE Geosci. Remote Sens. Lett.* **2017**, *14*, 549–553.

- Segarra, J.; Araus, J.L.; Kefauver, S.C. Farming and Earth Observation: Sentinel-2 data to estimate within-field wheat grain yield. *Int. J. Appl. Earth Obs. Geoinf.* **2022**, *107*, 102697.
- Senel, G.; Aguilar, M.A.; Aguilar, F.J.; Nemmaoui, A.; Goksel, C. A Comprehensive Benchmarking of the Available Spectral Indices Based on Sentinel-2 for Large-Scale Mapping of Plastic-Covered Greenhouses. *IEEE J. Sel. Top. Appl. Earth Observ. Remote Sens.* **2023**, *16*, 6601–6613
- Setiawan, W.; Rochman, E.M.S.; Satoto, B.D.; Rachmad, A. Machine Learning and Deep Learning for Maize Leaf Disease Classification: A Review. *J. Phys. Conf. Ser.* **2022**, *2406*, 012019.
- Seydi, S.T.; Amani, M.; Ghorbanian, A. A Dual Attention Convolutional Neural Network for Crop Classification Using Time-Series Sentinel-2 Imagery. *Remote Sens.* **2022**, *14*, 498. <https://doi.org/10.3390/rs14030498>
- Sharma, T.; Kaur, P.; Chahal, J.; Sharma, H. Classification of rice leaf diseases based on the deep convolutional neural network architectures: Review. *AIP Conf. Proc.* **2022**, *2451*, 020086.
- Sharma, V.; Tripathi, A.K.; Mittal, H. Technological Advancements in Automated Crop Pest and Disease Detection: A Review & Ongoing Research. In *Proceedings of the 2022 International Conference on Computing, Communication, Security and Intelligent Systems (IC3SIS)*, Kochi, India, 23–25 June 2022; pp. 1–6.
- Sinshaw, N.T.; Assefa, B.G.; Mohapatra, S.K.; Beyene, A.M. Applications of Computer Vision on Automatic Potato Plant Disease Detection: A Systematic Literature Review. *Comput. Intell. Neurosci.* **2022**, *2022*, 7186687.
- Sisodia, P. S., Tiwari, V., & Kumar, A. (2014, May). Analysis of supervised maximum likelihood classification for remote sensing image. In *International conference on recent advances and innovations in engineering (ICRAIE-2014)* (pp. 1-4). IEEE.
- Son, N.-T.; Chen, C.-F.; Cheng, Y.-S.; Toscano, P.; Chen, C.-R.; Chen, S.-L.; Tseng, K.-H.; Syu, C.-H.; Guo, H.-Y.; Zhang, Y.-T. Field-scale rice yield prediction from Sentinel-2 monthly image composites using machine learning algorithms. *Ecol. Inform.* **2022**, *69*, 101618.
- Talukdar, S.; Singha, P.; Mahato, S.; Shahfahad; Pal, S.; Liou, Y.-A.; Rahman, A. Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review. *Remote Sens.* **2020**, *12*, 1135.
- Thangaraj, R.; Anandamurugan, S.; Pandiyan, P.; Kaliappan, V.K. Artificial intelligence in tomato leaf disease detection: A comprehensive review and discussion. *J. Plant Dis. Prot.* **2022**, *129*, 469–488.
- Tugrul, B.; Elfatimi, E.; Eryigit, R. Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review. *Agriculture* **2022**, *12*, 1192.

- Vali, A.; Comai, S.; Matteucci, M. Deep Learning for Land Use and Land Cover Classification based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sens.* **2020**, *12*, 2495.
- Van Klompenburg, T.; Kassahun, A.; Catal, C. Crop yield prediction using machine learning: A systematic literature review. *Comput. Electron. Agric.* **2020**, *177*, 105709.
- Wang, J.; Wang, P.; Tian, H.; Tansey, K.; Liu, J.; Quan, W. A deep learning framework combining CNN and GRU for improving wheat yield estimates using time series remotely sensed multi-variables. *Comput. Electron. Agric.* **2023**, *206*, 107705.
- Wang, Q.; Blackburn, G.A.; Onojeghuo, A.O.; Dash, J.; Zhou, L.; Zhang, Y.; Atkinson, P.M. Fusion of Landsat 8 OLI and Sentinel-2 MSI Data. *IEEE Trans. Geosci. Remote Sens.* **2017**, *55*, 3885–3899. [
- Wan-Gyu, S.; Jun-Hwan, K.; Jae-Kyeong, B.; Dongwon, K.; Ho-Young, B.; Jung-Il, C.; Myung-Chul, S. Detection of Drought Stress in Soybean Plants using RGB-based Vegetation Indices. *Korean J. Agric. For. Meteorol.* **2021**, *23*, 340–348.
- Weng, Q. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. *ISPRS J. Photogramm. Remote Sens.* **2009**, *64*, 335–344.
- Xiao, G.; Zhang, X.; Niu, Q.; Li, X.; Li, X.; Zhong, L.; Huang, J. Winter wheat yield estimation at the field scale using sentinel-2 data and deep learning. *Comput. Electron. Agric.* **2024**, *216*, 108555.
- Xue, J.; Su, B. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *J. Sens.* **2017**, *2017*, 1353691.
- Zhang, H.; Zhang, Y.; Liu, K.; Lan, S.; Gao, T.; Li, M. Winter wheat yield prediction using integrated Landsat 8 and Sentinel-2 vegetation index time-series data and machine learning algorithms. *Comput. Electron. Agric.* **2023**, *213*, 108250.
- Zhao, Y.; Potgieter, A.B.; Zhang, M.; Wu, B.; Hammer, G.L. Predicting Wheat Yield at the Field Scale by Combining High-Resolution Sentinel-2 Satellite Imagery and Crop Modelling. *Remote Sens.* **2020**, *12*, 1024.
- Zhao, Y.; Potgieter, A.B.; Zhang, M.; Wu, B.; Hammer, G.L. Predicting Wheat Yield at the Field Scale by Combining High-Resolution Sentinel-2 Satellite Imagery and Crop Modelling. *Remote Sens.* **2020**, *12*, 1024.
- Zhou, M.; Li, C.R.; Ma, L.; Guan, H.C. Land cover classification from full-waveform lidar data based on support vector machines. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.-ISPRS Arch.* **2016**, *XLI-B3*, 447–452.
- Zhou, W. An Object-Based Approach for Urban Land Cover Classification: Integrating LiDAR Height and Intensity Data. *IEEE Geosci. Remote Sens. Lett.* **2013**, *10*, 928–931
- Zhuang, S.; Wang, P.; Jiang, B.; Li, M. Learned features of leaf phenotype to monitor maize water status in the fields. *Comput. Electron. Agric.* **2020**, *172*, 105347.