

## Review [Revisión]



## SENTINEL-2, TOOL IN AGRI-FOOD SAFETY AND PRECISION AGRICULTURE †

## [SENTINEL-2, HERRAMIENTA EN LA SEGURIDAD AGROALIMENTARIA Y AGRICULTURA DE PRECISIÓN]

Aaron David Lugo-Palacios<sup>1</sup>, Raul Eduardo Lugo-Palacios<sup>1</sup>,  
José Luis García-Hernández<sup>1</sup>, David Antonio Zúñiga-Gracia<sup>1</sup>  
and Edgar Omar Rueda-Puente<sup>2\*</sup>

<sup>1</sup>Facultad de Agricultura y Zootecnia, Universidad Juárez del Estado de Durango, Km 35 Carretera Gómez Palacio-Tlahualilo, Ejido Venecia, CP 35111, Gómez Palacio, Durango, México Email: [aarondlugo@hotmail.com](mailto:aarondlugo@hotmail.com), [raul.eduardo.lugo@hotmail.com](mailto:raul.eduardo.lugo@hotmail.com), [luiz\\_garher@hotmail.com](mailto:luiz_garher@hotmail.com), [david004\\_z@hotmail.com](mailto:david004_z@hotmail.com)

<sup>2</sup>Universidad de Sonora. Departamento de Agricultura y Ganadería. Blvd. Luis Encinas S/N Col. Centro C.P.83000. Hermosillo, Sonora, México. \*Email: [edgar.rueda@unison.mx](mailto:edgar.rueda@unison.mx)

\*Corresponding author

## SUMMARY

**Background.** Food production as the world population increases is an issue of global importance, resulting in uncertainty around agri-food security (AS). It is essential to apply new technology that monitors and makes crop management more efficient to achieve sustainable development (SD). One technology responsible for improving conventional farmers' practices is precision agriculture (PA) using tools such as big data analytics, artificial intelligence and geospatial analysis. In this sense, the monitoring of markers through satellite images requires knowledge for adequate interpretations. Some satellites have multispectral images, monitoring with these has demonstrated high precision in predicting crop yields. There are several satellites, Landsat 8 (L8) and Sentinel-2 (S2) are the most advanced and open access. **Objective.** To present the spectrophotometric fundamentals and current state of remote sensing with S2 multispectral images in relation to problems facing agriculture. It is concluded that remote sensing is a tool that contributes to the proper management of agricultural production, showing high reliability. **Methodology.** This review was carried out in accordance with the PRISMA statement (Preferred Reporting Items for Systematic reviews and Meta-Analyses), a systematic analysis of literature in the databases was carried out. MDPI, Springer Link, Science Direct, Taylor and Francis and Google Scholar were consulted. The key words were "Sentinel-2, R2, Salinity, Pest, Nitrogen, Drought". Zotero ([www.zotero.org](http://www.zotero.org)) was used as a free access bibliography manager; articles that were not related to the research objectives were excluded. **Results.** Articles related to the objective of this review were identified in the databases; the study was structured based on the needs of precision agriculture (PA). The importance of adequately managing the water demand of crops, salinity stress, pest detection and the movement of nitrogen (N) in the soil-plant-atmosphere interaction. **Implications.** Remote perception of phenomena at the field level represents an area for improvement in crop management. Increasing resource efficiency is crucial to achieving agri-food security (AS) and thus part of the sustainable development goals (SDGs). **Conclusion.** The S2 has multispectral images that, when processed, allow obtaining information about the crop, i.e. monitoring stress, humidity in plants and optimization of plant nutrition. With PA, decisions are made for crop management, costs are reduced by reducing losses due to crop stress, and resource efficiency increases.

**Key words:** Radiation; multispectral; forecast; satellite.

† Submitted February 12, 2024 – Accepted May 5, 2024. <http://doi.org/10.56369/tsaes.5474>



Copyright © the authors. Work licensed under a CC-BY 4.0 License. <https://creativecommons.org/licenses/by/4.0/>

ISSN: 1870-0462.

ORCID = Aaron David Lugo-Palacios: <http://orcid.org/0009-0008-0637-5379>; Raul Eduardo Lugo-Palacios: <http://orcid.org/0009-0008-3483-0973>; José Luis García-Hernández: <http://orcid.org/0000-0002-9190-8190>; David Antonio Zúñiga-Gracia: <http://orcid.org/0009-0006-4691-8249>; Edgar Omar Rueda-Puente: <http://orcid.org/0000-0002-9724-0558>

## RESUMEN

**Antecedentes.** La producción de alimentos conforme aumenta la población mundial, es un tema de importancia global, teniendo como consecuencia una incertidumbre en torno la seguridad agroalimentaria (SA). Es fundamental aplicar nueva tecnología que monitoree y haga más eficiente el manejo de los cultivos para lograr un desarrollo sustentable (DS). Una tecnología que conlleva la responsabilidad de mejorar las prácticas convencionales de los agricultores es la agricultura de precisión (AP) utilizando herramientas como análisis de macrodatos, inteligencia artificial y análisis geoespacial. En este sentido, el monitoreo de marcadores mediante imágenes de satélite que requiere de conocimiento para interpretaciones adecuadas. Algunos satélites disponen de imágenes multiespectrales, el monitoreo con estas ha demostrado alta precisión para pronosticar rendimiento de cultivos. Existen diversos satélites, el Landsat 8 (L8) y Sentinel-2 (S2) son los más avanzados y de acceso abierto. **Objetivo.** Presentar los fundamentos espectrofotométricos y el estado actual de la percepción remota con imágenes multiespectrales S2 con relación a problemáticas que enfrenta la agricultura. Se concluye que la percepción remota es una herramienta que coadyuva en el manejo adecuado de la producción agrícola mostrando alta confiabilidad. **Metodología.** Esta revisión se realizó acorde a conformidad en la declaración PRISMA (Preferred Reporting Items for Systematic reviews and Meta-Analyses), se elaboró un análisis sistemático de literatura en las bases de datos. Se consultó en MDPI, Springer Link, Science Direct, Taylor and Francis y Google Scholar. Los términos de búsqueda fueron “Sentinel-2, R2, Salinity, Pest, Nitrogen, Drought”. Se empleó Zotero ([www.zotero.org](http://www.zotero.org)) como gestor de acceso libre de bibliografía, se excluyeron los artículos que no estuvieran relacionados con los objetivos de la investigación. **Resultados.** Se identificaron los artículos relacionados con el objetivo de esta revisión en las bases de datos, el estudio se estructuró a partir de las necesidades de agricultura de precisión (AP). La importancia de manejar adecuadamente la demanda hídrica de los cultivos, estrés por salinidad, detección de plagas y el movimiento del nitrógeno (N) en la interacción suelo-planta-atmósfera. **Implicaciones.** La percepción remota de fenómenos a nivel de campo representa un área de mejora en el manejo de los cultivos. Aumentar la eficiencia de los recursos es crucial para lograr la seguridad agroalimentaria (SA) y con ello parte de los objetivos de desarrollo sustentable (ODS). **Conclusión.** El S2 dispone de imágenes multiespectrales que al ser procesadas permite obtener información del cultivo i.e. monitoreo de estrés, humedad en las plantas y optimización de nutrición vegetal. Con la AP se toman decisiones para el manejo del cultivo, se aminoran costos al reducir pérdidas por estrés del cultivo y aumenta la eficiencia de los recursos.

Palabras clave: Radiación; multiespectrales; pronóstico; satélite.

## INTRODUCCIÓN

La producción de alimentos se intensifica a medida que aumenta la población mundial (Zsigmond *et al.*, 2022). Esto agrega presión sobre los recursos naturales, el suelo sufre de degradación y aumenta la incertidumbre en torno la seguridad agroalimentaria (SA), a su vez incrementa la contaminación atmosférica y de cuerpos de agua. Es fundamental aplicar nuevas tecnologías que monitoree y haga eficiente el manejo de los cultivos para lograr los objetivos de desarrollo sustentable (ODS) (Buchailot *et al.*, 2022) y una tecnología que resalta es la agricultura de precisión (AP), que conlleva la responsabilidad de mejorar las prácticas convencionales de los agricultores, utilizando herramientas como análisis de macrodatos que implica mayor volumen y complejidad de datos que requieren de métodos de análisis no tradicionales, inteligencia artificial y análisis geoespacial (Marino, 2023).

Aplicar las herramientas que provee la AP orienta hacia un mejor manejo de los cultivos, de los recursos naturales y hace frente a la sindemia global (Swinburn *et al.*, 2019). Por otra parte, el rendimiento y la calidad de los cultivos depende de factores bióticos y abióticos, la aplicación de tecnología para prevenir, mantener y mejorar la eficiencia del campo es indispensable (Zsigmond *et al.*, 2022) y el monitoreo

de marcadores mediante imágenes de satélite es clave para lograr una AP (Amankulova *et al.*, 2023).

La interacción que ocurre entre la planta y la radiación electromagnética (REM) puede interpretarse para obtener información con alta precisión. Existe la necesidad de adoptar técnicas que potencialicen la producción de cultivos y así mismo hacer un uso eficiente de los recursos (Kganyago *et al.*, 2023a). Sin embargo, ello requiere de conocimiento para interpretaciones adecuadas. Algunos satélites disponen de imágenes multiespectrales de acceso abierto, el monitoreo con estas ha demostrado concisión para pronosticar rendimiento de cultivos, monitoreo de estrés, humedad en las plantas y optimización de nutrición vegetal por mencionar algunos (Ustin y Jacquemoud, 2020).

Existen diversos satélites en la órbita del planeta, el uso de alguno depende del objetivo de interés. Estos satélites difieren en cuanto a la resolución espectral, radiométrica, espacial y temporal, sin embargo, L8 y S2 son los satélites más avanzados de acceso abierto (Kang *et al.*, 2022); S2 ofrece resolución espacial de 10-20 y 60 metros en bandas para uso en la agricultura mientras L8 presenta resoluciones a los 30 metros, la resolución temporal es de cinco días y 16 respectivamente. Con relación a la resolución espectral cuentan con 13 y 11 bandas correspondientemente. En la Figura 1 se representa la composición de bandas de

S2 con relación a resolución espacial y espectral. La calidad de la imagen multispectral es determinado por el número de bandas y la mayor resolución espacial y temporal, orientándonos a que el S2 es el satélite más adecuado para monitoreo remoto y representa la mejor opción para la gestión del sector agrícola (Gogoi *et al.*, 2023).

Las imágenes multispectrales presentan excelentes áreas de oportunidad. Sin embargo, algunos factores atmosféricos como la nubosidad dificultan la recepción de la información espectral de la materia observada. En la actualidad hay métodos que permiten disminuir el ruido atmosférico para productos del S2, es indispensable procesar las imágenes para atenuar el efecto de la nubosidad. Sen2cor es una herramienta gratuita, se puede emplear en la plataforma de aplicaciones sentinel (SNAP por sus siglas en inglés), software desarrollado por la agencia espacial europea (ESA por sus siglas en inglés) y así mejorar la calidad espectral de la imagen (SUHET, 2015). La temporalidad es limitante en satélites de acceso abierto, la periodicidad de toma de datos por los satélites repercute en la observación de los fenómenos. La precisión requiere reducir el tiempo de visita de los satélites (Gogoi *et al.*, 2023).


La SA es un reto para la humanidad (Willett *et al.*, 2019). Con base a lo anterior descrito, el objetivo de la presente revisión es presentar los fundamentos espectrofotométricos y el estado actual de la

percepción remota con imágenes multispectrales S2 con relación a problemáticas que enfrenta la agricultura.

## METODOLOGÍA

La pregunta de investigación fue: ¿Cuál es el estado del arte actual del Sentinel-2 en agricultura de precisión con óptica hacia una seguridad agroalimentaria? El objetivo es mostrar los fundamentos espectrofotométricos y los avances de Sentinel-2 para percepción remota de plagas, salinidad, sequía y nitrógeno. El estudio se realizó acorde a la metodología PRISMA (Preferred Reporting Items for Systematic reviews and Meta-Analyses) (Page *et al.*, 2021); las bases de datos consultadas fueron MDPI, Springer Link, Science Direct, Taylor and Francis y Google Scholar.

La revisión de literatura fue sistemática, se partió de la búsqueda de artículos científicos con las palabras clave Sentinel 2 y  $R^2$  además de pest o salinity o drought o nitrogen, todas en idioma inglés. Se analizaron 1065 artículos que fueron resultado de la búsqueda considerando el periodo de tiempo máximo de la base de datos, el primer filtro consideró los documentos publicados entre el 2017 al 2023, en el idioma inglés y de acceso gratuito. El método de inclusión para selección de los artículos fue que presentaran modelos de predicción con imágenes del Sentinel-2, contabilizando 57.



**Figura 1.** Resolución espacial y longitud de onda de S2. Elaboración propia con datos de SUHET (2015).

Se emplearon 69 artículos en total incluyendo 12 artículos relacionados con los fundamentos espectrofotométricos de la percepción remota. Del 100% de los artículos empleados en esta revisión, 4.4% (tres artículos) de los artículos corresponden al tema de plagas (pest), 13% (nueve artículos) a salinidad (salinity), 21.7% (15 artículos) a sequía (drought), 43.4% (30 artículos) a nitrógeno (nitrogen) y 14.9% artículos son relacionados con los fundamentos.

Se empleó Zotero ([www.zotero.org](http://www.zotero.org)) como gestor de acceso libre de bibliografía, se excluyeron los artículos que no estuvieran relacionados con los objetivos de la investigación.

## RESULTADOS Y DISCUSIÓN

### Fundamentos espectrofotométricos de la percepción remota

La percepción remota de cultivos por imágenes de satélite es posible debido a que la materia interacciona con la radiación electromagnética (REM) (Olsen, 1990). Los sensores empleados en los satélites multispectrales de actualidad permiten observar la región del infrarrojo (IR) y luz visible (VIS). Tales zonas albergan la interacción de los estados de energía con la REM, por ende, la reflectancia y absorción del espectro ocurren debido a la interacción entre la REM y las transiciones entre los estados de energía. Estos incluyen el estado electrónico, de vibración y rotación. Específicamente se denota la vibración – rotación en el IR cercano mientras en el VIS surge del estado electrónico (Eisberg y Resnick, 1985).

La composición química de cada especie vegetal difiere mínimamente, sin embargo, aun así, es irrepetible la firma espectral debido a variaciones ligeras en la composición y concentración. La relación entre las plantas y la luz solar genera la firma espectral (Ollinger, 2011). Esta tiene fundamento en el proceso de absorción-reflectancia donde dicho evento consta de dos etapas (Eisberg y Resnick, 1985). Inicialmente las moléculas absorben la energía, para ello es necesario que se cumplan los dos siguientes fenómenos: 1) debe ocurrir una interacción entre la radiación y alguna carga eléctrica de la materia y, 2) la energía contenida en el fotón debe de ser igual a la energía que requiere la materia.

El evento de absorción se expresa como:

$$X + HV = X^* \quad [1]$$

Donde: X representa la materia en su estado fundamental, HV es la longitud de onda con su respectiva carga energética mientras que X\* simboliza a la materia en estado excitado.

### El proceso de reflectancia y la radiación electromagnética (REM)

El proceso de reflectancia es aquel en el que la materia pasa de estado excitado a fundamental, y viene dado por la siguiente ecuación:

$$X^* = X + HV \quad [2]$$

La diferenciación de especies se origina de la concentración de compuestos como pigmentos (clorofila, carotenoides o antocianinas), contenido de agua, compuestos que conforman la estructura de la pared celular (celulosa y lignina) y proteínas (Ustin y Jacquemoud, 2020). Los autores previos además citan que, cada cultivo presenta un patrón de absorción y reflectancia permitiendo así su identificación y que la variedad de compuestos presentes en los órganos son resultado de la expresión adaptativa de cada especie.

La REM viaja a través del espacio y es compuesta por distintas longitudes de onda, desde rayos gamma ( $10^{-6}$  nm) hasta ondas radio ( $10^{10}$  nm). Mediante teledetección con S2 es posible obtener información del espectro entre 443 y 2190 nm, por ende, abarca parte del espectro de VIS e IR (SUHET, 2015). Asimismo, las plantas utilizan el espectro de luz proveniente del sol para funciones específicas, principalmente emplean la longitud de onda en el espectro visible mediante los pigmentos (Ustin y Jacquemoud, 2020). Muestra de ello es la gran absorción que se presenta en la longitud de onda azul (400 - 500 nm) y roja (650 - 700 nm) debido a la interacción con la clorofila y la absorción para realizar la fotosíntesis, las antocianinas muestran mayor punto de absorción a 550 nm (Gitelson *et al.*, 2001). Los carotenoides a 425, 455 y 480 nm (Merzlyak *et al.*, 2003). Además, explorar las longitudes de onda que no actúan en la fotosíntesis ofrece amplitud sobre el funcionamiento de las plantas, con características singulares con relación a problemáticas de interés actual (Ustin y Jacquemoud, 2020). Si bien la estimación mediante métodos espectrofotométricos es de menor precisión comparada a métodos gravimétricos y volumétricos, los tiempos de obtención de información se reducen considerablemente (Olsen, 1990). En este subtema solo se considera la región del espectro del VIS y el IR por ser aquellas que se perciben mediante S2.

### Zona del ultravioleta-visible

La región del VIS no ofrece información suficiente para identificación de compuestos en comparación a la zona del infrarrojo. Los compuestos de carácter orgánico o inorgánico presentan un espectro de absorción – reflectancia sumamente similar en el espectro del VIS. En cambio, al observar el IR se

ahonda en las diferencias de los compuestos. Por ello es necesario emplear la región del espectro del VIS junto al IR para obtener un panorama con mayor cantidad de datos (Ustin y Jacquemoud, 2020).

La zona del VIS es el espacio de la REM en la cual el ojo humano observa la materia. Esta comprende de 400 nm – 700 nm y es totalmente observable mediante satélites de acceso abierto como es el caso del S2 (SUHET, 2015). Dependiendo del intervalo en el que interactúa la materia con la REM es el color que percibimos ocularmente. Considerando lo anterior es posible deducir a que longitudes de onda absorbe REM el objeto en cuestión. Ello se muestra en la Tabla 1. La REM dentro del ultravioleta y VIS contiene la energía suficiente para excitar los electrones de valencia, de esta manera permite precisar el estado electrónico (Eisberg y Resnick, 1985).

Entre la zona del VIS y el IR se encuentra la región del borde rojo (red-edge), esta zona tiene potencial en la agricultura y el estado del arte actual lo corrobora. S2 dispone de la banda cinco, seis y siete en dicha zona (SUHET, 2015).

**Tabla 1. Longitud de onda absorbida y color percibido ocularmente por el humano. Elaboración propia con datos de Olsen (1990).**

Intervalo de longitud de onda absorbido (nm)	Color percibido por el humano
400-450	Verde-amarillento
450-480	Amarillo
480-490	Naranja
490-500	Rojo
500-560	Purpura
560-580	Violeta
580-600	Azul
600-650	Azul-verdoso
650-750	Verde-azulado

### La región del infrarrojo cercano

La región del IR abarca desde 750 nm a  $1 \times 10^6$  nm, en este espacio de la REM se proporciona energía que genera diversos estados de energía. El IR se compone de tres subdivisiones, cuenta con IR próximo (NIR por sus siglas en inglés) que comprende de 800 nm a 2500 nm. El IR central 2500 – 25000 nm y el IR lejano 25000 – 500000 nm. El NIR abarca de 750 a 3000 nm. En esta zona se perciben transiciones electrónicas de 750 - 1000 nm, en cambio entre 1000 - 2700 nm ocurre vibración – rotación en las moléculas, mientras entre 2700 y 3000 nm disminuye dicha interacción con el espectro (Olsen, 1990). Mediante S2 se percibe la

firma espectral producto de los estados de energía contenidos en la REM (Eisberg y Resnick, 1985).

La región del NIR puede albergar información relacionada a compuestos sin relación a los pigmentos (Ollinger, 2011). Entre ellos es posible identificar aquellos que contengan los grupos funcionales carbono (C) – hidrógeno (H), N – H, O – H y otros como el azufre (S) – H, fósforo (P) – H y C – N (Olsen, 1990). Lo cual concuerda con lo reportado en el monitoreo de N en las hojas de algunas plantas, característica fundamental en el estado nutricional de la planta. Este elemento es crucial para el desarrollo vegetativo, identificar la forma adecuada de cuantificarlo con confiabilidad es importante para producir alimentos de forma sustentable (Berger *et al.*, 2020). Un estudio determinó la influencia de la concentración de nitrógeno en variación con la región NIR, mostrando una tendencia de mayor reflectancia conforme aumenta la concentración de este elemento (Ollinger *et al.*, 2008). Posteriormente dicho autor sugirió que la variación ocurrida en la zona NIR ante la concentración de nitrógeno se ve afectada por la densidad de área foliar, anatomía celular de las hojas, geometría y ángulo de la hoja (Ollinger, 2011). Sin embargo, una revisión de literatura recopiló que existe absorción de REM en proteínas y en nitrógeno, desde 910 nm hasta 2350 nm y 1510 nm a 2350 nm respectivamente (Berger *et al.*, 2020). Lo cual indica concordancia entre Ollinger *et al.* (2008) y Olsen (1990), demostrando así que compuestos nitrogenados interactúan en longitudes de onda mayores a 800 nm, en la región NIR. Así, continuar con investigación en tal región del espectro es de interés en AP para mejorar la nutrición de los cultivos y por ende optimizar rendimientos que impacten positivamente la SA.

Siguiendo la exploración de las regiones espectrales que no participan en la fotosíntesis se trata de compuestos que absorben en intervalos. Entre ellos la lignina (1690 nm y 1940), el almidón (1690 nm y 1940), y la celulosa (1940 nm y 2350) (Berger *et al.*, 2020). El agua es el mayor componente presente en las plantas, al reducir este compuesto aumenta la reflectancia desde 400-2500 nm, debido a que disminuye la capacidad de absorción destinada para el aparato fotosintético. El agua presenta picos de absorción a 1450, 1940 y 2500 nm (Carter, 1991). Además, absorbe levemente a 750 y 900 nm mientras incrementa su capacidad de absorción a 1240, 1450 y 1940 nm (Li *et al.*, 2018).

El S2 permite obtener información de esta zona mediante la banda ocho (NIR 1) y 8A (NIR 2). Las bandas recopilan datos de longitudes de onda de 842 nm y 865 nm respectivamente. Dentro de la región del infrarrojo se alberga la zona infrarroja de onda corta (SWIR por sus siglas en inglés) que percibe longitud

de onda entre 1000 y 2500 nm. El S2 cuenta con sensores que captan la reflectancia a 1610 y 2190 nm, específicamente SWIR1 y SWIR2 correspondientemente (SUHET, 2015). Como se mencionó previamente, estas zonas del espectro coadyuvan en la teledetección de fenómenos fisiológicos en los cultivos.

### **Estrés hídrico, ¿Auxilio de datos meteorológicos?**

El monitoreo del estrés hídrico en plantas es indispensable para optimizar riegos, asegurar un estado de salud que derive en producción adecuada es de utilidad económica, social y ambiental (Zhao *et al.*, 2020). La periodicidad de las imágenes espectrales representa un reto, el estado hídrico de los cultivos demanda puntualidad en tiempo y espacio (Ali *et al.*, 2020). Sin embargo, el S2 es el satélite de acceso abierto con mejor periodicidad y tamaño de píxel para observar eventos de estrés hídrico (Bellvert *et al.*, 2023). También permite supervisar riegos y así controlar el uso del agua en zonas áridas o semiáridas (Qian *et al.*, 2022)

Lin *et al.* (2020) evaluaron el potencial hídrico del tallo del algodón y su relación por separado con bandas multiespectrales del S2, índices calculados a partir de estas, así como combinación de bandas e índices. Además, se observó el efecto de regresión lineal (RL) y el método de aprendizaje automático bosque aleatorio (RF por sus siglas en inglés). La banda SWIR2 presentó mayor coeficiente de determinación ( $R^2$ ): 0.54 por parte de las bandas mediante RL. De igual manera, por medio de RL respecto a índices, el índice de diferencia normalizado 45 (NDI45) obtuvo  $R^2$ : 0.63. Mientras tanto, el RF presentó coeficiente de determinación superior al utilizar las bandas multiespectrales en comparación a índices y bandas con índices, con  $R^2$ : 0.6709, 0.6575 y 0.6592 respectivamente. Finalmente se señala que el NDI45 y el índice de relación de absorción de clorofila modificado (MCARI) ( $R^2$ : 0.61) son capaces de detectar estrés hídrico debido a la susceptibilidad al potencial hídrico.

Por otra parte, la percepción remota de la evapotranspiración (ET) es factible a través de la obtención del índice de área foliar (LAI por sus siglas en inglés), este se emplea en el modelo de balance de energía de dos fuentes (TSEB por sus siglas en inglés). Se utilizó la técnica de regresión cubica para el modelo de LAI a nivel suelo y LAI mediante S2 y L8. Todas las bandas del S2 predicen con  $R^2$ : 0.96 el LAI a nivel suelo y al agregar índices al modelo no se inmuta el coeficiente de determinación. Mientras L8 obtuvo  $R^2$ : 0.82 con todas las bandas. Por lo tanto, S2 fue superior lo cual puede ser atribuido al tamaño de píxel que permite obtener con mayor precisión los datos. El TSEB requiere de LAI, al cambiar la procedencia del

LAI modifica la ET. Así, la incertidumbre en la cuantificación del LAI repercute en la ET, o sea que la confiabilidad varía dependiendo del satélite. El S2 ofrece la proximidad más acertada, por lo tanto, el cálculo de ET es de mayor precisión (Kang *et al.*, 2022).

El índice de diferencia normalizada de humedad (NDMI por sus siglas en inglés) se calcula a partir de la región del NIR1 y del SWIR1, puede ser utilizado para monitorear el contenido de humedad del suelo y de la célula eucariota. Un estudio realizado en el sureste de Hungría por Amankulova *et al.* (2023) encontraron correlación negativa entre el NDMI y el estrés hídrico, a medida que incrementa el estrés hídrico disminuye el NDMI. Además, mostró que los valores de este índice aumentan de con la precipitación debido a que mejoran la capacidad fotosintética del cultivo (Amankulova *et al.*, 2023). También, el índice de agua de diferencia normalizada (NDWI, por sus siglas en inglés) y índice de verdor de relación simple (GI por sus siglas en inglés) permiten monitorear el contenido de agua en plantas. Por su parte Gogoi *et al.* (2023), emplearon diversos modelos a partir de índices para determinar el rendimiento, los resultados indican que estos modelos incluyen el NDWI y GI para estimar dicha variable mediante S2 con cautela. En contraparte, el índice de vegetación de la diferencia normalizada (NDVI por sus siglas en inglés) es susceptible de percibir la precipitación pues incrementó valores de NDVI en olivos ante este fenómeno atribuyéndosele al favorecimiento de condiciones de humedad (Blonda *et al.*, 2023).

En Italia se exploró la relación entre datos meteorológicos y NDVI para cuantificar contenido relativo de agua del suelo (RSWC por sus siglas en inglés) en olivo. El modelo RSWC generado a partir de NDVI y datos meteorológicos obtuvo  $R^2$ : 0.795 y raíz del error cuadrático medio (RMSE por sus siglas en inglés): 0.15 para predicción de RSWC a nivel suelo. La fórmula desarrollada fue  $RSWC_i = FVC_i (0.5 + 0.5 AW_i) + (1 - FVC_i) AW_i$ , donde FVC es la cobertura de vegetación fraccionada obtenida del NDVI; AW se calculó mediante  $AW_i = \sum Prec / \sum PET$ , donde Prec es la precipitación y PET es la relación entre la temperatura media del aire y la radiación solar calculada con un algoritmo (Battista *et al.*, 2023). Mientras tanto, el contenido de agua en suelo (SWC por sus siglas en inglés) se correlacionó con el NDVI con  $R$ : 0.564 en viñedos. Sin embargo, los resultados no fueron consistentes debido a que en maíz y pastizales la relación fue débil (0.271 y -0.121 respectivamente). No obstante, la fracción de radiación fotosintéticamente activa absorbida (fAPAR por sus siglas en inglés) presentó  $R$ : 0.977 con SWC en maíz, en pastizales 0.594 y en viñedos 0.264. El SWC optimiza la eficiencia de fAPAR al proveer mejores condiciones de humedad en el suelo, lo cual se refleja

en la actividad fotosintética de las plantas (Zsigmond *et al.*, 2022).

Por otra parte, en viñedos españoles se aplicó una metodología similar, en este estudio los autores cuantificaron la dosis de riego diaria utilizando el fAPAR obtenido mediante S2 junto a la ET, desequilibrio hídrico previsto, coeficiente ajustado empíricamente a partir de la retroalimentación de los sensores de humedad del suelo, coeficiente de evaporación del suelo, la lluvia efectiva del día anterior y un ajuste de medición. El fAPAR del S2 obtuvo  $R^2$ : 0.91 y 0.61 y RMSE: 0.10 y 0.9 para predicción de medición in situ del mismo fenómeno, la cual es una alternativa eficiente determinar la fAPAR de forma remota para reemplazar la toma de datos en campo y agregar al sistema de irrigación de precisión (Bellvert *et al.*, 2023).

La exploración de la ET fue objeto de estudio en diferentes cultivos en el distrito de riego de Yuma-Wellton-Mohawk. Se desarrolló un modelo de índice de vegetación (VIM por sus siglas en inglés) con datos meteorológicos y series de tiempo de NDVI a través de Google Earth Engine. El VIM presentó menor ET a comparación del reporte de ET emitido por la oficina de recuperación del gobierno de estados unidos, el VIM exhibió menos ET entre 388-479 mm para alfalfa, 51-76 mm para brócoli, algodón 30-109 mm y trigo 93-286. La reducción en la ET reportada por el VIM representa un área de optimización del uso del agua (French *et al.*, 2023).

Un análisis de regresión lineal multivariado determinó que de entre 14 índices, el índice de vegetación resistente a la sombra (OSAVI por siglas en inglés) + índice de clorofila (CI por siglas en inglés) + índice de estrés SI generó  $R^2$ : 0.91 y RMSE = 0.54 para predicción de rendimiento en trigo. El SI es un índice de estrés del cultivo que se calcula entre el radio de la ET real y la ET potencial, donde valores cercanos a uno (1), indican ausencia de estrés hídrico. Unir datos obtenidos a ras de suelo, presenta un área de oportunidad para crear modelos con basta confiabilidad, sin embargo, la variable respuesta en esta investigación es el rendimiento (Zhao *et al.*, 2020). Así mismo, el LAI mostro  $R^2$ : 0.80 con LAI obtenido de S2. Posteriormente se elaboró un índice considerando el LAI y un coeficiente de estrés hídrico obtenido del radio entre precipitación acumulada y ET potencial. Así, se calculó el índice de producción de pastizales (GPI por sus siglas en inglés) para determinar pérdidas por sequía de predios asegurados, el GPI obtuvo  $R^2$  de 0.74 a escala de parcela (Castelli *et al.*, 2023). Determinar el impacto de la sequía en la producción de cultivos exhibe una tendencia que sugiere que datos meteorológicos mejoran la confiabilidad de predicción.

Es posible conocer indirectamente la salud del cultivo y el flujo del agua en el ecosistema a través del contenido de clorofila en el dosel (Ali *et al.*, 2020; Kganyago *et al.*, 2023a). El estrés hídrico es adverso para la salinidad, el mapeo de zonas afectadas mediante índices de salinidad posee relación negativa con la precipitación ( $R^2$ : -0.65) lo cual ocurre debido al acumulamiento de sales en los horizontes próximos al cultivo (Rafik *et al.*, 2022).

### Teledetección de salinidad: limitantes y áreas de oportunidad

La salinidad es una problemática que influye en la degradación y desertificación del suelo, aqueja mayormente zonas áridas y semiáridas y limita la producción de alimentos (Moussa *et al.*, 2020). Las causas de la salinidad son variadas, sin embargo, lo que atañe a solucionarlo requiere determinar áreas afectadas. La percepción remota es una herramienta que permite cuantificar fenómenos en extensiones de terreno considerables con pocos recursos y precisión (Qi *et al.*, 2021). Alrededor de 397 millones de hectáreas del planeta presentan salinidad con una agregación anual de 2 millones (Taghadosi *et al.*, 2019). La SA demanda mitigar la salinidad como limitante en la producción de cultivos.

En el norte de Israel se realizó un estudio para evaluar la salinidad en plantas de tomate y algodón, específicamente concentración de cloro (Cl) y sodio (Na) en hojas. Desarrollaron un modelo en base al método de la pendiente, determinaron la diferencia entre las bandas espectrales obtenidas mediante eliminación continua (CR por sus siglas en inglés) y a su vez, se cuantificaron índices multispectrales. En cuanto a CR, los coeficientes de determinación con mayor confiabilidad se adjudican a la diferencia entre la longitud de onda 2340 nm – 2400nm con un  $R^2$ : 0.5964 para Cl. Respecto a Na, la absorción restante de 1124 nm – 1161 nm fue superior  $R^2$  de 0.4376. Posteriormente, todas las diferencias entre longitudes de onda se emularon en las bandas de S2 y las longitudes de 490–2190, o bien las bandas b2–b12 presentaron un  $R^2$  de 0.434 para Cl, mientras la b7 – b12 un  $R^2$  de 0.368 para Na. Mientras tanto, los índices sugieren mayor confiabilidad, el índice de salinidad en la vegetación (SVSI por sus siglas en inglés)  $(490 - 665) / (705 + 1610) (b4 - b2) / (b5 + b11) R^2$ : 0.488 en monitoreo de Cl. Por su parte, el segundo índice de salinidad  $(490 - 665) / (560 + 2190) (b4 - b2) / (b3 + b12)$  obtuvo  $R^2$ : 0.364 para Na. Se sugiere que las bandas de monitoreo del agua (principalmente entre 1840 - 2235 nm) son susceptibles para detectar niveles de salinidad en plantas. A medida que aumenta la concentración de Cl/Na disminuye la absorción de REM en tal intervalo, se especula que el agua decrece conforme se eleva la salinidad en las células eucariotas (Lugassi *et al.*, 2017). Sin embargo, ello no ocurre

cuando el objeto de estudio fue la conductividad eléctrica (CE) en el suelo, se atribuye a la textura del suelo y tipo de sal (Naimi *et al.*, 2021; Wang *et al.*, 2021).

El aumento de la salinidad se relaciona positivamente con la reflectancia del VIS, caso contrario con el NIR (Qi *et al.*, 2021). De manera similar, se señala que de la banda azul al NIR incrementa la reflectancia linealmente, alcanza un pico en el SWIR1 y decrece hacia SWIR2. El comportamiento de reflectancia plantea que el contenido de sales es inversamente proporcional a la reflectancia (Gopalakrishnan y Kumar, 2020). Por otra parte, se analizó por medio de regresión polinomial de segundo orden, cada una de las bandas de S2 por separado como variable predictora de CE; las bandas SWIR (1 y 2) presentaron  $R^2$  de 0.5 y 0.64 correspondientemente (Bannari *et al.*, 2018). Las sales presentes en los suelos interactúan con tal región del espectro, en particular en banda 11 y 12 en S2 (Bannari, *et al.*, 2018; Gopalakrishnan y Kumar, 2020).

En España se determinó la CE en predios con tomate, algodón y remolacha azucarera encontraron relación inversa entre CE y NDVI y los resultados indicaron que en tomate el valor de correlación (R) fluctuó por debajo de -0.66 hasta -0.73 en todas las profundidades (0.1, 0.3, 0.5, 0.7 y 0.9 m); respecto a NDVI a partir del día 50 después de siembra (dds) hasta el 60, teniendo al algodón como referencia, los valores de R estuvieron entre -0.70 a -0.90 a partir de los 35 dds en todas las profundidades. Estos resultados coinciden con el cultivo de remolacha azucarera, donde el R osciló entre -0.53 a -0.57 desde el dds 70 (Gómez-Flores *et al.*, 2022). Los sitios con mayor CE presentaron menor desarrollo del cultivo, así mismo decrece el NDVI lo cual indica que conforme aumenta la CE el cultivo se estresa y ralentiza su desarrollo (Gómez-Flores *et al.*, 2022). Mientras tanto, en la República del Níger fue imposible detectar CE con índice de salinidad (SI por sus siglas en inglés) debido a presencia de restos de cultivos y riegos de presiembra. No obstante, lo anterior, la CE se correlacionó negativamente con rendimiento y NDVI integrado en el tiempo (TI-NDVI) con R: -0.29 y -0.38 respectivamente (Moussa *et al.*, 2020). En Sri Lanka, precisamente en la región semiárida de Jaffna se construyó un modelo de regresión de mínimos cuadrados parciales (PLSR por sus siglas en inglés) utilizando imágenes del S2 y CE. El modelo de PLSR obtuvo  $R^2$ : 0.69 y RMSE: 0.4830, para ello se emplearon las bandas e índices con mayor correlación, estos últimos fueron índice salinidad 5, 6 y 3 (SI5, SI6 y SI3 por sus siglas en inglés respectivamente) con R de 0.3 para el primero y el segundo y -0.1 para el postrero, mientras las bandas 11 y 12 -0.3 y -0.4 en orden (Gopalakrishnan y Kumar, 2020).

En Irán se recolectaron muestras de suelo y se cuantificó la CE. Posteriormente, se analizaron modelos de regresión lineal múltiple (RLM) y técnicas de regresión basada en kernel. El modelo de soporte vectorial con RBF Kernel presentó  $R^2$ : 87.42 y RMSE: 5.1942, mientras la RLM arrojó un  $R^2$ : 63.13 y RMSE: 6.38. Ambos, emplearon como variables predictoras todas las bandas e índices calculados (Taghadosi *et al.*, 2019). El experimento se realizó en condiciones de suelo desnudo y/o poca vegetación, ello redujo el ruido y derivó en confiabilidad elevada. Además, la diferencia entre coeficientes de determinación fue considerable, ello denota que existen discrepancias respecto a técnicas de modelado de salinidad en suelo/plantas; un estudio realizado en el país de Irán (Naimi *et al.*, 2021), sugiere que la percepción remota de este fenómeno puede mejorar si se cruzan fuentes de datos y se utiliza aprendizaje automático. Emplear las bandas multiespectrales S2 e índices de salinidad y vegetación, imagen sintética e índices derivados de esta, además de atributos topográficos y geología obtuvieron  $R^2$ : 0.48 y RMSE = 2.49 (Naimi *et al.*, 2021). En corroboración, la aplicación de técnicas de aprendizaje automático aparenta confiabilidad superior. El uso de imágenes multiespectrales de S2 con análisis de datos mediante máquinas de vectores de soporte (SVM por sus siglas en inglés) demostró  $R^2$ : 0.88 y RMSE de 4.89 (Wang *et al.*, 2021).

El aprendizaje automático permite incrementar  $R^2$  en modelos más complejos y no lineales. Aminorar factores de ruido implica realizar corrección atmosférica a las imágenes, además, propiedades del suelo como textura, contenido de arcilla, materia orgánica y vegetación limitan la confiabilidad del modelo independientemente de la técnica de análisis de datos (Gopalakrishnan y Kumar, 2020). Considerar el estado actual del conocimiento en percepción remota de salinidad del suelo/planta sugiere explorar bandas e índices que cuenten con antecedentes favorables (Bannari *et al.*, 2018).

### Monitoreo remoto de plagas y enfermedades

La producción de alimentos mermada por estrés biótico se atribuye a insectos, malezas y microorganismos fitopatógenos. Afectan de maneras variadas y se les atribuyen pérdidas monetarias considerables. Determinar métodos de alerta temprana reduce drásticamente el daño productivo, una investigación realizada para detección de cogollero del maíz en África demostró viabilidad mediante teledetección. La magnitud de importancia de esta plaga se centra en la pérdida anual de 2.5-6.2 billones de USD tan solo en África, sin embargo, desde el año 2018 aumento a 13 billones en dicho continente. Si bien, el manejo cultural atenúa el impacto del cogollero es necesario aplicar tecnología que oriente a un manejo óptimo del cultivo, ello implica utilizar



monitoreo remoto por imágenes multiespectrales S2. Tal estudio utilizó el NDVI en calculadora ráster en QGIS, sin embargo, para analizar los datos mediante regresión lineal utilizaron el nivel de infestación del gusano cogollero del maíz (GCM) como variable predictora de la primera derivada del NDVI (dNDVI). Buchaillot *et al.* (2022), obtuvieron un  $R^2$ : 0.8102 y la relación fue negativa, a medida que aumenta el GCM disminuye el dNDVI en el cultivo de maíz, ello se debe a la alimentación del insecto, disminuye la masa de la planta y se refleja en el NDVI; los mismos autores concluyen que el homologar tal metodología en otros ambientes resulta de interés para la SA.

La maleza puede causar un detrimento en el rendimiento de los cultivos, la detección y corrección en tiempo es crucial. Se le atribuyen pérdidas de hasta 78% en rendimientos, lo anterior repercute en los objetivos de desarrollo sustentable (ODS). Un estudio realizado por Marino (2023), determinó el impacto de la maleza en un predio de trigo bajo sistema de producción orgánico. Utilizaron QGIS, calcularon el NDVI mediante calculadora ráster. Los datos fueron analizados mediante regresión lineal simple entre cada variable de rendimiento del trigo y la materia seca de la maleza, resultó en relación negativa significativa para número de espigas ( $R^2$ : 0.738), peso de espiga ( $R^2$ : 0.629), rendimiento de grano ( $R^2$ : 0.625) y biomasa del cultivo ( $R^2$ : 0.611), la maleza compite por agua, nutrientes y radiación con el cultivo acentuado (Marino, 2023). La *Xylella fastidiosa* ssp. *Pauca* causa síndrome de declive rápido de oliva (OQD por sus siglas en inglés) en olivos; la detección sugiere que individuos infectados presentan valores inferiores de NDVI respecto a árboles sanos (Blonda *et al.*, 2023).

Cuantificar el impacto de especies vegetales silvestres en los cultivos no solo permite estimar pérdidas, de realizarse en épocas tempranas es factible disminuir el riego de menoscabar rendimientos. El enfoque de los autores bajo un sistema de producción orgánica apertura el panorama para productores en general en la optimización del manejo de los cultivos. La percepción remota es una tecnología que tiene el potencial de impactar positivamente en la detección de plagas y enfermedades.

### Nitrógeno: optimización de nutrición

El nitrógeno (N) es el elemento de mayor requerimiento por los cultivos, asegurar el abasto suficiente es determinante en la producción. La SA demanda maximizar rendimientos sin menoscabar la eficiencia de los recursos. La AP permite optimizar el manejo de los cultivos, el monitoreo remoto funge como catalizador en el proceso del conocimiento de los fenómenos a nivel de campo. En cuanto a la nutrición, se requiere de aplicaciones en cantidades adecuadas y en tiempo-espacio específico. Aplicar herramientas de

AP para algún fenómeno optimiza a otro, como ejemplo, el manejo adecuado de riegos al considerar el NDVI como métrica en modelo de ET impacto positivamente en la asimilación de N en 18-23%, mientras en conjunto N, P y potasio (K) incrementa en 20-28%. El NDVI parte como representación del estado fotosintético e indirectamente percibe el estrés hídrico del cultivo (Filintas *et al.*, 2023). Este tema abarca desde el estado del N en el suelo, la formación de compuestos en los cultivos y posteriormente en grano. Además, ilustra el avance en la estimación de proteína cruda, la interacción del N con otros elementos y evidencia limitada (hasta donde lo permite la literatura) de la determinación de otros minerales a nivel planta y suelo.

Realizar estudios en suelos típicos de cada región permite extrapolar el contenido de minerales a zonas aledañas, esto deriva en reducción de costos por análisis químicos del suelo. A su vez, incrementa hipotéticamente la eficiencia de fertilización. Disponer de mapas de fertilidad con precisión elevada limita el error considerablemente, así minimiza el exceso y/o el déficit por nutrición. Delimitar la distribución espacial de N en suelo por medio de técnicas de aprendizaje automático RF, potenciación del gradiente (GB por sus siglas en inglés) y técnica de refuerzo de gradientes extremo (XGBoost por sus siglas en inglés) junto a variables ambientales (la pendiente, elevación del nivel del mar, dirección del terreno y precipitación) es promisorio, la temperatura resalta en importancia. El desempeño de predicción entre bandas y variables ambientales resultó favorable en contraste ( $R^2$ : 0.90, 0.88 utilizando RF y GB) a índices, bandas e información ambiental ( $R^2$ : 0.90 con XG), si bien la confiabilidad es similar la complejidad aumenta con el modelo XG, por lo tanto, resulta factible aminorar los factores incidentes manteniendo la exactitud. Además, la región del rojo, borde rojo y SWIR obtuvieron correlaciones de 0.89 a 0.90 con el N (Mashaba-Munghemezulu *et al.*, 2021).

La adición de variables atmosféricas en detección de amonio ( $\text{NH}_3$ ), ello fue objeto de estudio en sinergia de bandas del S2 y datos de calidad del aire, esto fue realizado con un método de integración de aprendizaje automático, estimador parzen estructurado en árbol y kriging ordinario arrojando  $R^2$ : 0.85. Las variables predictoras con mayor puntuación de importancia según análisis de explicaciones aditivas SHapley fueron el ozono (26.29%), NDWI (20.12%), óxido de azufre (10.3%), las PM10 (9.01%) y el CO (7.62%). Los autores atribuyen el impacto del ozono a la alteración generada en la respiración radicular de las plantas, mientras el NDWI es susceptible al estado hídrico, con ello la absorción del  $\text{NH}_3$  en amonio ( $\text{NH}_4$ ) y en consecuencia su movilización del suelo a la planta. Al agrupar a las variables independientes por tipo de información, ya sea datos de calidad del aire,

índices de vegetación y textura del suelo se estableció influencia sobre el modelo, con 60.52%, 30.79% y 8.69% respectivamente. Considerando lo anterior, es probable que la agregación de fuentes de datos cruzados sea clave en avances de actualidad y futuro en la percepción remota (Song *et al.*, 2023).

Mientras tanto diversos índices del S2, entre ellos el índice de vegetación mejorado (EVI por sus siglas en inglés), índice de vegetación de diferencia normalizada verde (GNDVI por sus siglas en inglés), índice de borde rojo de diferencia normalizada (NDRE por sus siglas en inglés), NDVI, NDMI y índice de borde rojo normalizado (NRERI por sus siglas en inglés) muestran correlaciones con índices derivados del sistema ISARIA. Este es un método de estimación que se instala en tractores, se auxilia de sensores ópticos y GPS para generar un mapa de fertilidad que permite optimizar la nutrición del productor (Mezera *et al.*, 2022). En consecuencia, emplear sistema ISARIA o S2 es similar estadísticamente, la elección del instrumento a elegir depende de los recursos y el área de interés. El S2 muestra mayor accesibilidad económicamente y en demanda de tiempo. Así mismo, se han desarrollado estudios para evaluar la sinergia de diversas fuentes espectrales o el contraste entre estas. Un estudio comparó al S2 frente a un satélite hiperespectral (mayor número de bandas) para determinar contenido de N total en suelo. El resultado indicó mayor fiabilidad mediante S2 con RF ( $R^2$ : 0.74 y RMSE: 0.10 g/kg) utilizando las bandas únicamente. La banda 3 contribuyó en un 20% al modelo, mientras las bandas 4, 5 y 12 aportaron alrededor del 12.5% (Zhang *et al.*, 2023b).

En otro estudio se comparó el coeficiente de determinación de diversos modelos de aprendizaje automático, esto en base a máquinas de vectores de soporte (SVMr por sus siglas en inglés) y RF con imágenes multispectrales de L8 y S2 para cuantificar N del suelo, L8 fue mejor por 11 puntos en  $R^2$  (S2 0.79), ambos con SVMr. Luego se añadió el contenido de materia orgánica del suelo (SOC por sus siglas en inglés). De esta manera se incrementó significativamente la precisión de los modelos, con S2 el  $R^2$  paso a 0.92 mientras L8 obtuvo 0.95 (Sahabiev *et al.*, 2021). Sin embargo, no todo es contrastar fuentes. Por su cuenta, se cuantificó el contenido de nitrato ( $\text{NO}_3$ ),  $\text{NH}_3$  y el porcentaje de N en el suelo con bandas espectrales del S2 y L8 satisfactoriamente. Se emplearon diversas técnicas de aprendizaje automático y bandas espectrales con corrección atmosférica, así como en crudo. La detección del porcentaje de N fue superior con GB ( $R^2$ : 0.98) en bandas crudas, aunado a esto los resultados fueron consistentes en el resto de métodos de aprendizaje automático con valores de  $R^2 > 0.70$ . De igual forma el modelo GB fue superior con bandas crudas para  $\text{NO}_3$  con  $R^2$ : 0.90, en cambio, el  $\text{NH}_4$  presentó regularidad media entre los diferentes

modelos con espectro corregido atmosféricamente (Dhiman *et al.*, 2023). Además, la determinación de N total del suelo resultó favorecida al unificar bandas del S2, L8 y Sentinel-1 (S1) (Zhang *et al.*, 2023a). Las imágenes del S1 ofrecen información del sensor de radar de apertura sintética, lo cual inhibe la injerencia de ruido atmosférico al operar en 5.405 GHz. Evaluar la simbiosis entre satélites con resoluciones distintas permite optimizar la observación de fenómenos a nivel suelo.

En cuanto al estado del N dentro de los cultivos se han evaluado diferentes variables asociadas. El contenido foliar de N (LNC por sus siglas en inglés) es un indicador del estado nutricional del cultivo, se determina de diversas formas, la manera indirecta es considerando el NDRE mediante una ecuación ( $\text{LNC} = 4.060 \cdot \text{NDRE} + 0.43$ ). Posteriormente se desarrolló un modelo de predicción de rendimiento a partir de XGBoost, se obtuvo un RMSE: 0.73. El LNC multiplicado por el día después de siembra en que se obtuvo fue altamente ponderado en importancia del modelo, esto después de la variedad del cultivo. Se determinó que la aplicación de  $240 \text{ kg ha}^{-1} \text{ N}$  superior no beneficia la producción. De esta manera es posible precisar requerimiento de N en los cultivos (Iatrou *et al.*, 2021).

En añadidura, el LNC en forrajes fue estimado mediante el índice de radio de tres bandas (TBI por sus siglas en inglés), el cual utilizó las bandas 2, 3 y 4 y obtuvo un  $R^2$ : de 0.38 y RMSE: 3.36. Sin embargo, demuestra falta de consistencia entre el nivel de fertilización de N y el LNC, la relación presenta tendencia cuadrática en un sitio, mientras en la otra localidad el vínculo es lineal. Por lo tanto, se constata que existe discrepancia entre la dosis de N y el valor de LNC, ello puede ser atribuido a variaciones en el contenido de N y otros minerales disponibles en el suelo. La validación de los modelos debe de realizarse en las condiciones específicas de la zona de interés (Cisneros *et al.*, 2020). En concordancia, el borde rojo y la región del VIS fueron determinantes en la obtención de LNC. Mientras tanto, la región NIR y SWIR no fueron importantes en los modelos de detección. En añadidura, la resolución espacial fue objeto de análisis, los resultados sugieren una decantación por resolución de 50 cm por píxel. Sin embargo, la diferencia no es considerable, los recursos disponibles pueden limitar el acceso a satélites comerciales o la exploración a través de vehículo aéreo no tripulado (VANT) (Hassani *et al.*, 2023). Entonces el S2 es el satélite de acceso abierto con mayor resolución espacial, lo cual lo convierte en la primera elección al explorar la percepción remota.

En otra investigación se evaluó el contenido de N en pastizales con confiabilidad aceptable con ( $R^2$ : 0.78). Para ello se desarrolló un modelo de PLSR con

algoritmo de mejora de bandas multiespectrales en sinergia con datos meteorológicos, específicamente índice de humedad relativa (RHI por sus siglas en inglés) que se obtiene de la temperatura del aire, precipitación, presión atmosférica, velocidad del viento, radiación y otros factores, dicho modelo incremento 0.14 el  $R^2$  en contraste con el espectro crudo. La banda 12 y el RHI fueron de mayor importancia en el modelo, seguidos por la banda 11 y 3 (Pang *et al.*, 2022). Los datos meteorológicos son factores fuertemente asociados al bienestar de las plantas, considerar estos en los modelos deriva en un panorama amplificado suelo-planta-atmosfera. Lo cual se refleja en el aumento de la precisión.

La unión de fuentes espectrales es prometedora. El porcentaje de N en pastizales fue observado con la generación de valores de satélites multiespectrales de S2, Landsat 7 y L8 en conjunto. La unión de diferentes fuentes de datos permite obtener información con especificaciones variadas como resolución espectral, espacial y temporal. El  $R^2$  fue de 0.50 y RMSE: 0.35. Este proceso de unificación no es común de observar, requiere de mayor exploración sin embargo es promisorio (Dehghan-Shoar *et al.*, 2023). La unión de bandas multiespectrales del S2 junto a satélite constelación de monitoreo de desastres (DMC por sus siglas en inglés) presentó un error medio absoluto de 11–15 kg N ha<sup>-1</sup> en el mapeo de absorción de N, el error es bajo, por lo tanto, la AP tiene cabida bajo este sistema. La combinación de información de ambos satélites permite conseguir más imágenes libres de nubosidad. La nubosidad obstruye la recepción de la radiación reflejada, en consecuencia, la información recopilada por el satélite en cuestión presenta valores con ruido. Además, se resalta la importancia de la región borde rojo y NIR del S2 que conforman los índices NDRE e índice de clorofila borde rojo (CIred-edge por sus siglas en inglés), ambos con  $R^2$ : 0.85 y 0.88 correspondientemente. Tales regiones del espectro han abierto un área de oportunidad en el manejo de la nutrición de N en los cultivos (Söderström *et al.*, 2017).

El contenido de clorofila en el dosel (CCC por sus siglas en inglés) es un indicador indirecto del contenido de N en los cultivos, además es considerado una métrica para evaluar el estado de salud de las plantas por su relación con la productividad. Ha sido objeto de estudio, se evaluó la predicción a través de algoritmos de redes neuronales del software SNAP (ANNS2 por sus siglas en inglés) así como índices, el ANNS2 demostró correlación elevada ( $R^2$ : 0.85) mientras el índice con mejor relación fue el CIred-edge ( $R^2$ : 0.81) seguido del índice de clorofila de borde rojo invertido (IRECI) ( $R^2$ : 0.80). Explorar el ANNS2 posee ventajas predictivas ante índices comúnmente empleados, dispersar el uso del SNAP es de utilidad en

el vínculo percepción remota-agricultura (Casella *et al.*, 2022).

Otra variable similar es contenido de clorofila en hojas (LCC por sus siglas en inglés), se comparó el S2 con el satélite RapidEye y EnMap. El  $R^2$  del S2 fue 0.805 para dos años de estudio, siendo superior por 0.098 y 0.034 puntos respectivamente producto del PLSR y con injerencia de zona del borde rojo (699 nm y 734 nm). En cambio, al estimar el vínculo de índices con LCC, se encontró al índice de clorofila terrestre MERIS (MTCI por sus siglas en inglés) apto para la labor. Este utiliza dos bandas del borde rojo (740 nm y 783 nm), considerando lo anterior, la región del borde rojo generó asertividad amplia en comparación a índices con una banda de esta zona y fue más notorio al cotejarlo con índices en su ausencia. Explorar esta parte del espectro puede mejorar la estimación de compuestos con N, como lo es el LCC (Cui *et al.*, 2019).

La influencia de la configuración espacial ha sido explorada, esta fue objeto de análisis en cuanto a determinación de LCC y CCC. En la primera variable el RMSE: <7 en dos sitios de estudio con bandas de 10 m, respecto a CCC hubo inconsistencias puesto que en un sitio el RMSE fue inferior a resolución de 20 m, mientras en el otro se adjudica a 10 m. Por lo anterior, es probable que el área de píxel no desempeñe un rol de variación más allá de la resolución espectral. La región del espectro con 10 m por píxel en S2 ha sido explorada desde hace décadas, a esta zona le compete la absorción de pigmentos. La clorofila resalta como marcador de salud, además es necesario explorar aun la relación de xantofilas, antocianinas y carotenoides con procesos bioquímicos dentro de los cultivos, ya sea para manejo o mejora de componentes nutraceuticos. Por otra parte, las bandas con 20 m de resolución aún son investigadas, sin embargo, el estado del arte va generando una corroboración del conocimiento. Esta región del espectro parece representar fenómenos físicos y bioquímicos distintos mencionados en diversas áreas de esta revisión de literatura (Kganyago *et al.*, 2023a). Por otra parte, agregar covariables geométricas que representan el ángulo cenital y azimutal incremento entre el 3-5% la confiabilidad de predicción de CCC. Este hallazgo abre la consideración de la viabilidad de variables geométricas en la indagación de modelos de predicción de parámetros bioquímicos (Kganyago *et al.*, 2023b).

Estimar el índice de nutrición de N (NNI por sus siglas en inglés) en maíz y trigo arrojó resultados contrastantes. La confiabilidad fue superior en el primer cultivo, los autores atribuyen la discrepancia a nubosidad en el predio con trigo. En el caso del maíz el  $R^2$ : 0.79 con NDRE, para trigo  $R^2$ : 0.61 con el índice de relación de absorción de clorofila transformada (TCARI por sus siglas en inglés). El NNI fue calculado

mediante la relación actual de concentración de N dividido entre la concentración crítica de N en el cultivo, ambos en %. El CCC fue estimado en ambos cultivos con  $R^2$ : 0.81 y 0.37 respectivamente. La absorción de N se trazó a través del contenido de clorofila del dosel (CCC\_S2) con  $R^2$ : 0.77 con tendencia lineal desde 0 kg ha<sup>-1</sup> hasta 150, en adición, la biomasa se determinó con un modelo logarítmico con índice de áreas verdes (GAI\_S2) arrojando un  $R^2$ : 0.83 (Crema *et al.*, 2020). Tal investigación realizó un manejo completo de los cultivos, modelaron la absorción de N, concentración en el cultivo y la producción. De esta manera se aprecia la interacción del N con las plantas y su impacto en la seguridad agroalimentaria. Ello es ejemplo de manejo de nutrición en cultivos. El contenido de N en dosel (CNC por sus siglas en inglés) fue analizado en un estudio, se determinó la confiabilidad de PROSAIL (PRO viene de PROSpect, un modelo que simula las propiedades ópticas de las hojas, SAIL viene de SAIL, un modelo que simula la reflectancia del dosel vegetal), PLSR e índices de vegetación para establecer el CNC, los autores emplearon el RMSE para evaluar el ajuste entre los datos actuales y los datos generados por el modelo en 2017 y 2018. El distanciamiento medio mediante PROSAIL fue de 33.9 kg ha<sup>-1</sup> y 36.8 kg ha<sup>-1</sup>, PLSR 27.9 kg ha<sup>-1</sup> y 38.4 kg ha<sup>-1</sup> mientras los índices presentaron valores superiores a 50 kg ha<sup>-1</sup>. Se señala al PROSAIL como el método apropiado debido a la volatilidad del PLSR (Bossung *et al.*, 2022). En contraparte, el CNC analizado por modelado de enfoque híbrido fue inferior en  $R^2$  0.50 mediante dos aproximaciones (Rossi *et al.*, 2022).

Las bandas del borde rojo mejoran la estimación de compuestos con N. Ello se constata en la comparación de la confiabilidad de predicción en ausencia y presencia de dicha región y su impacto de densidad de clorofila del dosel (CCD por sus siglas en inglés) a diferentes etapas del cultivo. Así se permite identificar el CCD con correlación significativa al 95% a partir de la etapa de unión en diversos índices, mientras en etapa de llenado es significativa al 99% (Xing *et al.*, 2022). Por otra parte, se utilizaron 14 índices para determinar concentración de N mediante LNC, acumulación foliar de N (LNA por sus siglas en inglés), concentración de N (PNC por sus siglas en inglés) y acumulación de N (PNA por sus siglas en inglés). Se seleccionaron dos índices como predictores para cada variable, se realizó RLM y los modelos mostraron buena confiabilidad ( $>R^2$ : 0.73) y raíz de error cuadrático medio normalizado (nRMSE por sus siglas en inglés)  $<14\%$ . Posteriormente se evaluó la predicción del contenido de proteína en grano (GPC por sus siglas en inglés) con auxilio de índices y los cuatro indicadores de N en planta (LNC, LNA, PNC y PNA), sin embargo, el  $R^2$  no fue superior a 0.5. Por lo tanto, el GPC es influenciado por otros factores más allá del contenido de N en el cultivo, entre ellos el estrés hídrico y

calórico. Cuantificar el contenido de N demuestra fundamentos firmes, mientras GPC es un reto de actualidad (Zhao *et al.*, 2019). Segarra *et al.* (2022) obtuvieron resultados similares ( $R^2$ : 0.40) referente al contenido de N en grano.

En contraste, se cuantificó la proteína cruda en forrajes a través de RF con índices de vegetación ( $R^2$ : 0.77, RMSE: 6.6 y nRMSE: 10%). Además se consiguió correlación  $>0.60$  entre proteína cruda y la región borde rojo, NIR y SWIR, se adjudica que el contenido de N en la hoja representa un rol importante en las enzimas, especialmente en la Rubisco y ello impacta la absorción - reflectancia en la zona NIR, en cuanto al SWIR, se atribuye la variación a los enlaces de las proteínas, precisamente la unión del H a S, N y C. Respecto a los índices, el índice de aguas superficiales terrestres (LSWI) por si solo logró predecir proteína cruda con  $R^2$ : 0.72 y nRMSE = 11%, por lo tanto represento la mayor variación del modelo elaborado a partir de índices con RF. En consecuencia, los autores realizaron un ajuste al LSWI para establecer tendencia potencial (sumaron 1 al valor de la variable independiente, esto porque no puede tomar valores negativos y el LSWI se encontraba entre -1 a 1) estableciendo el  $R^2$ : 0.79. Este índice es susceptible de monitorear proteína cruda debido la sensibilidad de percibir alteraciones hídricas, lo cual limita el contenido de N por estrés (Zhao *et al.*, 2023).

Generar prototipos matemáticos en base a VANT también es posible, ello fue objeto de estudio para estimación de proteína cruda. Sin embargo, la transferencia de información de los modelos de VANT a S2 no fue favorable puesto que decreció la confiabilidad a pesar de contar con la resolución espectral similar. Las razones pueden ser varias, sin embargo, la sensibilidad espacial aumento y con ello la incertidumbre del modelo (Wolters *et al.*, 2022). La diferencia en la confiabilidad es originada por la corrección atmosférica, es de interés ahondar en la causa de tal fenómeno. La disminución del  $R^2$  puede atribuirse a la eliminación de información generada por la interacción de los compuestos con la radiación. Sin embargo, el ajuste puede considerarlo ruido meteorológico. En cambio, al comparar estimaciones de proteína cruda bajo diferentes métodos resulto en menor precisión a nivel macroscópico con S2 ( $R^2$ : 0.62), en contraparte la determinación mediante espectrofotómetro en laboratorio ( $R^2$ : 0.73) fue superior también a espectrofotómetro a nivel campo ( $R^2$ : 0.64). La banda cuatro, la región borde rojo (resaltando la banda cinco) y SWIR tuvieron el mayor impacto en la determinación de proteína cruda bajo las tres técnicas de estimación. El trabajo fue realizado en pastizales, los autores mencionan que la diversidad de especies dificulta la homogeneidad de los datos y, por ende, la precisión decrece. En consideración, replicar la metodología en monocultivo puede eficientizar el

contenido de proteína cruda en predios de interés (Fernández-Habas *et al.*, 2021).

Estimar el N en hojas de manglares mediante XGBoost demostró coherencia entre las estaciones de primavera-verano-invierno ( $R^2$ : 0.66, 0.74, y 0.70), además se encontró relación inversa entre C y N, el aumento de C disminuyó el N, el N y P incrementaron en conjunto. La sinergia entre N y P resulta de la necesidad de estos elementos para la fijación de C, las proteasas requieren de la replicación de ácido nucleico para ser formadas. El índice de clorofila verde (CIgreen), la banda seis y 11 arrojaron las mejores correlaciones (todas negativas) con el contenido de N en orden estacional, mientras tanto, la puntuación de importancia de las variables del modelo XGBoost estableció diferentes bandas e índices para cada estación, sin embargo, la banda 8 y 11 resaltan junto a los índices MCARI/OSAVI y índice de bosques de manglares (MFI) (Miao *et al.*, 2022). Mapear la relación N/P en los cultivos permite ahondar en la dinámica de nutrición, se desarrolló un modelo en sinergia entre las bandas multiespectrales e índices. La banda 9 y 12, además del índice de clorofila de borde rojo (RECI2 por sus siglas en inglés) contribuyeron significativamente. Emplear las bandas junto a índices

incrementó el coeficiente de determinación en 0.04 unidades y aminoró el RMSE 0.03, sin embargo, el número de variables predictores fue de 10 frente a 5 en bandas optimizadas. Lo anterior vuelve complejo el modelo que no se refleja en mejoría notoria (Gao *et al.*, 2020). En otro estudio se calcularon 60 índices a partir de bandas del S2, Sentinel-3 y L8 por separado. El índice de tres bandas (TB) generado con S2 demostró mayor acierto respecto a la relación N/P y N, ambos contenidos en el dosel, sin embargo, no dista considerablemente la confiabilidad. Al TB le competen las longitudes de onda con 434 nm, 496 nm y 401 nm. Estas son caracterizadas por covariar con la concentración de clorofila en las plantas, por ello este índice es idóneo de emplear. La región del azul parece representar un rol importante en la variable respuesta (Loozen *et al.*, 2019).

El N es el elemento más estudiado en la percepción remota, sin embargo, hay trabajos en otros como el P, K, C, calcio (Ca) y magnesio (Mg). El alcance de este tema es cubrir el N, no obstante, se considera apropiado agregar la información resultante de otros elementos químicos de forma breve como se observa en la literatura que fue revisada, ello se examina en la Tabla 2.

Tabla 2. Antecedentes de elementos químicos observados mediante S2.

Elemento químico observado	Técnica de análisis de datos	Precisión del análisis estadístico	Comentarios	Fuente
P	RF	$R^2$ : 0.70 y RMSE: 10.68	Se estimó el contenido de P en suelo, S2 obtuvo confiabilidad inferior en comparación a satélite hiperespectral Zhangheng-1, se emplearon bandas e índices.	(Zhang <i>et al.</i> , 2023b)
P K	SVMr SVMr	$R^2$ : 0.72 $R^2$ : 0.88	Se modeló el contenido de P y K en suelo. La adición de textura mejoró el modelo para estimación de P en 0.08 unidades del $R^2$ . Respecto a K, agregar el contenido de limo, arcilla y materia orgánica del suelo al modelo incremento la predicción en 0.11 unidades del $R^2$ . Modelos generados a partir de L8 fueron superiores en predicción en ambos elementos.	(Sahabiev <i>et al.</i> , 2021)
P	RL	$R^2$ : 0.64	Se empleó el índice de tres bandas (TB1 por sus siglas en inglés) para predicción de P en dosel.	(Loozen <i>et al.</i> , 2019).
C P	PLSR	$R^2$ : 0.88 $R^2$ : 0.85	La fusión de datos meteorológicos junto a bandas multiespectrales produjo un incremento notorio en comparación al espectro crudo del S2 en pastizales. La confiabilidad aumento en 0.14 y 0.18 respectivamente. La banda 12 y el RHI fueron de mayor importancia en ambas variables de respuesta.	(Pang <i>et al.</i> , 2022).

Elemento químico observado	Técnica de análisis de datos	Precisión del análisis estadístico	Comentarios	Fuente
C P	XGBoost	R <sup>2</sup> : 0.65, 0.79, y 0.82 R <sup>2</sup> : 0.539, 0.622, y 0.596 en orden para primavera, verano e invierno para ambos elementos.	Estimar mediante el C en hojas de manglares demostró aumento sucesivo en confiabilidad entre las estaciones de primavera-verano-invierno respectivamente). Para P el modelo fue mejor en verano (0.62). Se determinó relación inversa entre el incremento de C y el aminoramiento de P.	(Miao <i>et al.</i> , 2022).
% C % P % Ca % Mg	GB	R <sup>2</sup> : 0.97, 0.84, 0.98 y 0.95 respectivamente.	Se generaron los modelos de predicción de elementos en suelo a partir de bandas crudas del S2.	(Dhiman <i>et al.</i> , 2023).

CONCLUSIÓN

La percepción remota es una herramienta que coadyuva en el manejo adecuado de la producción agrícola mostrando alta confiabilidad. El S2 dispone de imágenes multispectrales y de acceso abierto con información en espera de ser interpretada. Es necesario procesar las imágenes satelitales para obtener información del cultivo. Así, se toman decisiones en base a datos de carácter preventivo o correctivo respecto al manejo del cultivo. Las sustancias que forman parte de la estructura global de las plantas reflejan y/o absorben REM, al interpretarse adecuadamente se obtiene información para determinar la ocurrencia de fenómenos de interés en torno a la SA. Con la AP se aminoran costos al reducir perdidas por estrés del cultivo y aumenta la eficiencia de los recursos.

Acknowledgements

The authors thank the Postgraduate Department of the Facultad de Agricultura y Zootecnia of the Universidad Juárez del Estado de Durango.

**Funding.** This research was developed through a master degree scholarship supported by CONACYT with cvu number 1153259 to the first author.

**Conflict of Interest.** The authors declare that they do not have conflicts of interest.

**Compliance with ethical standards.** Does not apply.

**Data availability:** Data are available with E.O. Rueda-Puente and A.D. Lugo-Palacios.

**Author contribution statement (CRediT).** **A.D. Lugo-Palacios** – Conceptualization, Writing – original draft; **R.E. Lugo-Palacios** – Methodology, Software; **J.L. García-Hernández** – Resources, Supervision; **D.A.**

**Zúñiga-Gracia** – Visualization, Validation; **E.O. Rueda-Puente** – Project administration, Writing – review and editing.

REFERENCES

Ali, A.M., Darvishzadeh, R., Skidmore, A., Heurich, M., Paganini, M., Heiden, U. and Mücher, S., 2020. Evaluating Prediction Models for Mapping Canopy Chlorophyll Content Across Biomes. *Remote Sensing*, 12(11), pp.1–22. <https://doi.org/10.3390/rs12111788>

Amankulova, K., Farmonov, N., Mukhtorov, U. and Mucsi, L., 2023. Sunflower crop yield prediction by advanced statistical modeling using satellite-derived vegetation indices and crop phenology. *Geocarto International*, 38(1), pp.1–20. <https://doi.org/10.1080/10106049.2023.2197509>

Bannari, A., El-Battay, A., Bannari, R. and Rhinane, H., 2018. Sentinel-MSI VNIR and SWIR Bands Sensitivity Analysis for Soil Salinity Discrimination in an Arid Landscape. *Remote Sensing*, 10(6), pp.1–20. <https://doi.org/10.3390/rs10060855>

Battista, P., Bellini, E., Chiesi, M., Costafreda-Aumedes, S., Fibbi, L., Leolini, L., Moriondo, M., Rapi, B., Rossi, R., Sabatini, F. and Maselli, F., 2023. Estimating the effect of water shortage on olive trees by the combination of meteorological and Sentinel-2 data. *European Journal of Remote Sensing*, 56(1), pp.1–10. <https://doi.org/10.1080/22797254.2023.2194553>

- Bellvert, J., Pelechá, A., Pamies-Sans, M., Virgili, J., Torres, M. and Casadesús, J., 2023. Assimilation of Sentinel-2 Biophysical Variables into a Digital Twin for the Automated Irrigation Scheduling of a Vineyard. *Water*, 15(14), pp.1–23. <https://doi.org/10.3390/w15142506>
- Berger, K., Verrelst, J., Féret, J.-B., Wang, Z., Woher, M., Strathmann, M., Danner, M., Mauser, W. and Hank, T., 2020. Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions. *Remote Sensing of Environment*, 242, pp.1–44. <https://doi.org/10.1016/j.rse.2020.111758>
- Blonda, P., Tarantino, C., Scortichini, M., Maggi, S., Tarantino, M. and Adamo, M., 2023. Satellite monitoring of bio-fertilizer restoration in olive groves affected by *Xylella fastidiosa* subsp. *pauca*. *Scientific Reports*, 13(1), pp.1–20. <https://doi.org/10.1038/s41598-023-32170-x>
- Bossung, C., Schlerf, M. and Machwitz, M., 2022. Estimation of canopy nitrogen content in winter wheat from Sentinel-2 images for operational agricultural monitoring. *Precision Agriculture*, 23(6), pp.2229–2252. <https://doi.org/10.1007/s11119-022-09918-y>
- Buchaillot, M.L., Cairns, J., Hamadziripi, E., Wilson, K., Hughes, D., Chelal, J., McCloskey, P., Kehs, A., Clinton, N., Araus, J.L. and Kefauver, S.C., 2022. Regional Monitoring of Fall Armyworm (FAW) Using Early Warning Systems. *Remote Sensing*, 14(19), pp.1–19. <https://doi.org/10.3390/rs14195003>
- Carter, G.A., 1991. Primary and Secondary Effects of Water Content on the Spectral Reflectance of Leaves. *American Journal of Botany*, 78(7), pp.916–924. <https://doi.org/10.1002/j.1537-2197.1991.tb14495.x>
- Casella, A., Orden, L., Pezzola, N.A., Bellacomo, C., Winschel, C.I., Caballero, G.R., Delegido, J., Gracia, L.M.N. and Verrelst, J., 2022. Analysis of Biophysical Variables in an Onion Crop (*Allium cepa* L.) with Nitrogen Fertilization by Sentinel-2 Observations. *Agronomy*, 12(8), pp.1–17. <https://doi.org/10.3390/agronomy12081884>
- Castelli, M., Peratoner, G., Pasolli, L., Molisse, G., Dovas, A., Sicher, G., Crespi, A., Rossi, M., Alasawedah, M.H., Soini, E., Monsorno, R. and Notarnicola, C., 2023. Insuring Alpine Grasslands against Drought-Related Yield Losses Using Sentinel-2 Satellite Data. *Remote Sensing*, 15(14), pp.1–27. <https://doi.org/10.3390/rs15143542>
- Cisneros, A., Fiorio, P., Menezes, P., Pasqualotto, N., Van Wittenberghe, S., Bayma, G. and Furlan Nogueira, S., 2020. Mapping Productivity and Essential Biophysical Parameters of Cultivated Tropical Grasslands from Sentinel-2 Imagery. *Agronomy*, 10(5), pp.1–23. <https://doi.org/10.3390/agronomy10050711>
- Crema, A., Boschetti, M., Nutini, F., Cillis, D. and Casa, R., 2020. Influence of Soil Properties on Maize and Wheat Nitrogen Status Assessment from Sentinel-2 Data. *Remote Sensing*, 12(14), pp.1–23. <https://doi.org/10.3390/rs12142175>
- Cui, B., Zhao, Q., Huang, W., Song, X., Ye, H. and Zhou, X., 2019. Leaf chlorophyll content retrieval of wheat by simulated RapidEye, Sentinel-2 and EnMAP data. *Journal of Integrative Agriculture*, 18(6), pp.1230–1245. [https://doi.org/10.1016/S2095-3119\(18\)62093-3](https://doi.org/10.1016/S2095-3119(18)62093-3)
- Dehghan-Shoar, M.H., Pullanagari, R.R., Kereszturi, G., Orsi, A.A., Yule, I.J. and Hanly, J., 2023. A Unified Physically Based Method for Monitoring Grassland Nitrogen Concentration with Landsat 7, Landsat 8, and Sentinel-2 Satellite Data. *Remote Sensing*, 15(10), pp.1–21. <https://doi.org/10.3390/rs15102491>
- Dhiman, G., Bhattacharya, J. and Roy, S., 2023. Soil textures and nutrients estimation using remote sensing data in north india - Punjab region. *Procedia Computer Science*, 218, pp.2041–2048. <https://doi.org/10.1016/j.procs.2023.01.180>
- Eisberg, R.M. and Resnick, R., 1985. *Quantum Physics of Atoms, Molecules, Solids, Nuclei, and Particles*. Wiley.
- Fernández-Habas, J., García Moreno, A.M., Hidalgo-Fernández, M.T., Leal-Murillo, J.R., Abellanas Oar, B., Gómez-Giráldez, P.J., González-Dugo, M.P. and Fernández-Rebollo, P., 2021. Investigating the potential of Sentinel-2 configuration to predict the quality of Mediterranean permanent grasslands in open woodlands. *Science of The Total Environment*, 791, pp.1–19. <https://doi.org/10.1016/j.scitotenv.2021.148101>
- Filintas, A., Nteskou, A., Kourgialas, N., Gougoulas, N. and Hatzichristou, E., 2022. A Comparison between Variable Deficit Irrigation and



- Farmers' Irrigation Practices under Three Fertilization Levels in Cotton Yield (*Gossypium hirsutum* L.) Using Precision Agriculture, Remote Sensing, Soil Analyses, and Crop Growth Modeling. *Water*, 14(17), pp.1–34. <https://doi.org/10.3390/w14172654>
- French, A.N., Sanchez, C.A., Wirth, T., Scott, A., Shields, J.W., Bautista, E., Saber, M.N., Wisniewski, E. and Gohardoust, M.R., 2023. Remote sensing of evapotranspiration for irrigated crops at Yuma, Arizona, USA. *Agricultural Water Management*, 290, pp.1–18. <https://doi.org/10.1016/j.agwat.2023.108582>
- Gao, J., Liu, J., Liang, T., Hou, M., Ge, J., Feng, Q., Wu, C. and Li, W., 2020. Mapping the Forage Nitrogen-Phosphorus Ratio Based on Sentinel-2 MSI Data and a Random Forest Algorithm in an Alpine Grassland Ecosystem of the Tibetan Plateau. *Remote Sensing*, 12(18), pp.1–19. <https://doi.org/10.3390/rs12182929>
- Gitelson, A.A., Merzlyak, M.N. and Chivkunova, O.B., 2001. Optical properties and nondestructive estimation of anthocyanin content in plant leaves. *Photochemistry and Photobiology*, 74(1), pp.38–45. [https://doi.org/10.1562/0031-8655\(2001\)074<0038:opaneo>2.0.co;2](https://doi.org/10.1562/0031-8655(2001)074<0038:opaneo>2.0.co;2)
- Gogoi, J., Newlands, N.K., Mehrabi, Z., Coops, N.C. and Ramankutty, N., 2023. Assessing the Performance of Satellite-Based Models for Crop Yield Estimation in the Canadian Prairies. *Canadian Journal of Remote Sensing*, 49(1), pp.1–29. <https://doi.org/10.1080/07038992.2023.2252926>
- Gómez-Flores, J.L., Ramos-Rodríguez, M., González-Jiménez, A., Farzamian, M., Herencia.Galán, J.F., Salvatierra-Bellido, B., Cermeño-Sacristan, P. and Vanderlinden, K., 2022. Depth-Specific Soil Electrical Conductivity and NDVI Elucidate Salinity Effects on Crop Development in Reclaimed Marsh Soils. *Remote Sensing*, 14(14), pp.1–20. <https://doi.org/10.3390/rs14143389>
- Gopalakrishnan, T. and Kumar, L., 2020. Modeling and Mapping of Soil Salinity and its Impact on Paddy Lands in Jaffna Peninsula, Sri Lanka. *Sustainability*, 12(20), pp.1–15. <https://doi.org/10.3390/su12208317>
- Hassani, K., Gholizadeh, H., Taghvaeian, S., Natalie, V., Carpenter, J. and Jacob, J., 2023. Assessing the impact of spatial resolution of UAS-based remote sensing and spectral resolution of proximal sensing on crop nitrogen retrieval accuracy. *International Journal of Remote Sensing*, 44(14), pp.4441–4464. <https://doi.org/10.1080/01431161.2023.2237162>
- Iatrou, M., Karydas, C., Iatrou, G., Pitsiorlas, I., Aschonitis, V., Raptis, I., Mpetas, S., Kravvas, K. and Mourelatos, S., 2021. Topdressing Nitrogen Demand Prediction in Rice Crop Using Machine Learning Systems. *Agriculture*, 11(4), pp.1–17. <https://doi.org/10.3390/agriculture11040312>
- Kang, Y., Gao, F., Anderson, M., Kustas, W., Nieto, H., Knipper, K., Yang, Y., White, W., Alfieri, J., Torres-Rua, A., Alsina, M.M. and Karnieli, A., 2022. Evaluation of satellite Leaf Area Index in California vineyards for improving water use estimation. *Irrigation Science*, 40(4), pp.531–551. <https://doi.org/10.1007/s00271-022-00798-8>
- Kganyago, M., Adjorlolo, C., Sibanda, M., Mhangara, P., Laneve, G. and Alexandridis, T., 2023a. Testing Sentinel-2 spectral configurations for estimating relevant crop biophysical and biochemical parameters for precision agriculture using tree-based and kernel-based algorithms. *Geocarto International*, 38(1), pp.1–25. <https://doi.org/10.1080/10106049.2022.2146764>
- Kganyago, M., Ovakoglou, G., Mhangara, P., Adjorlolo, C., Alexandridis, T., Laneve, G. and Beltran, J.S., 2023b. Evaluating the contribution of Sentinel-2 view and illumination geometry to the accuracy of retrieving essential crop parameters. *GIScience & Remote Sensing*, 60(1), pp.1–20. <https://doi.org/10.1080/15481603.2022.2163046>
- Li, Z., Zhang, F., Chen, L., Zhang, H., and Hsiang-Te-Kung, 2018. Research on the Estimation Model of Vegetation Water Content in Halophyte Leaves Based on the Newly Developed Vegetation Indices. *Photogrammetric Engineering & Remote Sensing*, 84(9), pp.538–548. <https://doi.org/10.14358/PERS.84.9.537>



- Lin, Y., Zhu, Z., Guo, W., Sun, Y., Yang, X. and Kovalskyy, V., 2020. Continuous Monitoring of Cotton Stem Water Potential using Sentinel-2 Imagery. *Remote Sensing*, 12(7), pp.1–18. <https://doi.org/10.3390/rs12071176>
- Loozen, Y., Karssenbergh, D., de Jong, S.M., Wang, S., van Dijk, J., Wassen, M.J. and Rebel, K.T., 2019. Exploring the use of vegetation indices to sense canopy nitrogen to phosphorous ratio in grasses. *International Journal of Applied Earth Observation and Geoinformation*, 75, pp.1–14. <https://doi.org/10.1016/j.jag.2018.08.012>
- Lugassi, R., Goldshleger, N. and Chudnovsky, A., 2017. Studying Vegetation Salinity: From the Field View to a Satellite-Based Perspective. *Remote Sensing*, 9(2), pp.1–16. <https://doi.org/10.3390/rs9020122>
- Marino, S., 2023. Understanding the spatio-temporal behavior of crop yield, yield components and weed pressure using time series Sentinel-2-data in an organic farming system. *European Journal of Agronomy*, 145, pp.1–10. <https://doi.org/10.1016/j.eja.2023.126785>
- Mashaba-Munghemezulu, Z., Chirima, G.J. and Munghemezulu, C., 2021. Modeling the Spatial Distribution of Soil Nitrogen Content at Smallholder Maize Farms Using Machine Learning Regression and Sentinel-2 Data. *Sustainability*, 13(21), pp.1–21. <https://doi.org/10.3390/su132111591>
- Merzlyak, M.N., Solovchenko, A.E. and Gitelson, A.A., 2003. Reflectance spectral features and non-destructive estimation of chlorophyll, carotenoid and anthocyanin content in apple fruit. *Postharvest Biology and Technology*, 27(2), pp.197–211. [https://doi.org/10.1016/S0925-5214\(02\)00066-2](https://doi.org/10.1016/S0925-5214(02)00066-2)
- Mezera, J., Lukas, V., Horniaček, I., Smutný, V. and Elbl, J., 2022. Comparison of Proximal and Remote Sensing for the Diagnosis of Crop Status in Site-Specific Crop Management. *Sensors*, 22(1), pp.1–23. <https://doi.org/10.3390/s22010019>
- Miao, J., Zhen, J., Wang, J., Zhao, D., Jiang, X., Shen, Z., Gao, C. and Wu, G., 2022. Mapping Seasonal Leaf Nutrients of Mangrove with Sentinel-2 Images and XGBoost Method. *Remote Sensing*, 14(15), pp.1–23. <https://doi.org/10.3390/rs14153679>
- Moussa, I., Walter, C., Michot, D., Adam Boukary, I., Nicolas, H., Pichelin, P. and Guéro, Y., 2020. Soil Salinity Assessment in Irrigated Paddy Fields of the Niger Valley Using a Four-Year Time Series of Sentinel-2 Satellite Images. *Remote Sensing*, 12(20), pp.1–17. <https://doi.org/10.3390/rs12203399>
- Naimi, S., Ayoubi, S., Zeraatpisheh, M. and Dematte, J.A.M., 2021. Ground Observations and Environmental Covariates Integration for Mapping of Soil Salinity: A Machine Learning-Based Approach. *Remote Sensing*, 13(23), pp.1–21. <https://doi.org/10.3390/rs13234825>
- Ollinger, S.V., 2011. Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, 189(2), pp.375–394. <https://doi.org/10.1111/j.1469-8137.2010.03536.x>
- Ollinger, S.V., Richardson, A.D., Martin, M.E., Hollinger, D.Y., Frolking, S.E., Reich, P.B., Plourde, L.C., Katul, G.G., Munger, J.W., Oren, R., Smith, M.-L., Paw U, K.T., Bolstad, P.V., Cook, B.D., Day, M.C., Martin, T.A., Monson, R.K. and Schmid, H.P., 2008. Canopy nitrogen, carbon assimilation, and albedo in temperate and boreal forests: Functional relations and potential climate feedbacks. *Proceedings of the National Academy of Sciences*, 105(49), pp.19336–19341. <https://doi.org/10.1073/pnas.0810021105>
- Olsen, E.D., 1990. *Métodos ópticos de análisis*. Barcelona: Reverte.
- Page, M.J., McKenzie, J.E., Bossuyt, P.M., Boutron, I., Hoffmann, T.C., Mulrow, C.D., Shamseer, L., Tetzlaff, J.M., Akl, E.A., Brennan, S.E., Chou, R., Glanville, J., Grimshaw, J.M., Hróbjartsson, A., Lalu, M.M., Li, T., Loder, E.W., Mayo-Wilson, E., McDonald, S., McGuinness, L.A., Stewart, L.A., Thomas, J., Tricco, A.C., Welch, V.A., Whiting, P., Moher, D., Yepes-Núñez, J.J., Urrutia, G., Romero-García, M. and Alonso-Fernández, S., 2021. Declaración PRISMA 2020: una guía actualizada para la publicación de revisiones sistemáticas. *Revista Española de Cardiología*, 74(9), pp.790–799. <https://doi.org/10.1016/j.recesp.2021.06.016>
- Pang, H., Zhang, A., Yin, S., Zhang, J., Dong, G., He, N., Qin, W. and Wei, D., 2022. Estimating Carbon, Nitrogen, and Phosphorus Contents of West-East Grassland Transect in Inner

- Mongolia Based on Sentinel-2 and Meteorological Data. *Remote Sensing*, 14(2), pp.1–25. <https://doi.org/10.3390/rs14020242>
- Qi, G., Chang, C., Yang, W., Gao, P. and Zhao, G., 2021. Soil Salinity Inversion in Coastal Corn Planting Areas by the Satellite-UAV-Ground Integration Approach. *Remote Sensing*, 13(16), pp.1–17. <https://doi.org/10.3390/rs13163100>
- Qian, X., Qi, H., Shang, S., Wan, H. and Wang, R., 2022. Multi-year mapping of flood autumn irrigation extent and timing in harvested croplands of arid irrigation district. *GIScience & Remote Sensing*, 59(1), pp.1598–1623. <https://doi.org/10.1080/15481603.2022.2126342>
- Rafik, A., Ibouh, H., El Alaoui El Fels, A., Eddahby, L., Mezzane, D., Bousfoul, M., Amazirh, A., Ouhamdouch, S., Bahir, M., Gourfi, A., Dhiba, D. and Chehbouni, A., 2022. Soil Salinity Detection and Mapping in an Environment under Water Stress between 1984 and 2018 (Case of the Largest Oasis in Africa-Morocco). *Remote Sensing*, 14(7), pp.1–17. <https://doi.org/10.3390/rs14071606>
- Rossi, M., Candiani, G., Nutini, F., Gianinetto, M. and Boschetti, M., 2023. Sentinel-2 estimation of CNC and LAI in rice cropping system through hybrid approach modelling. *European Journal of Remote Sensing*, 56(1), pp.1–20. <https://doi.org/10.1080/22797254.2022.2117651>
- Sahabiev, I., Smirnova, E. and Giniyatullin, K., 2021. Spatial Prediction of Agrochemical Properties on the Scale of a Single Field Using Machine Learning Methods Based on Remote Sensing Data. *Agronomy*, 11(11), pp.1–16. <https://doi.org/10.3390/agronomy11112266>
- Segarra, J., Rezzouk, F.Z., Aparicio, N., González-Torralba, J., Aranjuelo, I., Gracia-Romero, A., Araus, J.L. and Kefauver, S.C., 2023. Multiscale assessment of ground, aerial and satellite spectral data for monitoring wheat grain nitrogen content. *Information Processing in Agriculture*, 10(4), pp.504–522. <https://doi.org/10.1016/j.inpa.2022.05.004>
- Söderström, M., Piikki, K., Stenberg, M., Stadig, H. and Martinsson, J., 2017. Producing nitrogen (N) uptake maps in winter wheat by combining proximal crop measurements with Sentinel-2 and DMC satellite images in a decision support system for farmers. *Acta Agriculturae Scandinavica, Section B — Soil & Plant Science*, 67(7), pp.637–650. <https://doi.org/10.1080/09064710.2017.1324044>
- Song, Y., Ye, M., Zheng, Z., Zhan, D., Duan, W., Lu, M., Song, Z., Sun, D., Yao, K. and Ding, Z., 2023. Tree-Structured Parzan Estimator–Machine Learning–Ordinary Kriging: An Integration Method for Soil Ammonia Spatial Prediction in the Typical Cropland of Chinese Yellow River Delta with Sentinel-2 Remote Sensing Image and Air Quality Data. *Remote Sensing*, 15(17), pp.1–21. <https://doi.org/10.3390/rs15174268>
- SUHET, 2015. *Sentinel-2 User Handbook*. [online] Sentinel Online. Available at: [https://copernicus.eu/user-guides/document-library/-/asset\\_publisher/xslst4309D5h/content/sentinel-2-user-handbook](https://copernicus.eu/user-guides/document-library/-/asset_publisher/xslst4309D5h/content/sentinel-2-user-handbook) [Accessed 2 February 2024].
- Swinburn, B.A., Kraak, V.I., Allender, S., Atkins, V.J., Baker, P.I., Bogard, J.R., Brinsden, H., Calvillo, A., De Schutter, O., Devarajan, R., Ezzati, M., Friel, S., Goenka, S., Hammond, R.A., Hastings, G., Hawkes, C., Herrero, M., Hovmand, P.S., Howden, M., Jaacks, L.M., Kapetanaki, A.B., Kasman, M., Kuhnlein, H.V., Kumanyika, S.K., Larijani, B., Lobstein, T., Long, M.W., Matsudo, V.K.R., Mills, S.D.H., Morgan, G., Morshed, A., Nece, P.M., Pan, A., Patterson, D.W., Sacks, G., Shekar, M., Simmons, G.L., Smit, W., Tootee, A., Vandevijvere, S., Waterlander, W.E., Wolfenden, L. and Dietz, W.H., 2019. The Global Syndemic of Obesity, Undernutrition, and Climate Change: The Lancet Commission report. *Lancet* (London, England), 393(10173), pp.791–846. [https://doi.org/10.1016/S0140-6736\(18\)32822-8](https://doi.org/10.1016/S0140-6736(18)32822-8)
- Taghadosi, M.M., Hasanlou, M. and Eftekhari, K., 2019. Retrieval of soil salinity from Sentinel-2 multispectral imagery. *European Journal of Remote Sensing*, 52(1), pp.138–154. <https://doi.org/10.1080/22797254.2019.1571870>
- Ustin, S.L. and Jacquemoud, S., 2020. How the Optical Properties of Leaves Modify the Absorption and Scattering of Energy and Enhance Leaf Functionality. In: J. Cavender-Bares, J.A. Gamon and P.A. Townsend, eds. *Remote Sensing of Plant Biodiversity*. [online] Cham: Springer International Publishing. pp.349–

384. [https://doi.org/10.1007/978-3-030-33157-3\\_14](https://doi.org/10.1007/978-3-030-33157-3_14)
- Wang, J., Peng, J., Li, H., Yin, C., Liu, W., Wang, T. and Zhang, H., 2021. Soil Salinity Mapping Using Machine Learning Algorithms with the Sentinel-2 MSI in Arid Areas, China. *Remote Sensing*, 13(2), pp.1–14. <https://doi.org/10.3390/rs13020305>
- Willett, W., Rockström, J., Loken, B., Springmann, M., Lang, T., Vermeulen, S., Garnett, T., Tilman, D., DeClerck, F., Wood, A., Jonell, M., Clark, M., Gordon, L.J., Fanzo, J., Hawkes, C., Zurayk, R., Rivera, J.A., Vries, W.D., Sibanda, L.M., Afshin, A., Chaudhary, A., Herrero, M., Agustina, R., Branca, F., Lartey, A., Fan, S., Crona, B., Fox, E., Bignet, V., Troell, M., Lindahl, T., Singh, S., Cornell, S.E., Reddy, K.S., Narain, S., Nishtar, S. and Murray, C.J.L., 2019. Food in the Anthropocene: the EAT–Lancet Commission on healthy diets from sustainable food systems. *The Lancet*, 393(10170), pp.447–492. [https://doi.org/10.1016/S0140-6736\(18\)31788-4](https://doi.org/10.1016/S0140-6736(18)31788-4)
- Wolters, S., Söderström, M., Piikki, K., Börjesson, T. and Pettersson, C.-G., 2022. Predicting grain protein concentration in winter wheat (*Triticum aestivum* L.) based on unpiloted aerial vehicle multispectral optical remote sensing. *Acta Agriculturae Scandinavica, Section B — Soil & Plant Science*, 72(1), pp.788–802. <https://doi.org/10.1080/09064710.2022.2085165>
- Xing, N., Huang, W., Ye, H., Dong, Y., Kong, W., Ren, Y. and Xie, Q., 2022. Remote sensing retrieval of winter wheat leaf area index and canopy chlorophyll density at different growth stages. *Big Earth Data*, 6(4), pp.580–602. <https://doi.org/10.1080/20964471.2021.1918909>
- Zhang, Q., Liu, M., Zhang, Y., Mao, D., Li, F., Wu, F., Song, J., Li, X., Kou, C., Li, C. and Man, W., 2023a. Comparison of Machine Learning Methods for Predicting Soil Total Nitrogen Content Using Landsat-8, Sentinel-1, and Sentinel-2 Images. *Remote Sensing*, 15(11), pp.1–22. <https://doi.org/10.3390/rs15112907>
- Zhang, W., Zhu, L., Zhuang, Q., Chen, D. and Sun, T., 2023b. Mapping Cropland Soil Nutrients Contents Based on Multi-Spectral Remote Sensing and Machine Learning. *Agriculture*, 13(8), pp.1–19. <https://doi.org/10.3390/agriculture13081592>
- Zhao, H., Song, X., Yang, G., Li, Z., Zhang, D. and Feng, H., 2019. Monitoring of Nitrogen and Grain Protein Content in Winter Wheat Based on Sentinel-2A Data. *Remote Sensing*, 11(14), pp.1–25. <https://doi.org/10.3390/rs11141724>
- Zhao, X., Wu, B., Xue, J., Shi, Y., Zhao, M., Geng, X., Yan, Z., Shen, H. and Fang, J., 2023. Mapping Forage Biomass and Quality of the Inner Mongolia Grasslands by Combining Field Measurements and Sentinel-2 Observations. *Remote Sensing*, 15(8), pp.1–17. <https://doi.org/10.3390/rs15081973>
- Zhao, Y., Potgieter, A.B., Zhang, M., Wu, B. and Hammer, G.L., 2020. Predicting Wheat Yield at the Field Scale by Combining High-Resolution Sentinel-2 Satellite Imagery and Crop Modelling. *Remote Sensing*, 12(6), pp.1–20. <https://doi.org/10.3390/rs12061024>
- Zsigmond, T., Braun, P., Mészáros, J., Waltner, I. and Horel, Á., 2022. Investigating Plant Response to Soil Characteristics and Slope Positions in a Small Catchment. *Land*, 11(6), pp.1–18. <https://doi.org/10.3390/land11060774>