

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

SUBDIRECCIÓN DE POSTGRADO



DETECCIÓN DEL ESTRÉS HÍDRICO EN CULTIVO DE FRIJOL (*Phaseolus Vulgaris* L.) UTILIZANDO IMÁGENES MULTIESPECTRALES Y SENSORES DE HUMEDAD DEL SUELO

Que presenta:

NESTOR MAGDALENO MONTOYA PINEDA
como requisito parcial para obtener el Grado de
MAESTRO EN CIENCIAS EN INGENIERÍA DE SISTEMAS DE PRODUCCIÓN

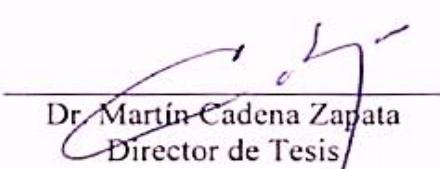
Saltillo, Coahuila

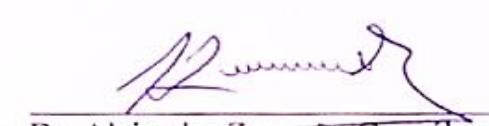
Julio 2024

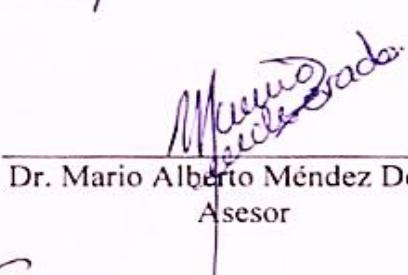
DETECCIÓN DEL ESTRÉS HÍDRICO EN CULTIVO DE FRIJOL (*Phaseolus Vulgaris L.*) UTILIZANDO IMÁGENES MULTIESPECTRALES Y SENSORES DE HUMEDAD DEL SUELO

TESIS

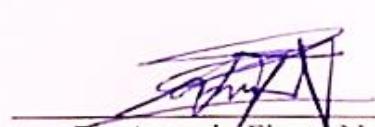
Elaborada por NESTOR MAGDALENO MONTOYA PINEDA Como requisito parcial para obtener el grado de MAESTRO EN CIENCIAS EN INGENIERÍA DE SISTEMAS DE PRODUCCIÓN con la supervisión y aprobación del Comité de Asesoría


Dr. Martín Cadena Zapata
Director de Tesis


Dr. Alejandro Zermeno González
Asesor


Dr. Mario Alberto Méndez Dorado
Asesor


M.C. Andrés Cadena Díaz
Asesor


Dr. Antonio Flores Naveda
Subdirector de Postgrado

UAAAN

AGRADECIMIENTOS

Agradezco a la UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO y a su DEPARTAMENTO DE POSTGRADO por darme la oportunidad de cursar el posgrado MAESTRÍA EN CIENCIAS EN INGENIERÍA DE SISTEMAS DE PRODUCCIÓN. También agradezco el apoyo del CONAHCYT, pues gracias a la beca obtenida por la institución pude desarrollarme académicamente y pude culminar con la meta propuesta.

Al Departamento de Maquinaria Agrícola y al Departamento de Riego y Drenaje, que me apoyaron con los materiales, equipos e instalaciones indispensables para la realización de la presente investigación.

Por último, deseo expresar mi agradecimiento al comité de asesoría, compuesto por el Dr. Marín Cadena Zapata, el Dr. Alejandro Zermeño González, el Dr. Mario Alberto Méndez Dorado y el M.C. Andrés Cadena Díaz. Sus enseñanzas y consejos son invaluables para mí.

DEDICATORIA

A mi adorada hija, **Regina Stephanie Montoya Chávez**, quien es la razón de todos mis logros.

ÍNDICE GENERAL

AGRADECIMIENTOS	3
DEDICATORIA.....	4
ÍNDICE GENERAL	5
ÍNDICE DE FIGURAS.....	7
ÍNDICE DE TABLAS.....	15
RESUMEN.....	13
INTRODUCCIÓN	1
HIPÓTESIS.....	3
OBJETIVO GENERAL	3
OBJETIVOS ESPECÍFICOS	3
REVISIÓN DE LITERATURA.....	4
Importancia del Agua en México	4
Sistemas de Riego y su Evolución.....	4
Huella Hídrica en la Agricultura	5
Cultivo de Frijol	6
Taxonomía	7
Morfología	7
Requerimientos Agronómicos.....	8
Necesidades Hídricas	8
Regiones con Mayor Producción de Frijol en México.....	9
ESTRÉS HÍDRICO	10
Estrés Hídrico en Frijol	10
Pérdidas Económicas	11
Tecnologías Implementadas en Frijol para Monitoreo del Estrés Hídrico.....	11
AGRICULTURA DE PRECISIÓN.....	13
Usos de Drones en Agricultura	14
Tipos de Drones	15
Multi Rotor.....	16
Ala Fija.....	17
TELEDETECCIÓN	18
Espectro Electromagnético de la Radiación Solar	19
Uso de Dron para Obtención de Imágenes.....	20
IMÁGENES DIGITALES	21
Procesamiento de Imágenes	21

Tipos de Resoluciones	22
Resolución Espacial	23
Resolución Espectral	23
Resolución Radiométrica	24
Resolución Temporal	25
TIPOS DE SENSORES	27
RGB	27
Térmicos	27
Multiespectrales	28
Hiperespectrales	29
ÍNDICES DE VEGETACIÓN	30
NDVI (Índice de Vegetación de Diferencia Normalizada)	30
BNDVI (Índice de Vegetación de Diferencia Normalizada Azul)	31
GNDVI (Índice de Vegetación de Diferencia Normalizada Verde)	32
NDRE (Diferencia Normalizada Borde Rojo)	33
SIPI2 (Índice de Pigmentos Intensivos de Estructura 2)	34
TGI (Índice de Verdor Triangular)	35
NDWI (Índice de Agua de Diferencia Normalizada)	36
MATERIALES Y MÉTODOS	37
Área de estudio	37
Manejo Agronómico del Cultivo y Tratamientos Evaluados	38
Tensión de Humedad del Suelo	39
Adquisición de Imágenes	40
Procesamiento de Imágenes Multiespectrales	40
Extracción de Regiones de Interés	41
Evaluación Estadística	41
RESULTADOS Y DISCUSIÓN	42
Variable de Respuesta Índice de Vegetación NDRE	42
Variable de Respuesta Índice de Vegetación TGI	43
Variable de Respuesta Índice de Vegetación NDWI	44
Variable de Respuesta Reflectancia Red Edge Band	45
Variable de Respuesta Reflectancia Red	46
CONCLUSIONES	47
REFERENCIAS	48

ÍNDICE DE FIGURAS

Figura 1. Proceso de la agrizzcultura de precisión con drones. Fuente: TYC GIS.....	14
Figura 2. (a) ala fija, (b) híbrido de ala fija, (c) de un solo rotor y (d) UAV multirotor. (Mohsan et al., 2022).	16
Figura 3. Ejemplos de multirrotores con diferentes tipos de configuración de brazos. Fuente: (Guevara-Bonilla et al., 2020).....	16
Figura 4. Drones de ala Fija. Fuente: (Fabián Reuter & Amilcar Pedenov, 2019).....	17
Figura 5. Componentes de un sistema de teledetección espacial: (A) Fuente de energía. (B) Atmósfera. (C) Suelo. (D) Sensor. (E) Transmisión, y procesamiento. (F) Análisis. (G) Aplicación. Fuente: (Bustos, 2014)	19
Figura 6. Espectro electromagnético en toda su amplitud. Fuente: (Sierra Figueredo & Baca, 2014)	20
Figura 7. Conformación de pixeles en una imagen digital. Fuente: (Miranda, Miguel, 2009)	21
Figura 8. Comparación del tamaño de pixel de una imagen. Fuente: (Chucos Baquerizo & Vega Ventocilla, 2022)	23
Figura 9. comparación entre RGB, multiespectral e hiperespectral. Fuente: (F. Y. Belen, 2022).	24
Figura 10. Comparación en los niveles de grises o niveles digital (ND) de una imagen (UNESCO RAPCA).....	25
Figura 11. Ejemplos de imágenes satelitales. A) Imagen Landsat8: composición 5-6-4. Fuente: https://app.climateengine.org/climateEngine . B) Imagen Sentinel2: composición 8-11-4. Fuente: Composito Año 2019-2020 https://app.climateengine.org/climateEngine . C) Imagen ASTER: composición 3-2-1. Fuente: Año: 2017 https://gbank.gsj.jp/madas/map/index.html . D) Imagen "basemap": color natural RGB 1-2-3. Fuente: SASPlanet. Año 2019-2020.....	26
Figura 12. Mapa de ubicación del área de estudio.....	37
Figura 13. Relación entre el contenido de agua en el suelo y la tensión de humedad correspondiente del suelo del sitio de estudio.....	39
Figura 14. Equipo utilizado para el levantamiento de imágenes: (a) Cámara	

multiespectral; (b) Sensor solar (DLS 2); (c) RPA utilizado para el estudio.....	40
Figura 15. Descripción y distribución de los tratamientos en el campo evaluados.	41
Figura 16. Efecto de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para riego aplicada sobre el índice NDRE de un cultivo de frijol (cv. Flor de mayo).....	42
Figura 17. Efecto de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para riego aplicada sobre el índice TGI de un cultivo de frijol (cv.	43
Figura 18. Efecto de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para riego aplicada sobre el NDWI (valores absolutos) de un cultivo de frijol (cv Flor de mayo).	44
Figura 19. Interacción entre la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para el riego aplicada sobre la reflectancia de la Banda de Borde Rojo (miles) de un cultivo de frijol (cv Flor de mayo).	45
Figura 20. Interacción de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para el riego aplicada sobre la reflectancia de la Banda Roja (miles) de un cultivo de frijol (cv Flor de mayo).	46

ÍNDICE DE TABLAS

Cuadro 1. Distribución de volúmenes de agua concesionados para usos consuntivos en México, 2017.	¡Error! Marcador no definido.
Cuadro 2. Huella hídrica de diferentes cultivos.....	6
Cuadro 3. Factores principales de estudio y tratamientos correspondientes.	38

RESUMEN

DETECCIÓN DEL ESTRÉS HÍDRICO EN CULTIVO DE FRIJOL (*Phaseolus Vulgaris* L.) UTILIZANDO IMÁGENES MULTIESPECTRALES Y SENSORES DE HUMEDAD DEL SUELO

Por:

NESTOR MAGDALENO MONTOYA PINEDA

MAESTRÍA EN CIENCIAS EN INGENIERÍA DE SISTEMAS DE PRODUCCIÓN
UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

Asesor Principal

Dr. MARTIN CADENA ZAPATA

Saltillo, Coahuila,

Julio 2024

RESUMEN

El estrés hídrico puede tener efectos adversos en el rendimiento de los cultivos y alterar sus respuestas morfofisiológicas. Por lo tanto, la detección del estrés hídrico es crucial para mejorar la productividad y la calidad de los cultivos. Este estudio evalúa la eficacia de la teledetección utilizando sistemas aéreos no tripulados (UAS) equipados con sensores multiespectrales y sensores de humedad del suelo para monitorear el estrés hídrico en la variedad de frijol "Flor de Mayo AN-05". Los factores considerados fueron, posición del cinta de riego (superficial y enterrada) y tres niveles de tensión de humedad del suelo 20, 30 y 50 kPa. Se evaluaron los índices de vegetación, NDRE (índice borde rojo de diferencia normalizada), TGI (índice de verdor triangular) y NDWI (índice de agua de diferencia normalizada), además la reflectancia de las bandas Red Edge y Red. Los hallazgos indican que la posición de la cinta de riego como la tensión de humedad del suelo tienen una relación significativa con los índices de vegetación evaluados. Además, se observó que la tensión de humedad del suelo de 20 kPa es más favorable para el NDWI, mientras que la tensión de 30 kPa aumentaba la reflectancia en las bandas Red Edge y Red. Estos resultados subrayan la importancia de la posición de cinta de riego y la tensión de humedad del suelo como elementos fundamentales para mejorar la eficiencia del riego y mejorar el rendimiento del frijol mediante la utilización de tecnologías de teledetección y sensores de humedad del suelo.

Palabras clave: Estrés hídrico, Detección del estrés hídrico, Teledetección, Sistemas aéreos no tripulados (UAS), Índices de vegetación.

ABSTRACT

DETECTION OF WATER STRESS IN BEAN CROPS (*Phaseolus vulgaris* L.) USING
MULTISPECTRAL IMAGING AND SOIL MOISTURE SENSORS

By:

NESTOR MAGDALENO MONTOYA PINEDA

MASTER OF SCIENCE IN PRODUCTION SYSTEMS ENGINEERING

UNIVERSIDAD AUTÓNOMA AGRARIA ANTONIO NARRO

Principal Advisor

Dr. MARTIN CADENA ZAPATA

Saltillo, Coahuila,

July 2024

SUMMARY

Water stress can have adverse effects on crop yields and alter their morphophysiological responses. Therefore, detecting water stress is crucial to improving crop productivity and quality. This study evaluates the effectiveness of remote sensing using unmanned aerial systems (UAS) equipped with multispectral sensors and soil moisture sensors to monitor water stress in the "Flor de Mayo AN-05" bean variety. The factors considered were the position of the irrigation belt (surface and buried) and three levels of soil moisture tension 20, 30 and 50 kPa. The vegetation indices, NDRE (red border index of normalized difference), TGI (triangular greenness index) and NDWI (normalized difference water index) were evaluated, in addition to the reflectance of the Red Edge and Red bands. The findings indicate that the position of the irrigation belt and the soil moisture tension have a significant relationship with the vegetation indices evaluated. In addition, it was observed that the soil moisture stress of 20 kPa is more favorable for NDWI, while the 30 kPa voltage increased reflectance in the Red Edge and Red bands. These results underscore the importance of irrigation belt position and soil moisture tension as critical elements to improve irrigation efficiency and improve bean yield through the utilization of remote sensing technologies and soil moisture sensors.

Keywords: Water Stress, Water Stress Sensing, Remote Sensing, Unmanned Aerial Systems (UAS), Vegetation Indices.

INTRODUCCIÓN

El sector agrícola en México, que es una pieza fundamental en la economía y la subsistencia del país, se encuentra en un punto crítico de su desarrollo. Este sector enfrenta desafíos significativos que amenazan su sostenibilidad y productividad, principalmente en lo que respecta a la gestión del agua y la eficiencia del riego. Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), aproximadamente el 70% del agua dulce extraída a nivel mundial se destina a la agricultura (FAO, 2019).

El cambio climático podría reducir significativamente los rendimientos agrícolas en regiones vulnerables (Dalin et al., 2017). Por otra parte, cambio climático afecta significativamente a la agricultura al provocar un aumento de las temperaturas, cambios en los patrones de lluvia, fenómenos meteorológicos extremos y una disminución del rendimiento de los cultivos, la producción ganadera y la viticultura (Kumari & Bains, 2023).

La integración de tecnologías avanzadas y políticas de manejo hídrico adecuadas puede mejorar la resiliencia de los sistemas agrícolas frente a las fluctuaciones en la disponibilidad de agua (Chouhan et al., 2023; Karri & Nalluri, 2024). Estudios recientes han demostrado la efectividad de estos sensores en la gestión del riego y la optimización del uso del agua en cultivos diversos (Liang et al., 2020). Además, el uso de cámaras térmicas para monitorear la temperatura de las hojas ha permitido detectar el estrés hídrico antes de que se manifiesten los síntomas visuales, mejorando así la capacidad de respuesta de los agricultores (Tavan et al., 2021). Investigaciones han resaltado la importancia de entrenar a los agricultores en la identificación de signos tempranos de estrés hídrico, lo que puede llevar a una intervención oportuna y a la prevención de daños severos en los cultivos (Kamienski et al., 2019).

Las variables climáticas, como la humedad media de la superficie del suelo, la precipitación efectiva acumulada y la temperatura del aire, desempeñan un papel importante a la hora de determinar el rendimiento de los cultivos (Llanes Cárdenas et al., 2024).

El contenido de humedad del suelo es un parámetro crucial para diversas actividades agrícolas, como el riego, la siembra y la detección de la compactación, e influye en procesos como la evapotranspiración y la recarga de los acuíferos (Aldaba et al., 2018). Los métodos tradicionales para medir la humedad de las hojas de las plantas consumen mucho tiempo y mano de obra, lo que dificulta la adquisición oportuna de los datos de monitoreo sobre el terreno (Yang et al., 2024). El monitoreo de la humedad del suelo a escala regional es crucial para varios estudios, como el ciclo del agua superficial, las sequías agrícolas, la evaluación de las inundaciones y la estimación del rendimiento de los cultivos (R. Lin et al., 2024).

Lipovac et al., (2022) evaluaron la viabilidad de las imágenes multiespectrales capturadas con vehículos aéreos no tripulados para el monitoreo estrés hídrico y la predicción del rendimiento en cultivos de frijol común en diferentes períodos de siembra y tratamientos de riego. Las tecnologías agrícolas inteligentes, en particular la integración de dispositivos de Internet de las cosas (IoT), como los drones, ofrecen soluciones prometedoras para mejorar la seguridad alimentaria (E. Singh et al., 2024). La integración de métodos de teledetección y teledetección puede mejorar la precisión de la evaluación del estado hídrico de las plantas al combinar escalas temporales y espaciales y mejorar las prácticas de gestión del agua para los cultivos de árboles frutales (Carella et al., 2024). Bajo la hipótesis de que, con la relación de los índices de reflectancia obtenidos con imágenes multiespectrales capturadas con drones y la tensión del humedad del suelo medida con tensiómetros se puede determinar el grado de estrés hídrico de un cultivo de frijol, el objetivo de este estudio fue evaluar cinco índices de reflectancia para determinar el grado de estrés de un cultivo de frijol, bajo tres niveles de tensión de la humedad del suelo para la aplicación del riego.

HIPÓTESIS

Mediante el uso de imágenes multiespectrales y sensores de humedad es posible monitorear el estrés hídrico en cultivo de frijol.

OBJETIVO GENERAL

Evaluar los índices de vegetación y la reflectancia de las bandas para determinar el grado de estrés en un cultivo de frijol, bajo tres niveles de tensión de la humedad del suelo.

OBJETIVOS ESPECÍFICOS

- Definir la relación entre tensión de humedad del suelo y los índices de vegetación y reflectancia para determinar el estrés hídrico del cultivo de frijol.
- Analizar la reflectancia y los índices foliares en función de la posición de la cinta (enterrada y superficial), con el fin de determinar su impacto en las características vegetativas de las plantas.
- Evaluar cómo la tensión de humedad del suelo (20,30 y 50 kPa), afecta la calidad y el desarrollo de la planta.

REVISIÓN DE LITERATURA

Importancia del Agua en México

Según los datos de 2020, México recibe anualmente aproximadamente 1.5 millones de metros cúbicos de agua en forma de precipitación; de esta cantidad, el 71.4% se evapotranspira y regresa a la atmósfera, el 22.2% escurre por ríos o arroyos y el 6.4% restante se infiltra al suelo y recarga los acuíferos (CONAGUA, 2022). En México, el 61% del agua proviene de fuentes superficiales y el 39% de fuentes subterráneas, el sector agrícola utiliza cerca del 76% de las extracciones, México tiene 22 millones de hectáreas dedicadas a la agricultura, de las cuales 6.1 millones tienen sistema de riego, se espera que para 2050, con un aumento del 25% en la población, las extracciones de agua aumenten un 55% para satisfacer una demanda de alimentos que será alrededor de un 70% mayor que la actual (CONAGUA, 2020). Por otra parte, (Mejía et al., 2002) destacan que el manejo del agua para uso agrícola en México es deficiente debido a las pérdidas en las redes de distribución, la falta de capacitación del personal y la ausencia de sistemas de medición adecuados, lo que resulta en una baja eficiencia en el uso del agua.

Cuadro 1. Distribución de volúmenes de agua concesionados para usos consuntivos en México, 2017.

Uso	Porcentaje
Agrícola	76%
Abastecimiento público	14%
Industria autoabastecida	5%
Energía eléctrica (excluyendo hidroelectricidad)	5%

Fuente: CONAGUA. 2018. Sistema Nacional de Información del Agua.

Sistemas de Riego y su Evolución

El riego es crucial para la producción agrícola y la generación de materias primas en México, especialmente ante el crecimiento poblacional, el país tiene 7.32 millones de hectáreas irrigadas, con 3.3 millones en Distritos de riego y 4.02 millones en Unidades de Riego, abastecidas principalmente por fuentes subterráneas (CONAGUA, 2017).

(Holzapfel et al., 2009); Olvera-Salgado et al., 2014) destacan que el diseño, la gestión y la operación de los sistemas de riego son factores clave para un uso eficiente del agua y una mayor producción, logrados a través de la automatización de los sistemas de riego y la incorporación de sensores y equipos que monitorean el proceso de irrigación. Sin embargo, la adopción de sistemas de riego tecnificados está influenciada por factores como el precio de la energía eléctrica y el valor del agua, un aumento del 10% en estos factores aumenta la probabilidad de usar un sistema tecnificado de 24.5% a entre 25.42% y 26.17%, una disminución del 10% en las precipitaciones aumenta la probabilidad de 24.51% a 25.41%, y un aumento de temperatura del 5% eleva la probabilidad de 24.51% a 29.40% (García-Salazar et al., 2023).

Huella Hídrica en la Agricultura

El concepto de huella hídrica cuantifica el volumen total de agua utilizada directa e indirectamente en la producción de bienes o servicios, incluida la agricultura (Mehla et al., 2023; Singh et al., 2023). Esta abarca todas las etapas de la producción, desde las fases iniciales, pasando por las distintas etapas de la cadena de producción, hasta el producto final(Delanhese et al., 2023). La evaluación de la huella hídrica ayuda a comprender los impactos y las limitaciones de los sistemas de producción actuales, lo que permite identificar las vulnerabilidades en diferentes regiones y épocas (Mehla, 2022).

Debido a que este índice permite realizar una cuantificación de cuánta agua es utilizada exactamente la huella hídrica es un importante instrumento para la evaluación de la sostenibilidad de los recursos hidráulicos para poder realizar un uso óptimo de los recursos hídricos (Becerra et al., 2013). A medida que la escasez de agua se convierte en un problema urgente, las estrategias innovadoras, como los sistemas de gestión precisa del agua, son cruciales para las prácticas agrícolas sostenibles, con el objetivo de reducir la huella hídrica y mejorar la gestión de los recursos hídricos (Preite et al., 2023).

Cuadro 1. Huella hídrica de diferentes cultivos.

Producto	Litros de agua / kilo de producto	Litros de agua / kilocaloría	Litros de agua/ gramo de proteína
Azúcar	197	0,69	0
Verduras	322	1,34	26
Frutas	962	2,09	180
Leche	1020	1,82	31
Huevos	3265	2,29	29
Pollo	4325	3,00	34
Carne de res	15.415	10,19	112

Fuente: IICA 2013b.

Cultivo de Frijol

El frijol común (*Phaseolus vulgaris* L.) es reconocido globalmente como la leguminosa más importante debido a su alto contenido de proteínas, carbohidratos, vitaminas y minerales, de las 1,300 especies existentes, 20 son consumidas especialmente en Centroamérica y Sudamérica (Vásquez et al., 2023). Las semillas contienen nutrientes esenciales como proteínas, fibra y almidón, y la cubierta de la semilla es rica en metabolitos secundarios que promueven la salud (Alfaro-Díaz et al., 2023; Blair et al., 2023). Los diferentes genotipos del frijol común muestran variabilidad en las características de las semillas: los frijoles pintos destacan por sus características morfológicas, los frijoles rojos por su contenido de proteínas y zinc y los frijoles blancos por sus niveles de hierro, calcio y magnesio (Kachiguma et al., 2024).

Taxonomía

Su taxonomía es la siguiente:

Reino: Plantae

División: Agiosperma

Clase: Dicotiledoneae

Subclase: Archichlamydeae

Orden: Rosales

Familia: Leguminosae

Subfamilia: Papilionoideae

Tribu: Phaseoleae

Subtribu: Phaseolinae

Género: Phaseolus

Especie: *Phaseolus vulgaris* L.

Morfología

La morfología estudia las características visibles de los órganos de las plantas a escalas macroscópicas y microscópicas, agrupándolas en caracteres constantes que identifican la especie y características variables influenciadas por las condiciones ambientales que afectan el fenotipo (Debouck & Hidalgo, 1985). Los estudios han destacado la amplia variación en los rasgos morfológicos, como el peso, el tamaño, la forma y el color de las semillas, así como en los hábitos de crecimiento de las plantas, las características de las hojas y la morfología de las vainas (Aziziaram et al., 2021; Jan et al., 2021). Los estudios de asociación de todo el genoma han identificado regiones genéticas asociadas con características morfológicas de las semillas, como el peso, el tamaño y la forma, y que los frijoles del grupo genético andino generalmente producen semillas más grandes (Giordani et al., 2022).

Requerimientos Agronómicos

Los tiempos de siembra varían según las condiciones edafoclimáticas, identificándose tres períodos principales: de agosto a octubre, de enero a abril y de mayo en adelante (Silva et al., 2020). Las prácticas agronómicas como la fertilización, el riego, la aplicación de rizobios, la densidad de siembra y el cultivo intercalado desempeñan un papel crucial en la mejora del rendimiento y la calidad del frijol (Karavidas et al., 2022).

Además, se ha demostrado que el uso de bioestimulantes sintéticos aumenta la productividad y los beneficios económicos de los agricultores, lo que pone de relieve la importancia de las tecnologías agrícolas sostenibles en el cultivo del frijol (Szparaga et al., 2019). Abordar la acidez del suelo mediante el encalado también es esencial para la producción de frijol común en tipos de suelo específicos, lo que hace hincapié en la necesidad de adoptar enfoques personalizados para el manejo del suelo (P. et al., 2020). Las condiciones ideales del suelo para el cultivo de frijoles incluyen una exposición total al sol, un suelo fértil y bien drenado y un riego regular para mantener la humedad del suelo cerca de la capacidad del campo (Domingues et al., 2018).

Los frijoles se benefician de suelos con una textura mixta limosa y franca arenosa, con un pH neutro o ligeramente ácido, ricos en materia orgánica y bajos niveles de carbonatos, lo que proporciona una alta capacidad de absorción de agua (Vance et al., 2021). Los atributos físicos del suelo, como la densidad aparente, la porosidad total, la macroporosidad y la microporosidad, desempeñan un papel crucial en el desarrollo de los cultivos de frijol, ya que están influenciados por los niveles de humedad del suelo y los factores del cultivar (Mayo-Prieto et al., 2021).

Necesidades Hídricas

Los requerimientos de agua del frijol común están influenciados por varios factores, como el tipo de cultivo, los niveles de riego y las respuestas genéticas al déficit de agua (Coelho et al., 2022; Leitão et al., 2021; E. F. dos Santos et al., 2020). Los diferentes cultivares de frijol común muestran respuestas variables a la disponibilidad de agua, lo que afecta el rendimiento agronómico, la productividad del agua y el rendimiento general (Tapia et al., 2022). Las investigaciones indican que, para maximizar la eficiencia física y económica del uso del agua en la producción de frijol, se necesitan volúmenes de entre 2.244,37

$\text{m}^3\cdot\text{ha}^{-1}$ y $2.438,06 \text{ m}^3\cdot\text{ha}^{-1}$ (Tornés Olivera et al., 2016).

En el caso de los sistemas de cultivos secundarios que utilizan frijol, los niveles de agua al 100% y al 125% de la evapotranspiración de referencia muestran la mayor eficiencia en el uso del agua y los rendimientos más altos, ya que se requieren aproximadamente 447,12 mm de agua para la variedad de frijol (Schwerz et al., 2017). El impacto del déficit hídrico en los cultivos de haba, el agua de riego osciló entre 476,83 $\text{m}^3/\text{alimento}$ y 696,41 $\text{m}^3/\text{alimentado}$, y las precipitaciones contribuyeron entre el 36,8% y el 46% del agua total aplicada (El-Hadidi et al., 2014).

Regiones con Mayor Producción de Frijol en México

En 2021, se produjeron 1.2 millones de toneladas de frijol, siendo Zacatecas fue el mayor productor con el 35% de la producción total, es decir, más de 451 mil toneladas. Le siguen Sinaloa con el 12% y Durango con el 10% de la producción total (SADER, 2022). Del mismo modo, los estados de Chihuahua, Durango y Zacatecas se consideran cruciales para la producción de frijol en condiciones de secano en las tierras altas semiáridas del norte de México, ya que representan una parte importante de la superficie cultivada con frijol de secano del país (Ennis et al., 2023).

Además, la zona agrícola de Sonora se ha ido adaptando a las oscilaciones de temperatura que afectan a la producción de frijol comercial, lo que sugiere desafíos ambientales y estrategias de adaptación en el cultivo del frijol (Chun et al., 2023). En resumen, los estados de Chiapas, Veracruz, Chihuahua, Durango, Zacatecas, Puebla, Sinaloa y Sonora emergen como contribuyentes importantes al panorama de producción de frijol de México, cada uno de los cuales enfrenta desafíos únicos y emplea estrategias distintas para mejorar la producción y gestionar los riesgos agrícolas (Vázquez Chun et al., 2023).

ESTRÉS HÍDRICO

El estrés hídrico se presenta cuando la perdida de agua de las plantas por medio de transpiración excede a la cantidad de agua que es absorbida por las raíces, el estrés hídrico es considerado la principal causa de muerte de las plantas (Luna Flores et al., 2018). Ihuoma & Madramootoo (2017) mencionan que la forma de realizar la programación de riego está basada en la medición de humedad de suelo, datos climáticos y mediciones de las respuestas fisiológicas de las plantas para calcular el estrés hídrico. Los modelos de interpolación pueden ser utilizados para generar mapas de estrés hídrico mediante el análisis de la relación entre el contenido de agua en la zona radicular y su disminución en ausencia de lluvia. (Villodre, 2019). Mediante datos colectados de un sistema automatizado para el monitoreo continuo de la salud de la planta asistido por computadora se pudieron recabar información de temperatura de la hoja de la planta, temperatura del aire, humedad relativa, velocidad del viento, intensidad lumínica e imágenes de la planta, donde se encontró una diferencia en la temperatura del aire de 1-3° C más altas al de la temperatura de la hoja en plantas estresadas (Kacira et al., 2002)

Estrés Hídrico en Frijol

El estrés hídrico en los frijoles afecta significativamente sus respuestas morfofisiológicas y sus atributos de rendimiento (Fogaça et al., 2023). Además, reduce el potencial hídrico, la presión de turgencia y el crecimiento de las células, lo que repercute en el desarrollo de las raíces, los tallos, las hojas y los frutos (Vilakazi et al., 2023). El estrés hídrico altera la composición química de las semillas, lo que afecta a la acumulación de azúcares solubles no reductores y al rendimiento germinativo de los garbanzos (Hemati et al., 2022). El estrés por sequía influye en el metabolismo, la morfología y la composición bioquímica de las plantas, lo que afecta a la pérdida de agua por transpiración y a la eficiencia en el uso del agua (Bijalwan et al., 2022).

En el frijol común, el estrés hídrico reduce significativamente el rendimiento del grano, el contenido de clorofila y el contenido relativo de agua, y altera los rasgos morfológicos, destacando el impacto del déficit hídrico durante el desarrollo reproductivo (Mataa et al., 2021). Las diferentes estrategias de riego, como el riego deficitario, pueden afectar las etapas de crecimiento del frijol de manera diferente: algunos genotipos muestran aclimatación cuando hay déficit de agua, mientras que otros experimentan respuestas plásticas y de estrés (Alomari-Mheidat et al., 2023).

Pérdidas Económicas

Los estudios muestran que el estrés hídrico puede reducir la producción de frijol común hasta en un 58% (Raderschall et al., 2021). Además, el índice de estrés hídrico de los cultivos (CWSI) derivado de la temperatura de la copa puede predecir las pérdidas de rendimiento, con una reducción del 42% observada en condiciones de estrés hídrico severo (Quiloango-Chimarro et al., 2021). Además, los efectos combinados del estrés hídrico y la herbívora de los insectos pueden influir de forma interactiva en el rendimiento del frijol, con una reducción de hasta un 84% cuando ambos factores de estrés están presentes (Kazai et al., 2019). El estrés por sequía también afecta el crecimiento y el desarrollo de la haba, lo que reduce la productividad. Algunos genotipos muestran una mayor tolerancia y mantienen los niveles de biomasa y clorofila en condiciones de deficiencia de agua (Papathanasiou et al., 2022).

Tecnologías Implementadas en Frijol para Monitoreo del Estrés Hídrico

Para resolver los problemas de evaluación de estrés hídricos de cultivos en áreas amplias la termografía área se ha vuelto una herramienta prometedora que parte del principio de las temperaturas del dosel, que se derivan de la ecuación de balance de energía que parte del supuesto del comportamiento del dosel como una sola hoja homogénea que cubre la superficie (Meron et al., 2013). Por otra parte, es posible que con el uso de índices de reflectancia adecuados es probable realizar la detección en tiempo real del estrés hídrico en invernadero, pero los factores de propiedades espectrales de las hojas no solo son influenciados por el contenido de agua de las hojas, sino que también por edad de la hoja, anatomía, gruesor, propiedades superficiales, el efecto del fondo de suelo, la estructura

del dosel y el área de la hoja (Katsoulas et al., 2016). Con base a estudios realizados por Yang et al., (2009) desarrollaron un método para la automatización en un sistema de riego y el procesamiento de la información del monitoreo del contenido de agua en la planta mediante estimación de la temperatura del dosel que fueron obtenidas con técnicas de identificación de por color, mediciones obtenidas con termografía IR y extracción de distribución de mezcla gaussiana.

AGRICULTURA DE PRECISIÓN

La agricultura de precisión integra tecnologías de vanguardia como sensores, drones y análisis de datos para optimizar las prácticas agrícolas (Fu et al., 2023; Verma et al., 2023). Esta integración permite a los agricultores mejorar el monitoreo de los cultivos, la detección de enfermedades y la gestión de los recursos en tiempo real, lo que conduce a una mayor eficiencia y sostenibilidad (Simanca et al., 2023). Al utilizar herramientas como el índice diferencial normalizado de vegetación (NDVI), la agricultura de precisión ayuda a optimizar el uso de herbicidas y el manejo de malezas en los cultivos extensivos, lo que se traduce en un aumento de los rendimientos y una reducción de los costes (Kanatas et al., 2023). Además, la experimentación de precisión en las explotaciones agrícolas, combinada con datos de código abierto y enfoques analíticos modernos, permite tomar decisiones agronómicas específicas para cada sitio, lo que permite superar los sesgos de los métodos de investigación tradicionales y acelerar el aprendizaje a escala de subcampos (Hegedus et al., 2023).

Los modelos de aprendizaje profundo para la detección y clasificación automatizadas de las enfermedades de las plantas ejemplifican aún más los avances tecnológicos de la agricultura de precisión, ya que ofrecen un diagnóstico preciso y precoz de las enfermedades de las plantas para mitigar las pérdidas de rendimiento (Pavithra et al., 2023). Por último, el estudio sobre el impacto de la variabilidad de las precipitaciones en el rendimiento de la soja en Brasil subraya la importancia de comprender los factores ambientales en la agricultura de precisión, destacando la necesidad de simulaciones multimodal para predecir y mitigar las pérdidas de producción debidas a la deficiencia de agua (Pilau et al., 2023).

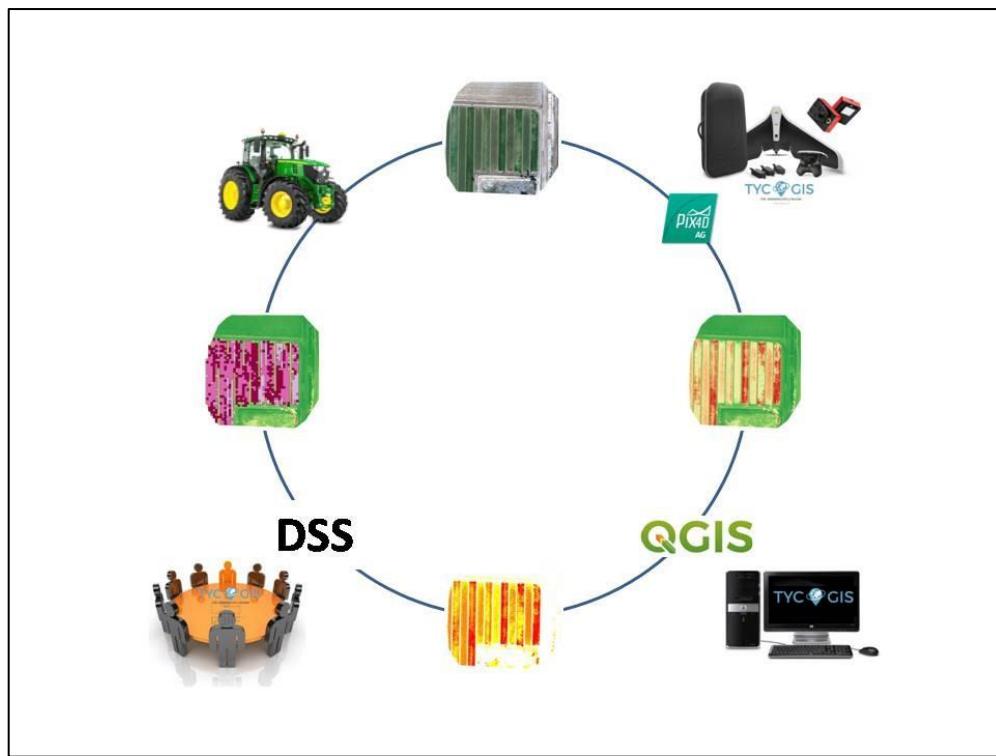


Figura 1. Proceso de la agricultura de precisión con drones. Fuente: TYC GIS.

Usos de Drones en Agricultura

Los drones en la agricultura tienen varios propósitos, incluida la teledetección para la evaluación de cultivos, la distribución precisa de productos químicos agrícolas, el monitoreo de la salud del ganado y el muestreo remoto (Malveaux et al., 2014; van der Merwe et al., 2020). Proporcionan datos de alta resolución en tiempo real para la toma de decisiones fundamentadas en materia de riego, fertilización y control de plagas, lo que permite optimizar la utilización de los recursos (Nunes, 2023). Los drones ayudan a fumigar con precisión, reducen el trabajo manual, ofrecen accesibilidad a áreas inaccesibles y mejoran el manejo de los cultivos mediante la cartografía y la topografía de los campos agrícolas (VANGU et al., 2023).

Los drones equipados con cámaras de alta resolución y otros sensores pueden inspeccionar rápidamente grandes áreas, proporcionando imágenes y datos de sensores valiosos para la gestión y la planificación de los cultivos sin el riesgo de dañarlos (Pilar Barreiro, 2013). Además del monitoreo de los cultivos, los drones se utilizan para monitorear la salud del ganado, lo que demuestra su versatilidad en aplicaciones agrícolas. También desempeñan

un papel crucial en la cartografía y la topografía de los campos agrícolas, ayudando en la planificación de los cultivos y la asignación de recursos (Spalević et al., 2018). La tecnología se ha ampliado aún más para predecir los brotes de plagas y enfermedades, ofreciendo un enfoque proactivo para gestionar la salud agrícola (Ioja et al., 2022). Sin embargo, los beneficios que ofrecen, incluidos el ahorro de costos y tiempo, la mejora de la recopilación y el análisis de datos, la mejora del manejo de los cultivos y la sostenibilidad ambiental, subrayan su potencial para revolucionar las prácticas agrícolas (Christopher, 2017).

Tipos de Drones

La clasificación principal divide los drones en helicópteros VTOL híbridos de ala fija, multirrotor y monorotor, y VTOL híbridos de ala fija, cada uno con características y usos distintos (Sönmez et al., 2022). Los drones de ala fija, que destacan por su eficiencia en vuelos de larga distancia, contrastan con las variantes multirrotor, que son famosas por sus capacidades de despegue y aterrizaje verticales, lo que los hace ideales para tareas de fotografía aérea, vigilancia e inspección (Garg, 2022). Los helicópteros de un solo rotor se parecen a los helicópteros tradicionales y ofrecen una mayor estabilidad de vuelo y capacidad de carga útil, mientras que los VTOL híbridos de ala fija combinan las ventajas de los diseños de ala fija con las capacidades de despegue y aterrizaje vertical de los rotores (Rominiyi et al., 2023). Este espectro de autonomía es esencial para las aplicaciones que requieren distintos niveles de control e independencia, desde la agricultura de precisión hasta la vigilancia autónoma (Thomassey, 2019). Los drones también se diferencian por su tamaño, peso y fuente de alimentación, lo que influye directamente en su alcance de crucero, la duración máxima del vuelo y la capacidad de carga (Mohsan et al., 2022). Estas especificaciones son cruciales para tareas como la entrega de mercancías, donde la capacidad de carga útil y la resistencia de vuelo son fundamentales (Valaboju et al., 2023).



Figura 2. (a) ala fija, (b) híbrido de ala fija, (c) de un solo rotor y (d) UAV multirrotor. (Mohsan et al., 2022).

Multi Rotor

Los drones multirrotor, caracterizados por múltiples hélices que proporcionan empuje, se utilizan ampliamente para obtener imágenes aéreas, vigilancia y monitorización (Derkachev et al., 2023; Hert et al., 2023). Se clasifican según la disposición de los brazos y el peso, y hay tipos como tricópteros, cuadricópteros, hexacópteros y octocópteros, cada uno de los cuales ofrece ventajas únicas en cuanto a estabilidad, potencia, maniobrabilidad y capacidad de carga (Bertrand & Shin, 2023). Estos drones desempeñan un papel crucial en varios sectores, como la fotogrametría, la fotografía, el modelado 3D y la recopilación rápida de datos desde lugares desafiantes (Zheng et al., 2023). Su versatilidad los hace ideales para capturar imágenes y videos aéreos, así como para ejecutar tareas de vigilancia y monitoreo de manera eficaz a distancias cortas y medias (Mohsan et al., 2023).

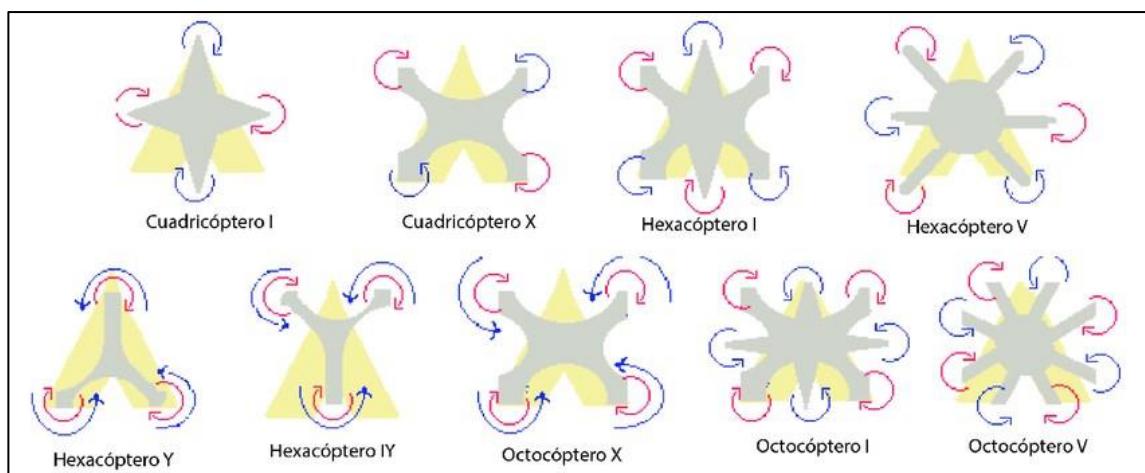


Figura 3. Ejemplos de multirrotores con diferentes tipos de configuración de brazos. Fuente: (Guevara-Bonilla et al., 2020)

Ala Fija

Los drones de ala fija ofrecen ventajas en cuanto a la eficiencia aerodinámica para misiones de larga distancia (Bello et al., 2022). Sin embargo, desafíos como la limitada precisión de la navegación dificultan todo su potencial (Kapoulas et al., 2023). Para abordar este problema, un estudio propone un sistema de visión por GNSS para una navegación precisa, reduciendo significativamente los errores (Wuest et al., 2022). Además, la integración de las capacidades de VTOL con los vehículos aéreos no tripulados de ala fija mejora su versatilidad sin comprometer la eficiencia (Sonkar et al., 2023). Los estudios de radar se centran más en los drones multirrotor, lo que deja un vacío en la comprensión de las características de los radares UAV de ala fija (Baldi et al., 2022).

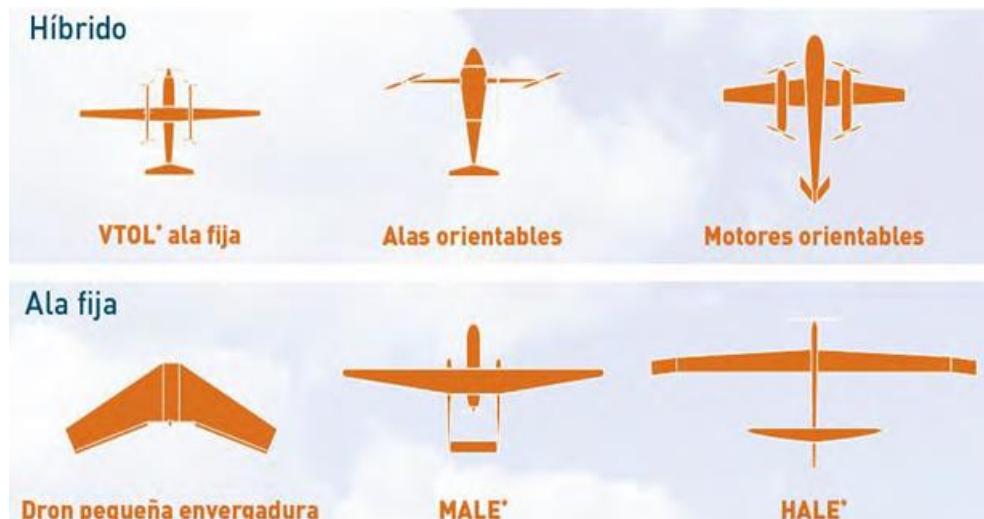


Figura 4. Drones de ala Fija. Fuente: *(Fabián Reuter & Amilcar Pedenov, 2019)*

TELEDETECCIÓN

La teledetección es la ciencia y el arte de adquirir información sobre objetos, áreas o fenómenos sin contacto físico, utilizando datos recopilados por varios sensores (Dewi et al., 2003). Los ordenadores procesan estos datos para producir imágenes, extraer conjuntos de datos y ayudar a la toma de decisiones (Mather, 2000). La teledetección consiste en registrar la radiación electromagnética reflejada o emitida desde la superficie terrestre, utilizando sensores en plataformas como aviones o satélites (Coops & Tooke, 2017; Lindgren, 1985).

Esta tecnología utiliza ondas electromagnéticas para observar y medir diferentes características de la Tierra, lo que proporciona datos críticos para el monitoreo ambiental, agrícola, gestión de desastres, entre otros (Scudiero et al., 2017). Mediante el uso de modelos de teledetección, los investigadores han cartografiado con éxito la salinidad del suelo en las zonas radiculares del oeste del valle de San Joaquín, lo que demuestra el potencial de la tecnología para identificar las áreas afectadas y ayudar a desarrollar estrategias de mitigación (Postolache, 2017). Además, la fusión de datos abiertos de diversas fuentes, incluidos satélites y drones, a través de la tecnología blockchain, destaca el potencial para mejorar la confiabilidad y confiabilidad de los datos de teledetección, abriendo nuevas vías para la agricultura de precisión y otras aplicaciones (Mbinya Manetu et al., 2023). A medida que las tecnologías de teledetección siguen avanzando, su integración con los sistemas de geoinformación y el uso de diversas técnicas de detección, incluidas la teledetección hiperespectral y el LiDAR, subrayan el papel fundamental de la tecnología a la hora de proporcionar observaciones completas y detalladas de la superficie terrestre, lo que respalda una amplia gama de aplicaciones científicas, ambientales y comerciales.

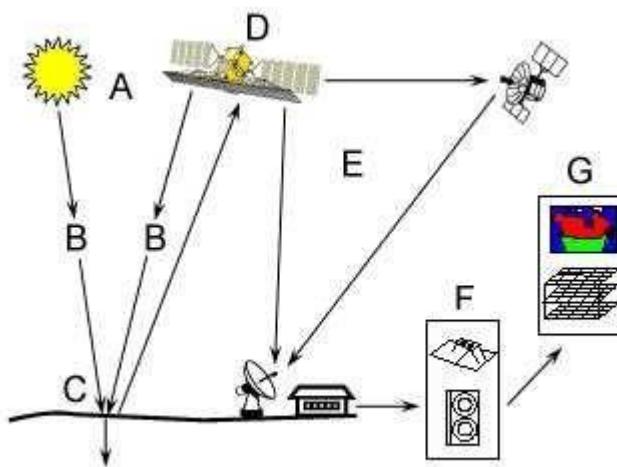


Figura 5. Componentes de un sistema de teledetección espacial: (A) Fuente de energía. (B) Atmósfera. (C) Suelo. (D) Sensor. (E) Transmisión, y procesamiento. (F) Análisis. (G) Aplicación. Fuente: (Bustos, 2014).

Espectro Electromagnético de la Radiación Solar

El espectro electromagnético de la radiación solar abarca una amplia gama de longitudes de onda, desde la ultravioleta (UV) pasando por el espectro de luz visible hasta la radiación infrarroja (IR), cada una de las cuales transporta distintas cantidades de energía cruciales para varios procesos en la Tierra (Hissou et al., 2023). La irradiación solar (R_s) es la energía emitida por el Sol, que desempeña un papel vital en el sustento de la vida al proporcionar luz, calor y energía e impulsar los sistemas climáticos y meteorológicos de la Tierra (Zhenming Ding et al., 2023). La medición del espectro solar en la región visible del infrarrojo cercano se puede realizar de manera eficiente utilizando chips de lentes espectrales de guía de ondas (WSL) integrados, lo que demuestra la viabilidad de desarrollar equipos espectrómetros compactos y portátiles (Wald, 2019).

La interacción de las ondas electromagnéticas con la materia, incluida la radiación solar, es un aspecto fundamental de la investigación científica, ya que proporciona información sobre las estructuras moleculares y los enlaces químicos (Gq, 2021). Los datos obtenidos por satélite han demostrado su fiabilidad para la evaluación local y regional de la radiación solar, lo que facilita las aplicaciones agrícolas y ambientales (Sayago et al., 2016). Por

último, la variabilidad temporal del espectro de radiación solar y su impacto en los sistemas ecológicos y de recolección de energía renovable subrayan la importancia de entender su dependencia de la ley de potencia espectral (Bel & Bandi, 2019).

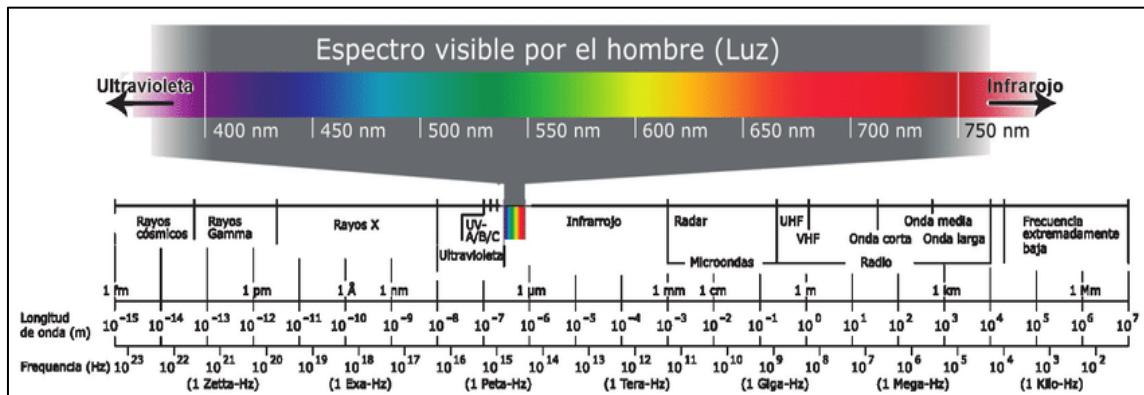


Figura 6. Espectro electromagnético en toda su amplitud. Fuente: (Sierra Figueredo & Baca, 2014)

Uso de Dron para Obtención de Imágenes

Los drones han demostrado ser herramientas valiosas para diversas aplicaciones, incluidos los estudios de hidrodinámica costera (Macedo et al., 2023), el inventario forestal en bosques nativos privados (Drozdowicz & Samczynski, 2022) y la investigación de mamíferos marinos, como el monitoreo de ballenas comunes (Degollada et al., 2023). Además, se han desarrollado métodos de optimización para mejorar la calidad de las imágenes y la determinación de la trayectoria para aplicaciones específicas, como la obtención de imágenes por radar de apertura sintética (Francis et al., 2022). El uso de drones para obtener imágenes en la agricultura ofrece una solución de vanguardia para la detección y el monitoreo eficientes de las enfermedades de las plantas (Abbas et al., 2023; Shah et al., 2023). Los drones equipados con cámaras de alta resolución capturan imágenes de los campos agrícolas, lo que permite identificar rápidamente las enfermedades de las plantas en sus etapas temprana (Näsi et al., 2023).

IMÁGENES DIGITALES

Una imagen digital es una representación de un objeto que utiliza elementos de imagen, conocidos como píxeles, en un formato digital que puede procesarse mediante algoritmos informáticos (Khoza, 2022; Nethaji & Shanmugasundaram, 2020; Pratt, 2013). Estas imágenes se almacenan como matrices de valores de intensidad de píxeles, lo que permite utilizar diversas técnicas de procesamiento digital de imágenes, como el reconocimiento de patrones, la teledetección y las imágenes médicas (Lupton et al., 2022).

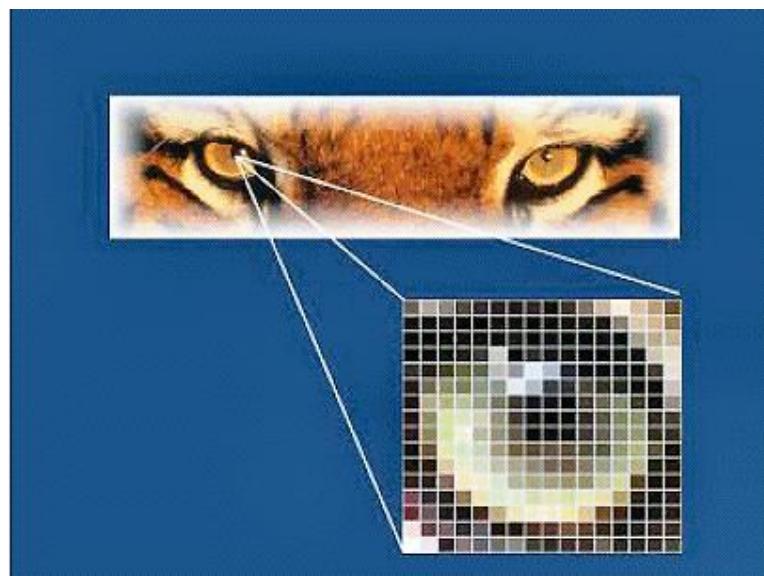


Figura 7. Conformación de píxeles en una imagen digital. Fuente: (Miranda, Miguel, 2009)

Procesamiento de Imágenes

El procesamiento digital de imágenes implica manipular imágenes digitales mediante varios algoritmos para mejorarlas, restaurarlas o clasificarlas (Dong et al., 2023; K Ganapathi Babu et al., 2023; Lakshmi Kumari, 2023). Esta tecnología se usa ampliamente en diferentes campos, como la teledetección, las imágenes médicas y la industria textil, para mejorar la eficiencia y la precisión (Abduganiev & Gafurov, 2023). El procesamiento digital de imágenes desempeña un papel crucial en la agricultura al ayudar a detectar y clasificar las enfermedades de las plantas, lo cual es esencial para mantener la calidad de los cultivos y aumentar el rendimiento (Ramachandran & kannan, 2021). Al utilizar

técnicas como las características del color, los detalles de los bordes y la extracción de características, el procesamiento de imágenes puede detectar eficazmente enfermedades en plantas como los plátanos, los tomates y la coliflor (Junior et al., 2021). Además, en el contexto del diagnóstico de las enfermedades de las plantas, se han propuesto metodologías como el análisis mejorado de la textura fractal por fusión (EFFTA) para mejorar la eficiencia y la precisión de la detección de enfermedades mediante la visión artificial (Gangadharan et al., 2020).

En cuanto a los softwares de procesamiento de imágenes Pix4Dmapper es utilizado para procesar fotografías aéreas, particularmente en proyectos ambientales que involucran vehículos aéreos no tripulados (UAV)(Walton et al., 2007) . Ofrece tiempos de procesamiento eficientes en comparación con otros programas similares como Agisoft PhotoScan (Walton et al., 2003). Pix4Dmapper se destaca por proporcionar líneas de contorno suaves y uniformes, lo que mejora la calidad de los ortomosaicos generados (Costales Acurio, 2018).

Tipos de Resoluciones

La resolución en imágenes digitales se refiere al nivel de detalle o claridad presente en una imagen (Wilson, 2023). Se puede clasificar en varios tipos, como la resolución en píxeles, la resolución espacial, la resolución temporal y la resolución radiométrica (Nugroho et al., 2022). La resolución espacial se refiere específicamente a la densidad de píxeles de una imagen, donde una resolución más alta indica más detalles (Brunett et al., 2000). La calidad de una imagen digital depende en gran medida de su resolución, ya que las imágenes de alta resolución contienen más información en comparación con las de baja resolución (Zerené Harcha & Cardoso Pereira, 2014). Además, las pruebas de resolución en imágenes digitales se pueden automatizar mediante algoritmos de aprendizaje automático entrenados con funciones extraídas de bases de datos de imágenes (Galdón et al., 2023).

Resolución Espacial

La resolución espacial es el nivel de detalle observable en una imagen o conjunto de datos, desempeña un papel crucial en campos como la geología, la teledetección y la generalización de mapas (Michael Abrams, 1982). En geología, la resolución espacial afecta a la detección de características espaciales y firmas espectrales (Tinghua & Yaolin, 2003). En el caso de la teledetección, una resolución espacial más alta permite extraer, identificar y cartografiar con mayor precisión las características de la superficie, como los deslizamientos de tierra (Wu et al., 2017). Además, en la generalización de mapas, la transformación de las relaciones espaciales es esencial, ya que implica componentes como la topología, la distancia y la orientación (Mora et al., 2014).

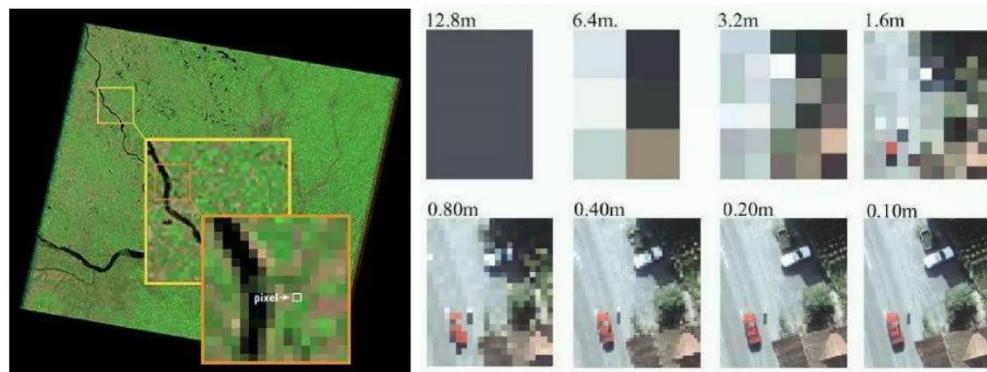


Figura 8. Comparación del tamaño de pixel de una imagen. Fuente: (Chucos Baquerizo & Vega Ventocilla, 2022).

Resolución Espectral

La resoluciónpectral se refiere a la capacidad de un espectrómetro para distinguir entre longitudes de onda poco espaciadas en un espectro (P. He et al., 2021; Vasilyev, 2020). Se emplean varios métodos y dispositivos para mejorar la resoluciónpectral, como la utilización de una clase especial de operadores en espacios discretos (Chen et al., 2021), o la implementación de nuevas técnicas de aprendizaje automático como Sparse Representations para mejorar la resoluciónpectral de los sistemas de imágenes (Fotiadou et al., 2016). El objetivo de técnicas como la superresoluciónpectral es sintetizar datos de alta resoluciónpectral procedentes de bandas espectrales limitadas, lo que permite describir mejor las escenas de interés (J. He et al., 2022).

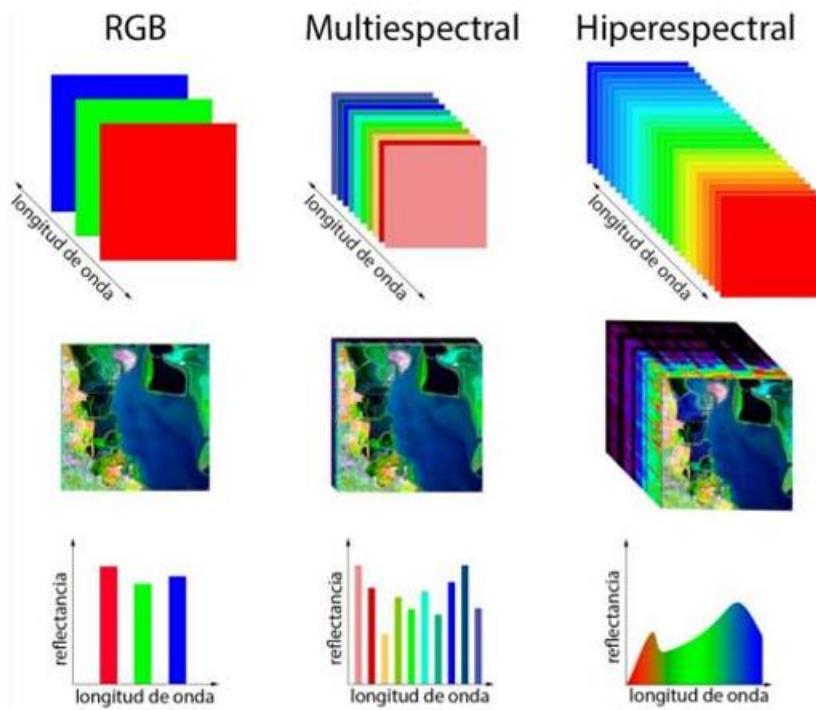


Figura 9. comparación entre RGB, multiespectral e hiperespectral. Fuente: (F. Y. Belen, 2022).

Resolución Radiométrica

La resolución radiométrica se refiere a la capacidad del sensor para detectar el menor cambio en la radiaciónpectral, algo crucial para un análisis preciso de las imágenes (Anikeeva, 2020). Una resolución radiométrica más alta permite diferenciar más detalladamente los niveles de brillo de las imágenes, lo que mejora la precisión en la clasificación de las imágenes y la extracción de información (Chilveri et al., 2023; Yalcin et al., 2021). El error de cuantificación en la resolución radiométrica puede inducir sesgos de calibración entre diferentes sensores, lo que afecta a la precisión de la calibración cruzada (Bhatt et al., 2018). Además, se pueden observar mejoras en la resolución espacial, como en las zonas urbanas, con una resolución radiométrica más alta, aunque pueden surgir problemas como los patrones de ruido cromático y borroso (Verde et al., 2018). Si se tienen en cuenta estos factores y se emplean métodos de corrección, se puede mejorar la resolución radiométrica de los sensores, aumentando la calidad y la fiabilidad de los datos de las imágenes de satélite para diversas aplicaciones (Bahcivan et al., 2022).

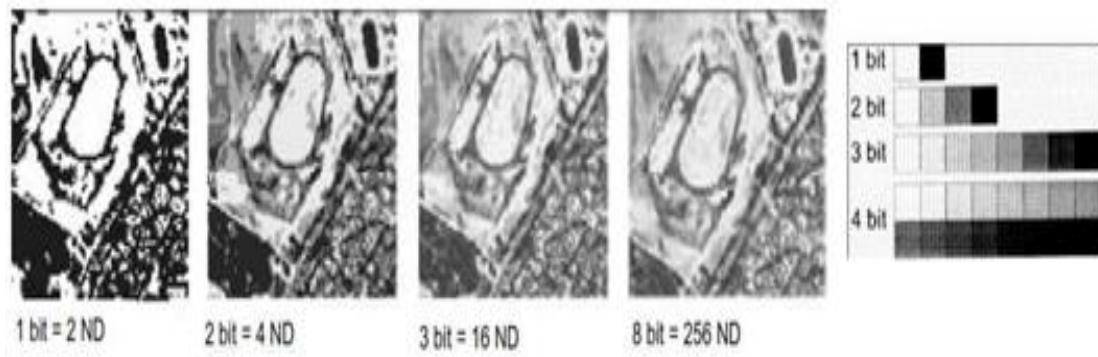


Figura 10. Comparación en los niveles de grises o niveles digital (ND) de una imagen (UNESCO RAPCA).

Resolución Temporal

La resolución temporal desempeña un papel crucial en la detección de cambios en las imágenes multiespectrales, una resolución temporal más alta permite obtener imágenes con mayor frecuencia a lo largo del tiempo, lo que permite detectar cambios sutiles y rápidos en la superficie de la Tierra (Lu et al., 2022). Además, la resolución temporal influye en la capacidad de rastrear los cambios con precisión a lo largo del tiempo, especialmente cuando se analizan imágenes de teledetección multitemporal (Vidya et al., 2023). Los métodos que tienen en cuenta las variaciones de la resolución temporal, como los enfoques basados en la fusión y la factorización matricial multitemporal con actualización automática, mejoran la detección de cambios al abordar los desafíos que plantean las diferentes resoluciones espaciales y espectrales en las imágenes multitemporales (Benkouider et al., 2022; Guo et al., 2021).

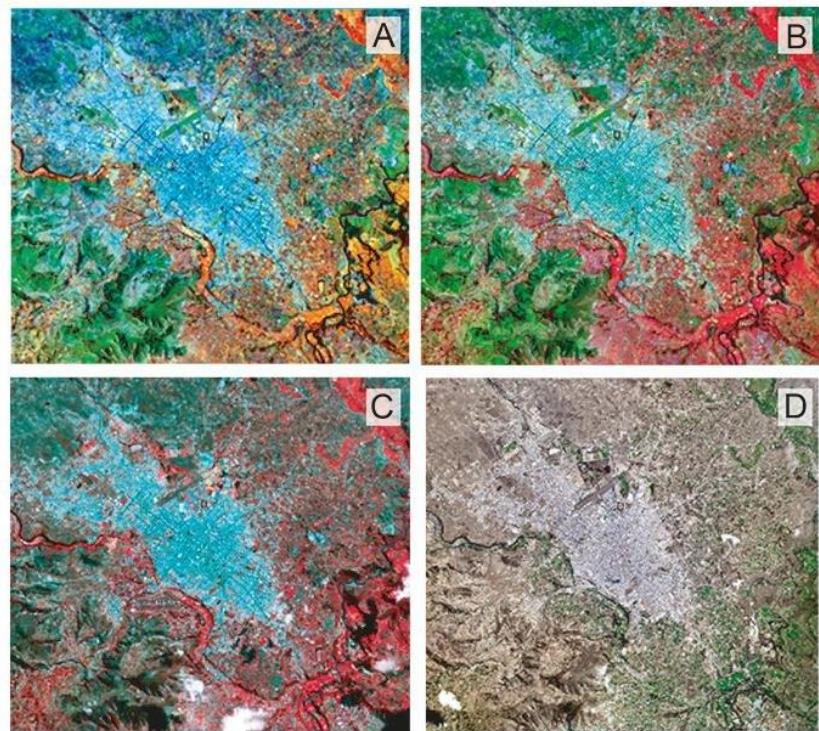


Figura 11. Ejemplos de imágenes satelitales. A) Imagen Landsat8: composición 5-6-4. Fuente: <https://app.climateengine.org/climateEngine>. B) Imagen Sentinel2: composición 8-11-4. Fuente: Composito Año 2019-2020 <https://app.climateengine.org/climateEngine>. C) Imagen ASTER: composición 3-2-1. Fuente: Año: 2017 <https://gbank.gsj.jp/madas/map/index.html>. D) Imagen "basemap": color natural RGB 1-2-3. Fuente: SASPlanet. Año 2019-2020

TIPOS DE SENSORES

Se han desarrollado varios tipos para capturar imágenes que enfrentan a desafíos como el alto consumo de energía y la latencia (Jang et al., 2022). Los sensores de imagen complementarios con semiconductores de óxido metálico (CMOS) se utilizan ampliamente, ya que permiten interactuar con el mundo visual y separan la captura de imágenes del procesamiento (Mennel et al., 2022). Estos sensores están evolucionando hacia la computación integrada en los sensores, en la que el procesamiento de las imágenes se realiza dentro de las matrices de fotodiodos, lo que reduce los costos de energía asociados con la transferencia de datos (RadhaKrishna et al., 2021). Además, los sensores de imagen suelen distinguirse por parámetros como el tamaño de la matriz de píxeles (megapíxeles) y el tipo de tecnología de imagen utilizada, como el CMOS o el CCD (Aguirre, 2022).

RGB

Un sensor RGB es un dispositivo capaz de detectar y medir componentes de color rojo, verde y azul en diversas aplicaciones son alternativas rentables a los espectrofotómetros tradicionales, ya que ofrecen portabilidad y versatilidad (Pazzi et al., 2022). Se pueden utilizar en diversos campos, como los análisis químicos y biológicos, el fenotipado de alto rendimiento en la agricultura e incluso en la robótica para la detección del color y la medición del brillo (Koch, 2023; Roales et al., 2023). Se han explorado los sensores RGB para detectar la ocupación en espacios iluminados, ya que proporcionan un seguimiento preciso de los ocupantes al monitorear los cambios de color causados por los movimientos y compensar las propiedades de absorción espectral de las superficies(Woodstock & Karliceck, 2020).

Térmicos

Los sensores térmicos detectan las radiaciones de calor emitidas por los objetos, que luego se transforman en energía eléctrica y se convierten en una imagen térmica o termograma (Unnikrishnan & Ramanand, 2020). Estos sensores se han desarrollado para una amplia gama de aplicaciones, desde la supervisión de procesos industriales hasta el control ambiental, debido a su capacidad de proporcionar una alta sensibilidad y

rendimiento en la detección de propiedades térmicas (Al-doski et al., n.d.; Virtue et al., 2021). Esta tecnología no es invasiva, no produce contacto y no es destructiva, lo que la hace particularmente útil para determinar las características térmicas de cualquier objeto de interés (Dinh et al., 2022; Ishimwe et al., 2014). El uso de imágenes térmicas en la agricultura está aumentando, especialmente en la detección de plagas, debido a la reducción de los costos de equipo y a la simplicidad de los procedimientos operativos (Collatz et al., 2018; Jones, 2018; Tang & Li, 2014). La versatilidad de los sensores térmicos se demuestra aún más en su aplicación para la monitorización de sequías, donde pueden ayudar a evaluar la gravedad de las sequías en función de la duración, la intensidad y la extensión espacial, lo cual es crucial para la planificación y la gestión del agua a fin de mitigar los impactos en la producción de cultivos (Labbé et al., 2012).

Multiespectrales

Un sensor multiespectral puede capturar imágenes en diferentes longitudes de onda más allá del espectro visible, lo que proporciona información sobre los efectos físicos, químicos y biológicos en los materiales y los tejidos biológicos (Poma, 2019). Pueden capturar datos de imágenes en rangos de longitud de onda específicos en todo el espectro electromagnético, extrayendo información adicional más allá de la visión humana (X. He, Liu, Ganeshan, et al., 2020; Shaik et al., 2023). Estos sensores son cruciales en varios campos, como la agricultura de precisión, la silvicultura, la medicina y la identificación de objetos (X. He, Liu, Beckett, et al., 2020).

Estos sensores se han utilizado para estudiar el estrés en las plantaciones de café, correlacionando los índices de vegetación con las variables bióticas y abióticas para mapear los cambios en la reflectancia de las plantas (Marin et al., 2019). En la agricultura, se han empleado sensores de imágenes multiespectrales transportados por drones para evaluar el estado fitosanitario de las gramíneas, con longitudes de onda específicas que muestran correlaciones con los niveles de enfermedad (Hoyos Rojas et al., 2019). Además, se ha propuesto la integración de sensores de luz infrarroja y visible en un único dispositivo para mejorar la fusión de imágenes sin necesidad de registro, lo que aumenta la eficacia de las tecnologías de obtención de imágenes multiespectrales (Qiao et al., 2018).

Hiperespectrales

Los sensores hiperespectrales ofrecen imágenes en tiempo real con una resolución espacial y temporal completa, lo que permite lograr resoluciones espectrales y espaciales extraordinarias en un amplio rango de longitudes de onda de 400 a 1700 nm (Bian et al., 2023). La utilidad de la tecnología se extiende al desarrollo de infraestructuras, ya que los sensores hiperespectrales proporcionan información detallada sobre la calidad, la cantidad y el tipo de los elementos presentes en cualquier área, gracias a su capacidad para capturar señales espectrales en un espectro electromagnético continuo (Flores et al., 2023). En la agricultura, los sensores hiperespectrales contribuyen a la gestión precisa de las enfermedades al proporcionar evaluaciones detalladas de las interacciones entre plantas y patógenos(Roh et al., 2021).

ÍNDICES DE VEGETACIÓN

Los índices de vegetación desempeñan un papel crucial en la agricultura de precisión al proporcionar información valiosa sobre la salud, el crecimiento y el contenido de nutrientes de los cultivos (Radočaj et al., 2023; Ramirez et al., 2023). Si bien los métodos tradicionales se basan en sensores multiespectrales instalados en satélites y vehículos aéreos no tripulados, estudios recientes han explorado el uso de imágenes RGB y técnicas de aprendizaje profundo para estimar los índices de vegetación (Devyatkin, 2023).

NDVI (Índice de Vegetación de Diferencia Normalizada)

El índice diferencial normalizado de vegetación (NDVI) es una medida de teledetección ampliamente utilizada que evalúa la salud y la densidad de la vegetación comparando la diferencia entre el infrarrojo cercano (que la vegetación refleja fuertemente) y la luz roja (que la vegetación absorbe) (Pangestu et al., 2023). En la agricultura, el NDVI ayuda a monitorizar las fases de crecimiento y la productividad del arroz, como han demostrado los estudios realizados con imágenes del Sentinel-2 para analizar los arrozales de Indonesia(Conley et al., 2023; Nafarin & Novitasari, 2023) . Los datos del NDVI de diferentes fuentes satelitales, como MODIS y FY-3D MERSI-II, se han validado para garantizar su coherencia, lo que garantiza un monitoreo confiable del estado de la vegetación a varias escalas(Nafarin & Novitasari, 2023). La integración del NDVI con tecnologías avanzadas, como los modelos de fenotipado vegetal y aprendizaje automático de alto rendimiento, mejora aún más sus capacidades predictivas y su ámbito de aplicación en la investigación ambiental y agrícola (Xiao et al., 2023).

La fórmula del NDVI se expresa como:

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

Donde:

NIR es la luz reflejada en el espectro del infrarrojo cercano.

Red es la luz reflejada en el rango rojo del espectro.

Rango de valores: Oscilan entre -1 a +1, donde los valores más altos indican una vegetación más densa y saludable (Safitri et al., 2023).

BNDVI (Índice de Vegetación de Diferencia Normalizada Azul)

El BNDVI, o índice azul de diferencia de vegetación normalizada, es un índice de vegetación que evalúa la presencia de vegetación verde viva, lo que indica la biomasa y la salud, mediante el uso de luz azul para una mejor detección en áreas con una alta reflectancia del fondo del suelo (Wójcik-Gront et al., 2022). Se calcula como la diferencia normalizada entre las bandas espectrales azules y del infrarrojo cercano (NIR). Los estudios han demostrado que el BNDVI, junto con otros índices como el NDVI, el GNDVI y el VARI, muestran una fuerte correlación positiva con el contenido de clorofila, lo que indica su eficacia para controlar la salud y el estado fisiológico de las plantas (Zou et al., 2018). Además, el BNDVI se ha destacado por su sensibilidad a los cambios en la heterogeneidad espacial dentro de los campos, lo que lo convierte en una herramienta valiosa para evaluar con precisión la salud de la vegetación y las variaciones de la pigmentación (Boonupara et al., 2024).

$$BNDVI = \frac{(NIR - Blue)}{(NIR + Blue)}$$

(WANG et al., 2007)

Donde:

NIR es la luz reflejada en el espectro del infrarrojo cercano.

Blue es la luz reflejada en la banda azul del espectro.

Rango de valores: -1 a 1, -1: Sin vegetación, 1: Vegetación densa.

GNDVI (Índice de Vegetación de Diferencia Normalizada Verde)

El índice de vegetación de diferencia normalizada verde (GNDVI) es un índice de vegetación que utiliza la banda verde en lugar de la roja, lo que demuestra su utilidad para estimar el rendimiento de los cultivos, como arrozales inundados con diferentes niveles de fertilización (Revelo et al., 2021). Los estudios han comparado el GNDVI con otros índices como el NDVI y el NDRE, destacando su menor sensibilidad a las variaciones en el vigor de la vegetación dentro de una región, lo que lo hace menos adecuado para caracterizar los estados de la vegetación en comparación con el NDRE (Pacheco Gallardo & Luis Lautaro, 2018). Además, las investigaciones han demostrado que el GNDVI, junto con otros índices como el Clg, mostraron correlaciones más bajas con variables como el verdor de la biomasa en comparación con el NDVI y el RVI, lo que enfatiza la importancia de elegir el índice apropiado para las evaluaciones específicas de la vegetación (De La Casa & Ovando, 2007).

La fórmula para calcular el GNDVI es la siguiente:

$$GNDVI = \frac{(NIR - Green)}{(NIR + Green)}$$

Donde:

(A. A. Gitelson et al., 1996)

NIR es la luz reflejada en el espectro del infrarrojo cercano.

Green es la luz reflejada en la banda verde del espectro

Rango de valores: - 0 a 1, 0: Baja cantidad de clorofila, 1: Alta cantidad de clorofila.

NDRE (Diferencia Normalizada Borde Rojo)

A diferencia del ampliamente utilizado Índice Diferencial de Vegetación Normalizado (NDVI), que mide principalmente el verdor y es propenso a la saturación en la vegetación densa, el NDRE aprovecha la banda roja del borde, lo que lo hace más sensible a las variaciones en los niveles de clorofila y menos afectado por la densidad del dosel (Huang et al., 2021; Suárez et al., 2021). Esta sensibilidad permite que el NDRE detecte las deficiencias de nitrógeno y otros factores de estrés en los cultivos de manera más eficaz que el NDVI, como se demostró en un estudio a escala de campo realizado en una granja experimental en Japón, donde el NDRE identificó áreas con bajo contenido de clorofila, lo que indica una limitación de nitrógeno (Boiarskii, 2019). La aplicación del NDRE se extiende más allá de la agricultura; se ha utilizado en estudios ecológicos para monitorear la dinámica de la vegetación y evaluar los impactos de los cambios ambientales en la biodiversidad y los servicios de los ecosistemas (Pettorelli et al., 2011; Radočaj et al., 2023). A pesar de sus ventajas, el NDRE se adopta con menos frecuencia en los estudios científicos en comparación con el NDVI, en parte debido al mayor costo y complejidad de los sensores multiespectrales necesarios para su cálculo (J. de B. G. dos Santos et al., 2023; Mayorga Arias et al., 2019).

La fórmula para calcular el NDRE es la siguiente:

$$NDRE = \frac{(NIR - RedEdge)}{(NIR + RedEdge)}$$

(A. Gitelson & Merzlyak, 1994)

Rango de valores: -1 a 1, -1: Baja cantidad de clorofila, 1: Alta cantidad de clorofila

SIPI2 (Índice de Pigmentos Intensivos de Estructura 2)

El SIPI, al igual que otros índices de vegetación, como el índice diferencial normalizado de vegetación (NDVI), aprovecha las propiedades de reflectancia espectral de las plantas para detectar el estrés y las enfermedades en forma temprana, a menudo antes de que aparezcan los síntomas visuales (Meena et al., 2020). La integración de múltiples índices, incluidos el SIPI, el NDVI y otros, puede proporcionar una visión integral de la sanidad vegetal al combinar diferentes aspectos de los datos espectrales, lo que ayuda a reducir los errores de juicio causados por las distorsiones espectrales (Wisayataksin et al., 2022). En general, el SIPI y los índices similares son herramientas invaluables en la agricultura moderna, ya que permiten la detección temprana y la gestión precisa de la sanidad de las plantas, lo que en última instancia conduce a un mejor rendimiento de los cultivos y a una reducción de las pérdidas económicas debidas a las enfermedades de las plantas (Khan et al., 2018).

La fórmula para calcular el SIPI2 es la siguiente:

$$\text{SIPI2} = \frac{(\text{NIR} - \text{Green})}{(\text{NIR} - \text{Red})}$$

(Cardim & Lima, 2019)

Rango de valores: -1 a 1, con 1 indicando bosques en zonas templadas y tropicales, 0 correspondiendo a áreas sin vegetación como rocas y terrenos desnudos, valores moderados entre 0.2 y 0.3 representando terrenos con arbustos y prados, y -1 indicando la presencia de agua o superficies muy oscuras.

TGI (Índice de Verdor Triangular)

Los componentes clave del índice de verdor triangular (TGI) incluyen la utilización de imágenes de espectro visible para la estimación de la fracción de vegetación o la evaluación del contenido de clorofila en los cultivos (De Ocampo et al., 2019). Se ha demostrado que el TGI es una métrica valiosa para el monitoreo de la salud de los cultivos, ya que su rendimiento depende de la comprensión de la sensibilidad a las longitudes de onda de los sensores CMOS utilizados para capturar imágenes RGB de los cultivos (Lemes et al., 2022). Además, el TGI ha demostrado su eficacia en la detección temprana de las lesiones causadas por el estrés abiótico, como la fitotoxicidad de los herbicidas, lo que lo convierte en un índice espectral práctico para evaluar la salud de las plantas y los niveles de lesiones (Xing et al., 2020). Además, se ha propuesto un nuevo índice denominado índice de vegetación triangular transformado (TTVI) para la recuperación del índice de área foliar (LAI), que sustituya el NIR y las bandas rojas por bandas NIR y de borde rojo para mejorar las estimaciones del LAI y mitigar los efectos de saturación, lo que demuestra una alta precisión en los escenarios de cobertura vegetal de baja a moderada y moderada a alta (Moffiet et al., 2010).

La fórmula del TGI se expresa como:

$$\text{TGI} = \text{Green} - 0.39 * \text{Red} - 0.61 * \text{Blue}$$

(Hunt et al., 2012)

Rango de valores: -1 a 1 valores cercanos a 1: alta densidad de biomasa, valores cercanos a 0: menor cantidad de biomasa o estrés.

NDWI (Índice de Agua de Diferencia Normalizada)

índice diferencial normalizado del agua (NDWI) se basa en los valores de reflectancia en verde e infrarrojo cercano, es un índice espectral que se usa comúnmente para detectar la presencia de agua en diferentes entornos (Augusto et al., 2022). Las investigaciones han demostrado que el NDWI, junto con otros índices hídricos, como el índice (NDWI) y el índice de ratio hídrico (WRI), pueden monitorear eficazmente la erosión y la acumulación de las riberas de los ríos, lo que ayuda a analizar los cambios en las masas de agua superficiales (Laonamsai et al., 2023; Liu et al., 2023). La integración del NDWI con el índice diferencial normalizado de calor latente (NDLI) ha demostrado ser fundamental para evaluar la salud de las plantas y detectar las condiciones de escasez de agua en los entornos agrícolas, lo que destaca su importancia en el monitoreo y el manejo de los cultivos (Son Le et al., 2023). Por último, el cálculo del índice diferencial normalizado de sequía (NDDI) mediante la combinación del NDWI con el índice diferencial de vegetación normalizado (NDVI) ha permitido mapear la gravedad de la sequía en regiones como la regencia de Bojonegoro, lo que ha ayudado a los esfuerzos de mitigación de desastres y a la gestión de los recursos hídricos (Artikanur et al., 2022).

La fórmula del NDWI se expresa como:

$$\text{NDWI} = \frac{(\text{GREEN} - \text{NIR})}{(\text{GREEN} + \text{NIR})}$$

(McFeeters, 1996)

Rango de valores: entre -1 y +1, donde (más cercanos a +1) indican un alto contenido de agua, lo que facilita la identificación de las masas de agua abiertas, mientras que los valores negativos (más cercanos a -1) indican áreas dominadas por vegetación o suelo.

MATERIALES Y MÉTODOS

Área de estudio

El estudio se realizó en el campo agrícola experimental denominado Jardín Hidráulico de la Universidad Autónoma Agraria Antonio Narro, ubicado al sur de la ciudad de Saltillo, Coahuila de Zaragoza. Sus coordenadas (en grados decimales) son: Latitud 25.3576127 y Longitud -101.0405497, a 1743 metros sobre el nivel del mar. La temperatura y precipitación media anual son 16.9 °C y 435 mm, respectivamente (**Figura 12**). El lote experimental fue una superficie de 420 m², equipada con un sistema de riego por goteo, con una separación entre goteros de 20 cm y un gasto de 2.0 l/min. El sistema se divide en 4 secciones, cada una con 3 válvulas que permitieron la aplicación de los tratamientos de manera independiente en cada sección. Además, el sistema incluye un dispositivo Venturi para la aplicación de fertilizantes.

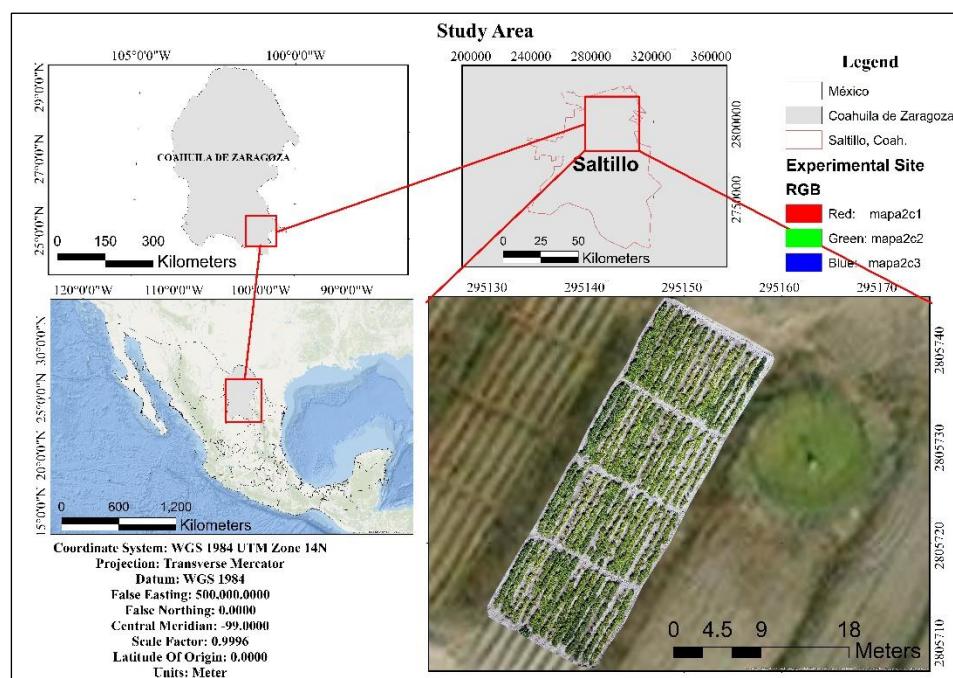


Figura 12. Mapa de ubicación del área de estudio

Manejo Agronómico del Cultivo y Tratamientos Evaluados

El 15 de agosto de 2023, se sembró el frijol ‘Flor de Mayo AN-05’ con una separación de 80 cm entre surcos y 10 cm entre plantas. Se utilizó un diseño de parcelas divididas al azar, donde el Factor A fue la posición de la cinta de riego (superficial o enterrada) y el Factor B fue el nivel de tensión de humedad del suelo (20, 30 y 50 kPa). Se establecieron seis tratamientos, repetidos cuatro veces (**Cuadro 3**). Se usó la prueba de Tukey para comparar las medias. Cada parcela tenía 2 surcos de 8 m para la cinta enterrada y 3 surcos de 4 m para la cinta superficial. La tensión de humedad se midió con dos tensíómetros (marca Irrometer, Irrometer, Inc., Riverside, CA, EE. UU.) de 30 cm de longitud, enterrados a 20 cm de profundidad en el centro de la cama en tres repeticiones de cada tensión de humedad.

Cuadro 3. Factores principales de estudio y tratamientos correspondientes.

Factor A	Factor B	
Posición de la cinta de riego	Tensión de humedad del suelo (kPa)	Tratamiento
Superficie	20	T1
Superficie	30	T2
Superficie	50	T3
Enterrada	20	T4
Enterrada	30	T5
Enterrada	50	T6

La dosis de fertilización establecida para el ciclo de producción fue de 200-50-100, aplicando el 25% al inicio del ciclo del cultivo, el 50% en la etapa de floración y el 25% en la etapa de llenado de grano. Adicionalmente, se realizaron 3 aplicaciones foliares de macronutrientes, ‘Grofol 20-30-10’ a una dosis de 1 kg/ha, y el complejo de micronutrientes quelatados ‘Ultrasol micro Rexene BSP Mix’ a una concentración de 2 g por litro de agua, a los 23, 42 y 56 días después de la siembra (DDS). Se complementó con el enraizador ‘Magic Root’ a una dosis de 2 kg por hectárea, y el coadyuvante agrícola ‘Phase-1’ para mejorar la eficacia de las aplicaciones, regulando el pH del agua a un valor

de 6.0. Para el control fitosanitario, se realizó una aplicación de benomilo (300 g/ha) para el control preventivo de hongos a los 24 DDS. La segunda aplicación a los 43 DDS con Imidacloprid (0.3 l/ha) y cipermetrina (0.25 l/ha) fue para el control de gusano cortador (*Agrotis spp.*) y chapulín (*Brachystola magna*). A los 59 DDS (inicio de la etapa de floración), se aplicó el bioestimulante ‘Maxi-Grow Excel’ (0.5 l/ha).

Tensión de Humedad del Suelo

Para determinar el contenido de agua en el suelo para cada valor de tensión, se realizaron mediciones simultáneas del contenido de agua en el suelo. Estas se midieron con una sonda TDR (Time Domain Reflectometry) con varillas de 20 cm de longitud (modelo HydroSense II, Campbell Scientific, Inc., Logan, Utah, USA) y el promedio de 3 tensímetros de la marca Irrometer, cuya cápsula porosa se enterró a una profundidad de 20 cm. Las mediciones se realizaron desde saturación hasta una tensión de 62 kPa. La Figura 2 muestra la relación entre el contenido de agua en el suelo (% en volumen) y la tensión de la humedad correspondiente. También se muestra la función (polinomio de segundo orden) y sus coeficientes que describen dicha relación (**Figura 2**).

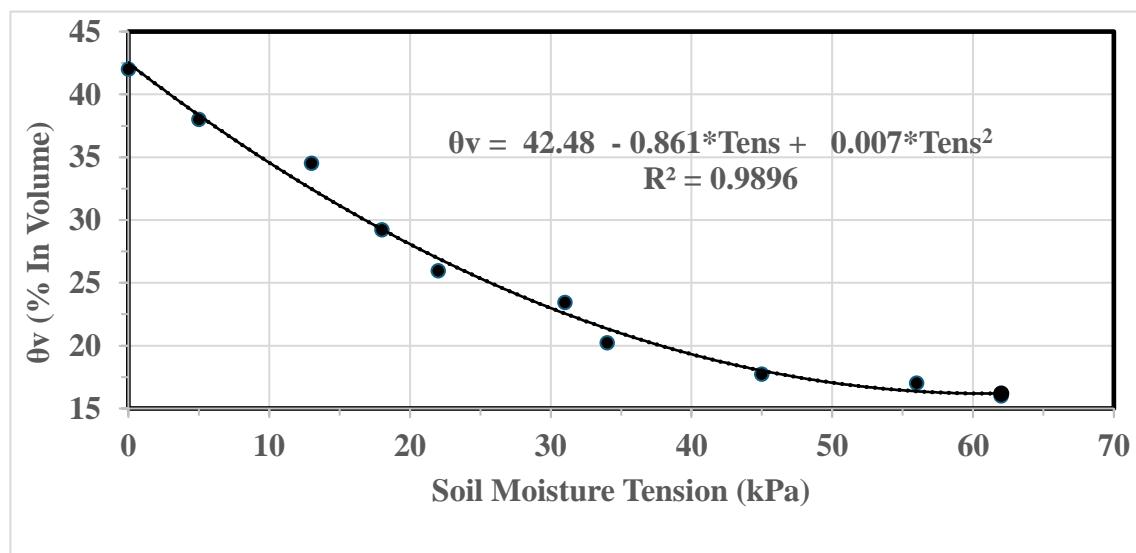


Figura 13. Relación entre el contenido de agua en el suelo y la tensión de humedad correspondiente del suelo del sitio de estudio.

Adquisición de Imágenes

La captura de imágenes inició el 13 de octubre de 2023 a los 59 DDS, continuando con mediciones al alcanzar las tensiones de humedad del suelo (20, 30 y 50 kPa), seguidas por el tratamiento de riego. El último levantamiento fue el 6 de diciembre de 2023. Se utilizó una aeronave Phantom 4 Pro (DJI Technology Co., Ltd.) (**Figura 3a**), pilotada de manera remota, a la cual se le acopló un sensor multiespectral RedEdge-MX™ (MicaSense, Seattle, WA, EE. UU.) (**Figura 3b**).

Las imágenes se capturaron en formato TIFF de 16 bits (1280 x 960), autocalibradas con el sensor solar DLS 2 y GPS integrado (**Figura 3c**). Se usó la aplicación DJI GS PRO (DJI Technology Co., Ltd.) para planificar la misión, que aprovecha el GNSS (Sistema Global de Navegación por Satélite) de la aeronave para realizar vuelos autónomos. Los parámetros de vuelo incluyeron una velocidad de 9.6 km/h, altura de 20 m, tiempo de captura de 1.0 s, y solapamiento de las imágenes del 80%. Esto resultó en un GSD (Distancia de Muestreo del Suelo) de 1.4 cm/píxel.

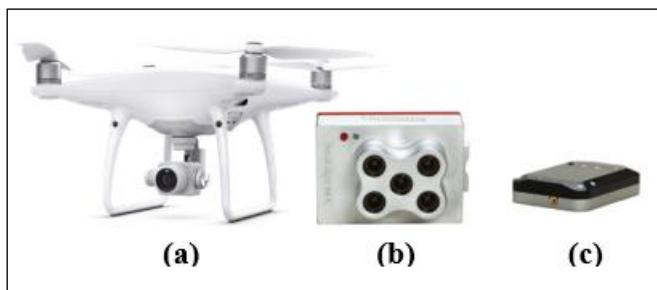


Figura 14. Equipo utilizado para el levantamiento de imágenes: (a) Cámara multiespectral; (b) Sensor solar (DLS 2); (c) RPA utilizado para el estudio.

Procesamiento de Imágenes Multiespectrales

Se usó Pix4Dmapper (v.4.6.4, Pix4D S.A., Prilly, Suiza) para procesar las imágenes y obtener los índices de vegetación (BNDVI, GNDVI, LCI, MCARI, NDRE, NDVI, NDWI, Sipi2 y TGI), y el ortomosaico de reflectancia de bandas (Azul, Verde, NIR, Red Edge y Rojo). Se calcularon promedios de índices y niveles digitales en áreas de muestreo definidas por tratamientos, usando GCP (Ground Control Point) para alinear los resultados. La resolución espacial GSD se ajustó a 2 cm/píxel para uniformidad, calidad y detalle.

Extracción de Regiones de Interés

Para cada uno de los tratamientos y repeticiones en los bloques, se empleó una máscara de tipo Shape para realizar la extracción del promedio de los índices y las bandas. Se crearon zonas de muestreo rectangulares de 2 metros x 0.20 metros, con un total de 3 por cada repetición en el bloque del tratamiento (**Figura 4**). Cuando se obtuvieron las áreas de muestreo, se desarrolló un script en Python que permitió calcular la media de cada bloque correspondiente a los tratamientos.

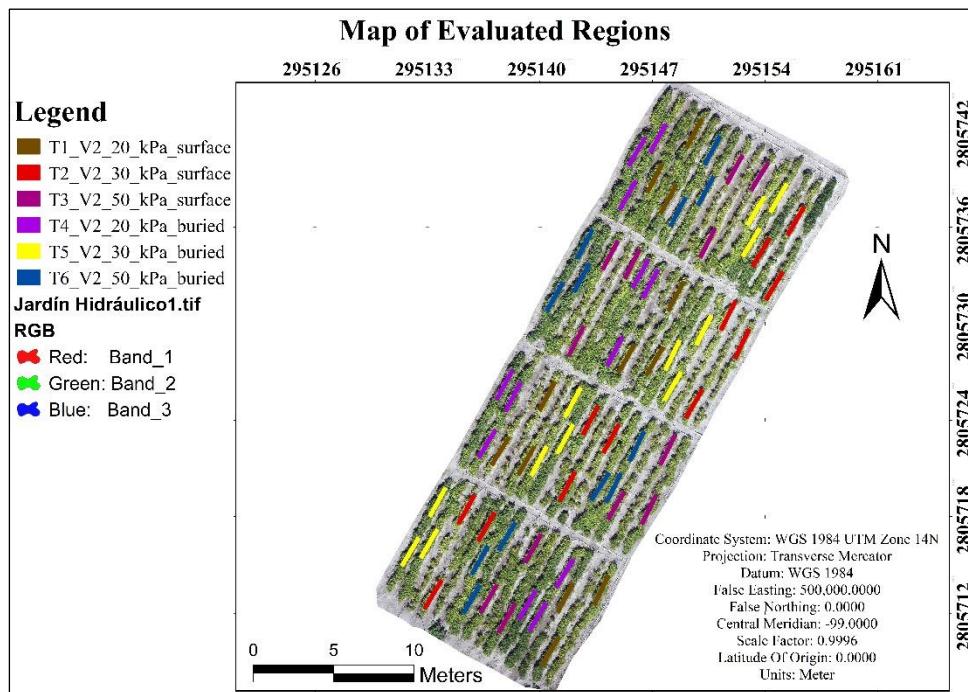


Figura 15. Descripción y distribución de los tratamientos en el campo evaluados.

Evaluación Estadística

Se analizaron estadísticamente los índices de vegetación y reflectancia de bandas, aplicando pruebas de Shapiro-Wilk (W ; $p \leq 0.05$), Bartlett (B ; $p \leq 0.05$) y ANOVA para determinar diferencias significativas entre factores A y B y la interacción. Se usó R Studio versión (v x, R Core Team, Viena, Austria) para el análisis descriptivo y comparar la variabilidad de los datos. Los índices y bandas con mayor variación y significancia fueron: NDRE (índice borde rojo de diferencia normalizada), TGI (índice de verdor triangular), NDWI (índice de agua de diferencia normalizada), banda Roja y banda Red Edge.

RESULTADOS Y DISCUSIÓN

Variable de Respuesta Índice de Vegetación NDRE

El análisis de varianza (ANOVA) realizado para los factores A y B demuestra disparidades notables en el índice NDRE. En concreto, el impacto de estar enterrado o en la superficie en el índice NDRE del factor A es estadísticamente significativo ($p = 0,0223$). Del mismo modo, en el factor B, la tensión ejerce una influencia significativa ($p = 0,00482$). A pesar de la falta de significancia estadística en la interacción entre los factores A y B ($p = 0,06442$), la proximidad al umbral de 0,05 sugiere explorar más a fondo esta interacción. Como se muestra en la (Figura 5, el índice NDRE muestra un valor más alto para la cinta enterrada en comparación con la cinta superficial. Este resultado coincide con las observaciones de (Griffin-LaHue et al., 2023), quienes observaron que la cinta enterrada a una profundidad de 0,15 m producía niveles de humedad más uniformes en comparación con la cinta superficial. Además, el uso de cintas de goteo enterradas, tal como sugieren (Adrian Card & Troy Bauder, 2019), prevén la pérdida de humedad en la superficie y garantiza la disponibilidad de agua en las zonas radiculares, optimizando así la eficacia del crecimiento de las plantas.

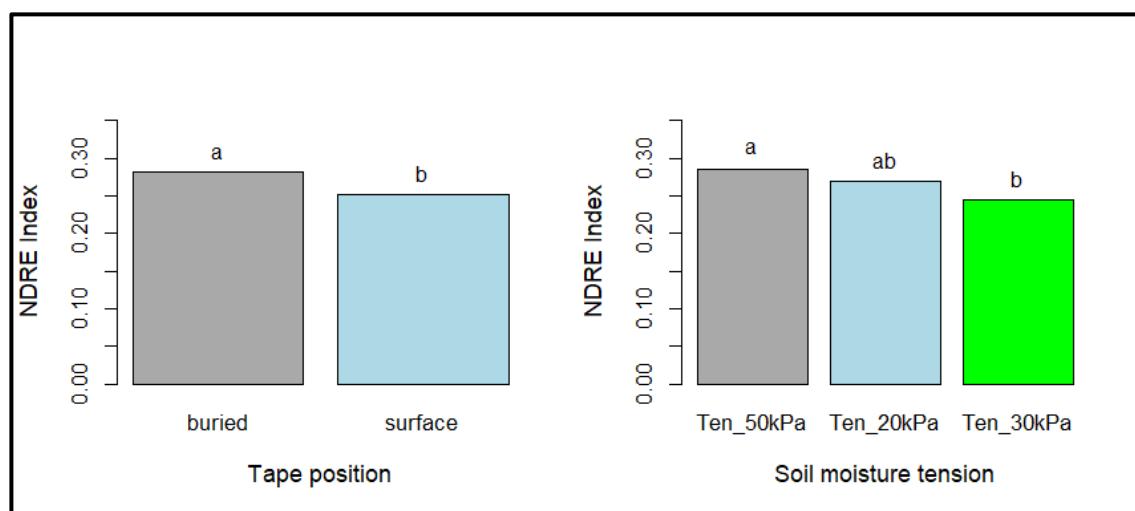


Figura 16. Efecto de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para riego aplicada sobre el índice NDRE de un cultivo de frijol (cv. Flor de mayo).

Variable de Respuesta Índice de Vegetación TGI

Los resultados del análisis de varianza (ANOVA) coinciden con los de las pruebas realizadas, lo que indica una disparidad notable en el factor A (valor $p = 0.464$) y revela un contraste estadísticamente significativo en el factor B (valor $p = 3.33e-07$), lo que implica una influencia considerable en el índice TGI. La interacción entre el factor A y el factor B tuvo un impacto significativo en el índice TGI (valor $p = 0.0396$), lo que ofrece una posible explicación de las variaciones observadas en los valores del índice de vegetación TGI en las diferentes tensiones de humedad del suelo (**Figura 6**). Estos hallazgos concuerdan con la investigación realizada por (Cui et al., 2022), que subraya la capacidad de las condiciones de humedad del suelo para modificar sustancialmente los valores del índice de vegetación en diferentes estaciones y elevaciones. Además, (Zhang et al., 2023) observaron que los índices de vegetación, incluido el índice diferencial de vegetación normalizado (NDVI), muestran sensibilidad a las alteraciones de la humedad del suelo y muestran una correlación casi lineal entre el NDVI y el contenido de agua del suelo.

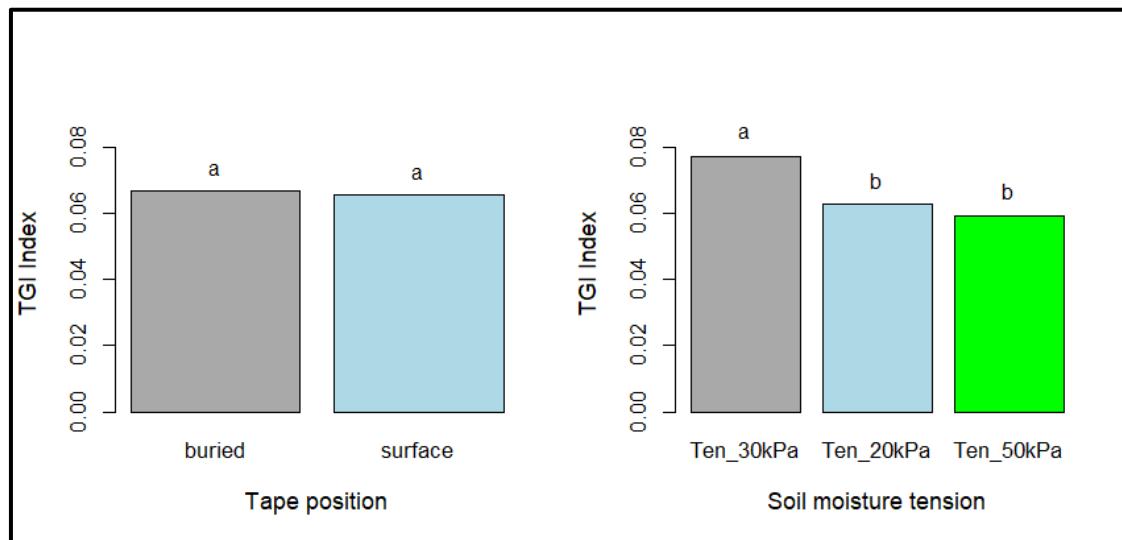


Figura 17. Efecto de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para riego aplicada sobre el índice TGI de un cultivo de frijol (cv.

Variable de Respuesta Índice de Vegetación NDWI

El enfoque ideado por (McFeeters, 1996) utiliza el índice diferencial de agua normalizado (NDWI) para detectar cuerpos de agua basándose en los datos obtenidos de imágenes de teledetección. No obstante, es imprescindible reconocer que el contenido de humedad de las hojas puede afectar a las lecturas del NDWI. A pesar de esto, estas lecturas no pueden equipararse directamente a las adquiridas al analizar los cuerpos de agua. Específicamente, la vegetación, como los árboles, a menudo presenta valores negativos de NDWI según el método de McFeeters, que se encuentran dentro del rango de -0,55 a -1, como lo demuestran (Pereira et al., 2018). Mediante la aplicación de esta técnica, se han observado variaciones notables en la cinta enterrada en comparación con la posición de la superficie. Además, una tendencia observable indica una disminución sustancial de los valores del NDWI al aumento de la tensión de humedad del suelo de 20 a 50 kPa, como se ilustra en la (Figura 7). (Quemada et al., 2021) atribuyen este fenómeno a las variaciones en la reflexión de la luz por parte de las hojas que dependen de su contenido de agua.

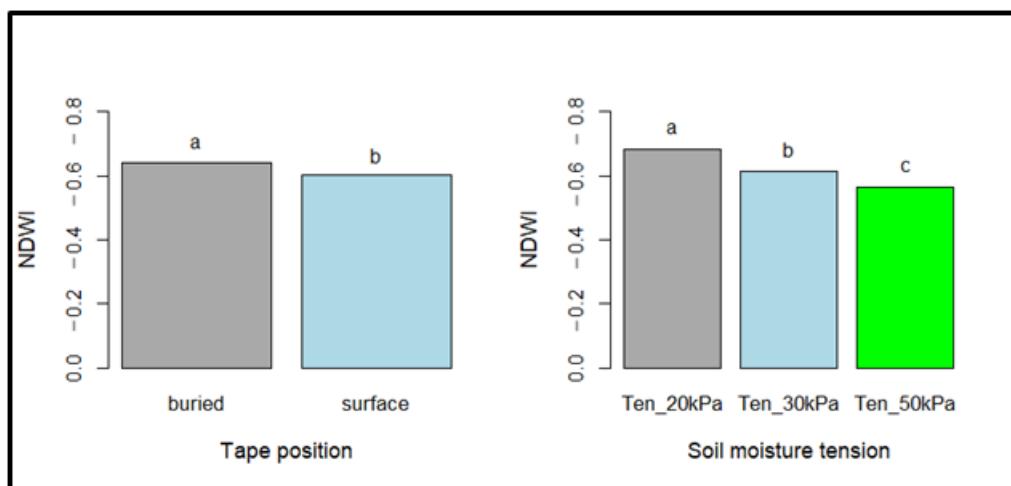


Figura 18. Efecto de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para riego aplicada sobre el NDWI (valores absolutos) de un cultivo de frijol (cv Flor de mayo).

Variable de Respuesta Reflectancia Red Edge Band

Según los hallazgos adquiridos, la interacción observada entre los componentes principales sugiere que la posición de la cinta y la tensión del suelo experimentado por el cultivo de frijol influyen significativamente en los niveles de reflectancia de la banda Red Edge. Estas interacciones muestran una variabilidad basada en las condiciones específicas de humedad del suelo. Se puede identificar el valor máximo de reflectancia en la cinta enterrada y a una tensión de humedad del suelo de 30 kPa (consulte la **Figura 8**). Una investigación de (S. Lin et al., 2019) demostró que la reflectancia de Red Edge responde a los niveles de clorofila en las hojas, un parámetro directamente relacionado con el proceso de fotosíntesis. Por otra parte, (Shi et al., 2023) sostienen que una mayor concentración de clorofila generalmente se correlaciona con una mejora en salud y el rendimiento de los cultivos, y enfatizan su importancia como un indicador crucial para los agricultores y los investigadores.

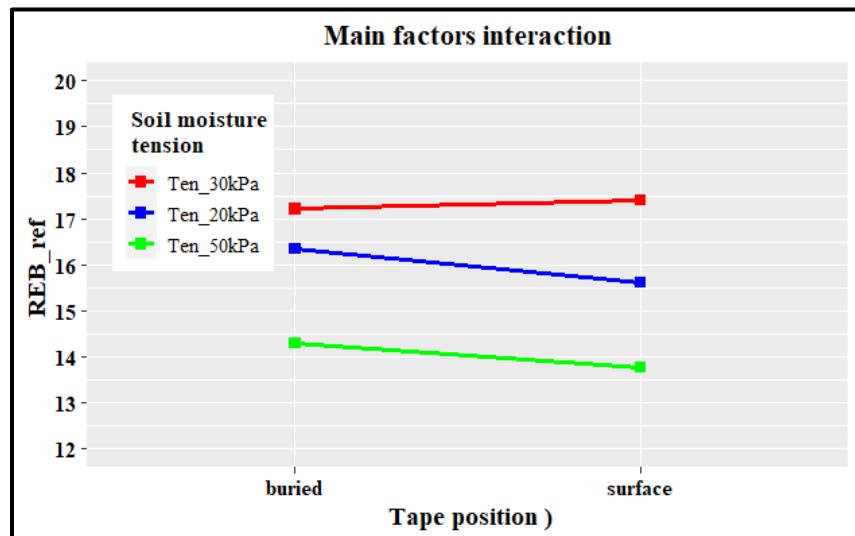


Figura 19. Interacción entre la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para el riego aplicada sobre la reflectancia de la Banda de Borde Rojo (miles) de un cultivo de frijol (cv Flor de mayo).

Variable de Respuesta Reflectancia Red

En el análisis de reflectancia para la banda del rojo, se observa que la cinta en superficie a una tensión de humedad del suelo de 30 kPa presenta los mayores valores de reflectancia (**Figura 9**). Esta interacción indica que la cinta en superficie es especialmente efectiva para maximizar la reflectancia bajo condiciones de humedad moderada. Como indica (Xue & Su, 2017), la banda roja es esencial para generar los índices de vegetación, ya que evalúa la salud de las plantas a través de la absorción de la luz roja por la clorofila; los cambios en la reflectancia podrían sugerir que las plantas están sufriendo estrés causado por problemas como la disponibilidad limitada de agua, la insuficiencia de nutrientes o las enfermedades.

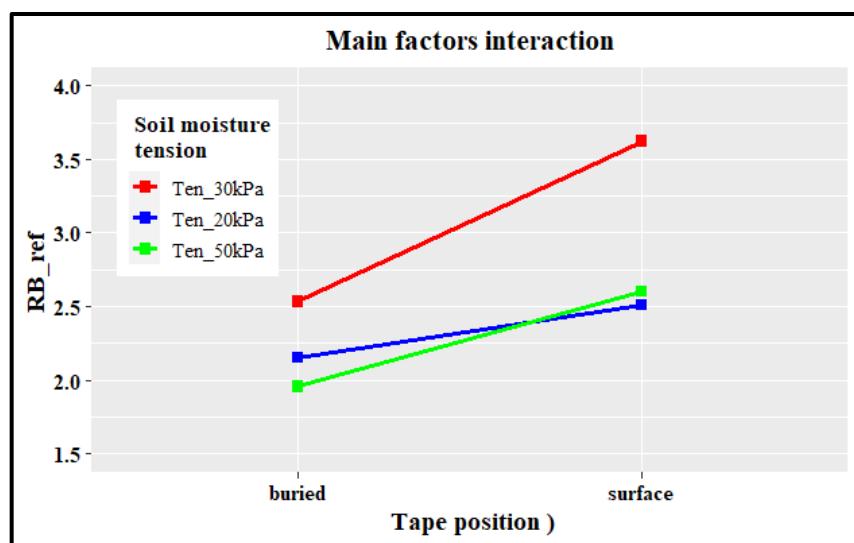


Figura 20. Interacción de la posición de la cinta de riego (enterrada, superficial) y la tensión de humedad del suelo para el riego aplicada sobre la reflectancia de la Banda Roja (miles) de un cultivo de frijol (cv Flor de mayo).

CONCLUSIONES

La influencia de la posición de la cinta (ya sea enterrada o en la superficie) tiene un efecto considerable en los índices NDRE y NDWI. La cinta enterrada exhibe valores más altos, lo que significa una menor vulnerabilidad a las fluctuaciones en la humedad del suelo y una mejor utilización del agua. Apoyando esta observación, el análisis ANOVA revela una notable disparidad en el índice NDRE basado en la ubicación de la cinta ($p = 0.0223$). El índice NDWI demostró una eficacia superior en la detección del estrés hídrico, el índice NDWI disminuyen progresivamente a medida que la tensión hídrica aumenta de 20 a 50 kPa. Es importante destacar que un nivel de 20 kPa resulta ser el más propicio para obtener un alto valor de NDWI.

La interacción significativa entre la posición de la cinta y los niveles de humedad influyen en el índice TGI, manifestando su impacto en las variaciones de reflectancia y los índices de vegetación. Particularmente, un nivel de tensión de 30 kPa afecta de manera prominente esta interacción, lo que resulta en una elevada reflectancia en las bandas Red Edge y Red cuando la cinta se coloca en la superficie.

Los resultados indican que tanto la ubicación de la cinta como el estrés por humedad del suelo juegan un papel fundamental en los índices de vegetación NDRE, NDWI y TGI. La cinta enterrada confiere una ventaja en la mejora de estos índices, potencialmente debido a la menor exposición a las fluctuaciones en la humedad de la superficie.

REFERENCIAS

- Abbas, A., Zhang, Z., Zheng, H., Alami, M. M., Alrefaei, A. F., Abbas, Q., Naqvi, S. A. H., Rao, M. J., Mosa, W. F. A., Abbas, Q., Hussain, A., Hassan, M. Z., & Zhou, L. (2023). Drones in Plant Disease Assessment, Efficient Monitoring, and Detection: A Way Forward to Smart Agriculture. In *Agronomy* (Vol. 13, Issue 6). <https://doi.org/10.3390/agronomy13061524>
- Abduganiev, M., & Gafurov, S. (2023). Application of two variable hermite splines in digital image processing. *InterConf*, 34(159). <https://doi.org/10.51582/interconf.19-20.06.2023.030>
- Adrian Card, & Troy Bauder. (2019). *Determining Irrigation Run Times with Drip Tape on Specialty Crops*.
- Aguirre, J. (2022). *An image sensor based on single-pulse photoacoustic electromagnetic detection (SPEED): a simulation study*.
- Aldaba, A. L., Lopez-Torres, D., Campo-Bescós, M. A., López, J. J., Yerro, D., Elosua, C., Arregui, F. J., Auguste, J. L., Jamier, R., Roy, P., & López-Amo, M. (2018). Comparison between capacitive and microstructured optical fiber soil moisture sensors. *Applied Sciences (Switzerland)*, 8(9). <https://doi.org/10.3390/app8091499>
- Al-doski, J., Bin Mansor, S., & Zulhai Bin Mohd Shafri, H. (n.d.). THERMAL IMAGING FOR PESTS DETECTING-A REVIEW. *International Journal of Agriculture*, 2.
- Alfaro-Diaz, A., Escobedo, A., Luna-Vital, D. A., Castillo-Herrera, G., & Mojica, L. (2023). Common beans as a source of food ingredients: Techno-functional and biological potential. In *Comprehensive Reviews in Food Science and Food Safety* (Vol. 22, Issue 4). <https://doi.org/10.1111/1541-4337.13166>
- Alomari-Mheidat, M., Martín-Palomo, M. J., Castro-Valdecantos, P., Medina-Zurita, N., Moriana, A., & Corell, M. (2023). Effect of Water Stress on the Yield of Indeterminate-Growth Green Bean Cultivars (*Phaseolus vulgaris* L.) during the Autumn Cycle in Southern Spain. *Agriculture (Switzerland)*, 13(1). <https://doi.org/10.3390/agriculture13010046>
- Anikeeva, I. A. (2020). Radiometric resolution and dynamic range of aerial and space images, obtained for monitoring and mapping purposes. *Geodezia i Kartografia*, 964(10). <https://doi.org/10.22389/0016-7126-2020-964-10-40-48>
- Artikanur, S. D., Widiatmaka, Setiawan, Y., & Marimin. (2022). Normalized Difference Drought Index (NDDI) computation for mapping drought severity in Bojonegoro Regency, East Java, Indonesia. *IOP Conference Series: Earth and Environmental Science*, 1109(1). <https://doi.org/10.1088/1755-1315/1109/1/012027>
- Augusto, R. C., Cruz, C. B. M., da Silva Seabra, V., & Martins, J. S. (2022). Delineation of

- riparian zones in plains using the Normalized Difference Water Index (NDWI) and Landsat multitemporal series. *Revista Brasileira de Geografia Física*, 15(1). <https://doi.org/10.26848/rbgf.v15.1.p234-249>
- Aziziaram, Z., Cheghamirza, K., Zarei, L., & Beheshti-Alagha, A. (2021). Chemical and morphological characteristics of common bean seed and evaluating genetic advance in commercial classes. *Cellular and Molecular Biology*, 67(6). <https://doi.org/10.14715/cmb/2021.67.6.13>
- Bahcivan, H., Brady, D. J., & Hageman, G. C. (2022). *Radiometric sensitivity and resolution of synthetic tracking imaging for orbital debris monitoring*. <http://arxiv.org/abs/2211.09789>
- Baldi, S., Roy, S., Yang, K., & Liu, D. (2022). An Underactuated Control System Design for Adaptive Autopilot of Fixed-Wing Drones. *IEEE/ASME Transactions on Mechatronics*, 27(5). <https://doi.org/10.1109/TMECH.2022.3144459>
- Becerra, A. T., Bolívar, X., Bravo, L., José, V., & Membrive, F. (2013). *HUELLA HÍDRICA Y SOSTENIBILIDAD DEL USO DE LOS RECURSOS HÍDRICOS. Aplicación al Poniente Almeriense. Estudios previos y medidas de eficiencia*. https://doi.org/10.5209/rev_MARE.2013.v14.n1.42123
- Bel, G., & Bandi, M. M. (2019). Geographic dependence of the solar irradiance spectrum at intermediate to high frequencies. *Physical Review Applied*, 12(2). <https://doi.org/10.1103/PhysRevApplied.12.024032>
- Bello, A. B., Navarro, F., Raposo, J., Miranda, M., Zazo, A., & Álvarez, M. (2022). Fixed-Wing UAV Flight Operation under Harsh Weather Conditions: A Case Study in Livingston Island Glaciers, Antarctica. *Drones*, 6(12). <https://doi.org/10.3390/drones6120384>
- Benkouider, Y. K., Benhalouche, F. Z., Karoui, M. S., & Iftene, M. (2022). Nonnegative Tensor Factorization Based Fusion for Changes Detection in Multiresolution Remote Sensing Images. *2022 IEEE Mediterranean and Middle-East Geoscience and Remote Sensing Symposium, M2GARSS 2022 - Proceedings*. <https://doi.org/10.1109/M2GARSS52314.2022.9840208>
- Bertrand, S., & Shin, H. S. (2023). Special Issue on Unmanned Aerial Vehicles. In *Applied Sciences (Switzerland)* (Vol. 13, Issue 7). <https://doi.org/10.3390/app13074134>
- Bhatt, R., Doelling, D., Haney, C., Scarino, B., & Gopalan, A. (2018). Consideration of radiometric quantization error in satellite sensor cross-calibration. *Remote Sensing*, 10(7). <https://doi.org/10.3390/rs10071131>
- Bian, L., Wang, Z., Zhang, Y., Zhang, Y., Yang, C., Li, L., Fang, W., Zhao, J., Zhu, C., Zheng, D., & Zhang, J. (2023). A *low-cost integrated hyperspectral imaging sensor with full*

- temporal and spatial resolution at VIS-NIR wide range.* <http://arxiv.org/abs/2306.11583>
- Bijalwan, P., Sharma, M., & Kaushik, P. (2022). Review of the Effects of Drought Stress on Plants : A Systematic Approach. *Preprints*.
- Blair, M. W., Li, H., Nekkalapudi, L., Becerra, V., & Paredes, M. (2023). Nutritional Traits of Beans (*Phaseolus vulgaris*): Nutraceutical Characterization and Genomics. In *Compendium of Crop Genome Designing for Nutraceuticals*. https://doi.org/10.1007/978-981-19-3627-2_23-1
- Boiarskii, B. (2019). Comparison of NDVI and NDRE Indices to Detect Differences in Vegetation and Chlorophyll Content. *JOURNAL OF MECHANICS OF CONTINUA AND MATHEMATICAL SCIENCES*, *sp1*(4). <https://doi.org/10.26782/jmcms.sp1.4/2019.11.00003>
- Boonupara, T., Udomkun, P., & Kajitvichyanukul, P. (2024). Quantitative Analysis of Atrazine Impact on UAV-Derived Multispectral Indices and Correlated Plant Pigment Alterations: A Heatmap Approach. *Agronomy*, *14*(4). <https://doi.org/10.3390/agronomy14040814>
- Bustos, O. H. (2014). *Introducción a los procesos markovianos en el análisis y procesamiento de imágenes*.
- Cardim, M., & Lima, F. (2019). *Development of Multispectral Indices for Organic Fertilization Monitoring in Tomato Plants at Early Stages* UNIVERSITAT POLITÈCNICA DE VALÈNCIA DEPARTMENT OF AGROFORESTRY ECOSYSTEMS Master's Degree in Plant Health in Sustainable Cropping Systems.
- Carella, A., Bulacio Fischer, P. T., Massenti, R., & Lo Bianco, R. (2024). Continuous Plant-Based and Remote Sensing for Determination of Fruit Tree Water Status. *Horticulturae*, *10*(5), 516. <https://doi.org/10.3390/horticulturae10050516>
- Chilveri, S., Jain, T., & Mhaske, Prof. H. (2023). Satellite Image Processing Using Radiometric Resolution & Spectral Resolution. *International Journal for Research in Applied Science and Engineering Technology*, *11*(3). <https://doi.org/10.22214/ijraset.2023.49300>
- Chouhan, S., Kumari, S., Kumar, R., & Chaudhary, P. L. (2023). Climate Resilient Water Management for Sustainable Agriculture. *International Journal of Environment and Climate Change*, *13*(7). <https://doi.org/10.9734/ijecc/2023/v13i71894>
- Christopher, V. , H. (2017). *AGRICULTURAL DRONE FOR USE IN CONTROLLING THE DIRECTION OF TILLAGE AND APPLYING MATTER TO A FIELD*.
- Chucos Baquerizo, N., & Vega Ventocilla, E. J. (2022). Evaluación de algoritmos de machine learning en la clasificación de imágenes satelitales multiespectrales, caso: Amazonia Peruana. *Ciencia Latina Revista Científica Multidisciplinar*, *6*(1). https://doi.org/10.37811/cl_rcm.v6i1.1843

- Chun, C. V., De Jesús Peña Uribe, G., Santos, A. L., & De Jesús Meraz Jiménez, A. (2023). An index of environmental and cultural suitability for the cultivation of climateresilient castor bean in rainfed low-productivity common lands in Mexico. *Italian Journal of Agronomy*, 18(1). <https://doi.org/10.4081/ija.2023.2107>
- Coelho, A. P., de Faria, R. T., Lemos, L. B., Dos Reis, M. A. M., Filla, V. A., & Bertino, A. M. P. (2022). Irrigation management of common bean cultivars with contrasting growth habits. *Scientia Agricola*, 80. <https://doi.org/10.1590/1678-992X-2022-0038>
- Collatz, W., McKee, L., Coopmans, C., Torres-Rua, A. F., Nieto, H., Parry, C., Elarab, M., McKee, M., & Kustas, W. (2018). *Inter-comparison of thermal measurements using ground-based sensors, UAV thermal cameras, and eddy covariance radiometers*. <https://doi.org/10.1111/12.2305832>
- CONAGUA (2017) Estadísticas Agrícolas de las Unidades de Riego Comisión Nacional del Agua. Consulta: 04 junio 2024. Disponible en: <https://www.gob.mx/conagua/documentos/estadisticas-agricolas-de-unidades-de-riego>
- CONAGUA (2020) Programa Nacional Hídrico 2020-2024 Resumen Comisión Nacional del Agua. Consulta: 04 junio 2024. Disponible en: <https://www.gob.mx/conagua/articulos/consulta-para-el-del-programa-nacional-hidrico-2019-2024-190499>
- CONAGUA (2022) Estadísticas del Agua en México 2021. Consulta: 04 junio 2024. Disponible en: <https://www.mendeley.com/reference-manager/reader-v2/9517a99b-c452-3899-acd1-5d7b265a11b7/0fb7216f-0242-32bd-6083-f2bdb76574b1>
- Conley, M. M., Thompson, A. L., & Hejl, R. (2023). Proximal Active Optical Sensing Operational Improvement for Research Using the CropCircle ACS-470, Implications for Measurement of Normalized Difference Vegetation Index (NDVI). *Sensors*, 23(11). <https://doi.org/10.3390/s23115044>
- Coops, N. C., & Tooke, T. R. (2017). Introduction to Remote Sensing. In *Learning Landscape Ecology* (pp. 3–19). Springer New York. https://doi.org/10.1007/978-1-4939-6374-4_1
- Costales Acurio, G. A. (2018). *Análisis comparativo entre los software de prueba Agisoft Photoscan y Pix4D para el procesamiento de datos obtenidos con fotogrametría de vehículo aéreo no tripulado (UAV) de bajo costo aplicado a proyectos de medio ambiente*.
- Cui, X., Xu, G., He, X., & Luo, D. (2022). Influences of Seasonal Soil Moisture and Temperature on Vegetation Phenology in the Qilian Mountains. *Remote Sensing*, 14(15). <https://doi.org/10.3390/rs14153645>

- Dalin, C., Wada, Y., Kastner, T., & Puma, M. J. (2017). Groundwater depletion embedded in international food trade. *Nature*, 543(7647). <https://doi.org/10.1038/nature21403>
- De La Casa, A., & Ovando, G. (2007). Integración del Índice de Vegetación de la Diferencia Normalizada (NDVI) y del ciclo fenológico de maíz para estimar el rendimiento a escala departamental en Córdoba, Argentina. *Agricultura Técnica*, 67(4). <https://doi.org/10.4067/s0365-28072007000400004>
- De Ocampo, A. L. P., Bandala, A. A., & Dadios, E. P. (2019). Estimation of Triangular Greenness Index for Unknown PeakWavelength Sensitivity of CMOS-acquired Crop Images. *2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management, HNICEM 2019*. <https://doi.org/10.1109/HNICEM48295.2019.9072796>
- Degollada, E., Amigó, N., O'Callaghan, S. A., Varola, M., Ruggero, K., & Tort, B. (2023). A Novel Technique for Photo-Identification of the Fin Whale, *Balaenoptera physalus*, as Determined by Drone Aerial Images. *Drones*, 7(3). <https://doi.org/10.3390/drones7030220>
- Delanhese, B. C. do N. S., Pacobello, D. R., Benedicto, S. C. De, & Georges, M. R. R. (2023). Water footprint: a study on crepe adhesive tape. *Periódico Eletrônico Fórum Ambiental Da Alta Paulista*, 19(1). <https://doi.org/10.17271/1980082719120233521>
- Derkachev, V., Bakhchevnikov, V., & Bakumenko, A. (2023). MULTI-ROTOR UAV CLASSIFIER. *IZVESTIYA SFedU. ENGINEERING SCIENCES*, 2. <https://doi.org/10.18522/2311-3103-2023-2-90-99>
- Devyatkin, D. A. (2023). Estimation of Vegetation Indices With Random Kernel Forests. *IEEE Access*, 11. <https://doi.org/10.1109/ACCESS.2023.3261129>
- Dewi, O., Kom, S., Kom, M., & Setiyadi, A. (2003). *REMOTE SENSING IPENGINDERAAN JAUHI*.
- Dinh, T., Nguyen, T., Phan, H. P., Dau, V., Dao, D., & Nguyen, N. T. (2022). Physical Sensors: Thermal Sensors. In *Encyclopedia of Sensors and Biosensors: Volume 1-4, First Edition* (Vols. 1–4). <https://doi.org/10.1016/B978-0-12-822548-6.00052-2>
- Domingues, R., Pereira, A. B., Schiebelbein, L. M., & Barbosa, E. A. A. (2018). Beans cultivation and water regime on soil physical attributes. *Agricultural Engineering International: CIGR Journal*, 20(3).
- Dong, L., Gangyi, D., Dapeng, Y., & Kexiang, H. (2023). Image defogging algorithm and artificial intelligence technology innovation application in digital media image processing. *Soft Computing*. <https://doi.org/10.1007/s00500-023-08473-6>
- dos Santos, J. de B. G., Hacon, S. de S., & Neves, S. M. A. da S. (2023). Normalized Difference Vegetation Index (NDVI) and its use in the study of human health: a scoping review. *Revista Brasileira de Geografia Física*, 16(3). <https://doi.org/10.26848/rbgf.v16.3.p1115-1144>

- Drozdowicz, J., & Samczynski, P. (2022). Drone-Based 3D Synthetic Aperture Radar Imaging with Trajectory Optimization. *Sensors*, 22(18). <https://doi.org/10.3390/s22186990>
- El-Hadidi, E. M., EL-Marsafawy, S. M., & Abdel- Fattah, I. M. (2014). THE AMOUNT OF WATER SHOULD BE APPLIED FOR FABA BEAN CROP UNDER DRIP AND DEFICIT IRRIGATION. *Journal of Soil Sciences and Agricultural Engineering*, 5(4). <https://doi.org/10.21608/jssae.2014.49334>
- Ennis, K. K., Quadri, P., Zhu, K., Philpott, S. M., & Millard-Ball, A. (2023). *Yield declines and producer responses to shifting climate and economic conditions in Mexican coffee production*.
- Estadísticas Agrícolas de las Unidades de Riego Comisión Nacional del Agua*. (2017).
- F. Y. Belen. (2022). *Imágenes hiperespectrales y su uso en la medicina*.
- Fabián Reuter, & Amilcar Pedenov. (2019). *LOS DRONES Y SUS APPLICACIONES A LA INGENIERÍA*.
- FAO (2019) Water Scarcity – One of the greatest challenges of our time. Consulta: 04 junio 2024. Disponible en: <https://www.fao.org/newsroom/story/Water-Scarcity-One-of-the-greatest-challenges-of-our-time/en>
- Fogaça, A. M., De Castro, A. G., & Barbosa, E. A. A. (2023). PHYSIOLOGICAL AND MORPHOLOGICAL RESPONSES OF TWO BEANS COMMON GENOTYPE TO WATER STRESS AT DIFFERENT PHENOLOGICAL STAGES. *Bioscience Journal*, 39. <https://doi.org/10.14393/BJ-v39n0a2023-59855>
- Fotiadou, K., Tsagkatakis, G., & Tsakalides, P. (2016). Spectral resolution enhancement of hyperspectral images via sparse representations. *IS and T International Symposium on Electronic Imaging Science and Technology*. <https://doi.org/10.2352/ISSN.2470-1173.2016.19.COIMG-169>
- Francis, R. J., Brandis, K. J., & McCann, J. A. (2022). Offline Imagery Checks for Remote Drone Usage. *Drones*, 6(12). <https://doi.org/10.3390/drones6120395>
- Fu, W., Wu, K., Liang, Z., Pang, T., & Qiu, Y. (2023). Construction Scheme of Precision Service Platform for Smart Farm. *Journal of Innovation and Development*, 3(2). <https://doi.org/10.54097/jid.v3i2.9393>
- Galdón, L., Garcia-Sucerquia, J., Saavedra, G., Martínez-Corral, M., & Sánchez-Ortiga, E. (2023). Resolution limit in opto-digital systems revisited. *Optics Express*, 31(2). <https://doi.org/10.1364/oe.479458>
- Gangadharan, K., Kumari, G. R. N., Dhanasekaran, D., & Malathi, K. (2020). Automatic detection of plant disease and insect attack using EFFTAA algorithm. *International Journal of Advanced Computer Science and Applications*, 2.

<https://doi.org/10.14569/ijacsa.2020.0110221>

García-Salazar, J. A., Bautista-Mayorga, F., & Reyes-Santiago, E. (2023). Factors conditioning the adoption rate of technified irrigation systems in Mexico. *Agronomia Mesoamericana*, 34(2). <https://doi.org/10.15517/am.v34i2.51202>

Garg, P. K. (2022). Characterisation of Fixed-Wing Versus Multirotors UAVs/Drones. *Journal of Geomatics*, 16(2). <https://doi.org/10.58825/jog.2022.16.2.44>

Giordani, W., Gama, H. C., Chiorato, A. F., Garcia, A. A. F., & Vieira, M. L. C. (2022). Genome-wide association studies dissect the genetic architecture of seed shape and size in common bean. *G3: Genes, Genomes, Genetics*, 12(4). <https://doi.org/10.1093/g3journal/jkac048>

Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS- MODIS. *Remote Sensing of Environment*, 58(3). [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)

Gitelson, A., & Merzlyak, M. N. (1994). Quantitative estimation of chlorophyll-a using reflectance spectra: Experiments with autumn chestnut and maple leaves. *Journal of Photochemistry and Photobiology, B: Biology*, 22(3). [https://doi.org/10.1016/1011-1344\(93\)06963-4](https://doi.org/10.1016/1011-1344(93)06963-4)

Gq, X. (2021). *Theory of Electromagnetic Spectrum*.

Griffin-LaHue, D., Wang, D., Gaudin, A. C. M., Durbin-Johnson, B., Settles, M. L., & Scow, K. M. (2023). Extended soil surface drying triggered by subsurface drip irrigation decouples carbon and nitrogen cycles and alters microbiome composition. *Frontiers in Soil Science*, 3. <https://doi.org/10.3389/fsoil.2023.1267685>

Guevara-Bonilla, M., Meza-Leandro, A. S., Esquivel-Segura, E. A., Arias-Aguilar, D., Tapia-Arenas, A., & Masís Meléndez, F. (2020). Uso de vehículos aéreos no tripulados (VANTS) para el monitoreo y manejo de los recursos naturales: una síntesis. *Revista Tecnología En Marcha*. <https://doi.org/10.18845/tm.v33i4.4528>

Guo, Q., Zhang, J., & Zhang, Y. (2021). Multitemporal Images Change Detection Based on AMMF and Spectral Constraint Strategy. *IEEE Transactions on Geoscience and Remote Sensing*, 59(4). <https://doi.org/10.1109/TGRS.2020.3008016>

He, J., Li, J., Yuan, Q., Shen, H., & Zhang, L. (2022). Spectral Response Function-Guided Deep Optimization-Driven Network for Spectral Super-Resolution. *IEEE Transactions on Neural Networks and Learning Systems*, 33(9). <https://doi.org/10.1109/TNNLS.2021.3056181>

He, P., Yuan, Y., Lv, Q., & Xiangli, B. (2021). Method for evaluating spectral resolution based on a single-lens spectrometer. *Applied Optics*, 60(25). <https://doi.org/10.1364/ao.430028>

He, X., Liu, Y., Beckett, P., Uddin, M. H., Nirmalathas, A., & Unnithan, R. R. (2020). Hybrid

Color Filters for Multispectral Imaging. *Advanced Theory and Simulations*, 3(11). <https://doi.org/10.1002/adts.202000137>

He, X., Liu, Y., Ganesan, K., Ahnood, A., Beckett, P., Eftekhari, F., Smith, D., Uddin, M. H., Skafidas, E., Nirmalathas, A., & Unnithan, R. R. (2020). A single sensor based multispectral imaging camera using a narrow spectral band color mosaic integrated on the monochrome CMOS image sensor. *APL Photonics*, 5(4). <https://doi.org/10.1063/1.5140215>

Hegedus, P. B., Maxwell, B., Sheppard, J., Loewen, S., Duff, H., Morales-Luna, G., & Peerlinck, A. (2023). Towards a Low-Cost Comprehensive Process for On-Farm Precision Experimentation and Analysis. *Agriculture (Switzerland)*, 13(3). <https://doi.org/10.3390/agriculture13030524>

Hemati, A., Moghiseh, E., Amirifar, A., Mofidi-Chelan, M., & Lajayer, B. A. (2022). Physiological Effects of Drought Stress in Plants. In *Plant Stress Mitigators: Action and Application*. https://doi.org/10.1007/978-981-16-7759-5_6

Hert, D., Baca, T., Petracek, P., Kratky, V., Penicka, R., Spurny, V., Matej, ·, Matous Vrba, P. ·, Zaitlik, D., Stoudek, P., Walter, V., Stepan, P., Horyna, J., Pritzl, V., Sramek, M., Ahmad, A., Silano, G., Daniel, ·, Licea, B., ... Saska, M. (2023). *MRS Drone: A Modular Platform for Real-World Deployment of Aerial Multi-Robot Systems*. <http://mrs.felk.cvut.cz>

Hissou, H., Benkirane, S., Guezzaz, A., Azrour, M., & Beni-Hssane, A. (2023). A Novel Machine Learning Approach for Solar Radiation Estimation. *Sustainability (Switzerland)*, 15(13). <https://doi.org/10.3390/su151310609>

Holzapfel, E. A., Pannunzio, A., Lorite, I., de Oliveira, A. S. S., & Farkas, I. (2009). Design and management of irrigation systems. In *Chilean Journal of Agricultural Research* (Vol. 69, Issue SUPPL. 1). <https://doi.org/10.4067/s0718-58392009000500003>

Hoyos Rojas, J. E., Posada Asprilla, W., & Cerón Muñoz, M. F. (2019). Fotografía multiespectral para el diagnóstico fitosanitario del pasto kikuyo (*Cechrus clandestinus* (Hochst ex Chiov) Morrone). *Acta Agronómica*, 68(1). <https://doi.org/10.15446/acag.v68n1.75662>

Huang, S., Tang, L., Hupy, J. P., Wang, Y., & Shao, G. (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. In *Journal of Forestry Research* (Vol. 32, Issue 1). <https://doi.org/10.1007/s11676-020-01155-1>

Hunt, E. R., Doraiswamy, P. C., McMurtrey, J. E., Daughtry, C. S. T., Perry, E. M., & Akhmedov, B. (2012). A visible band index for remote sensing leaf chlorophyll content at the Canopy scale. *International Journal of Applied Earth Observation and Geoinformation*, 21(1). <https://doi.org/10.1016/j.jag.2012.07.020>

- Ihuoma, S. O., & Madramootoo, C. A. (2017). Recent advances in crop water stress detection. In *Computers and Electronics in Agriculture* (Vol. 141). <https://doi.org/10.1016/j.compag.2017.07.026>
- INIA. (2023). *Manual de Manejo Agronómico de Frijol en Regiones Andinas*. Consulta: 04 junio 2024. Disponible en: www.gob.pe/inia
- Ioja, I., Nedeff, V., & Nedeff, F. (2022). The Use of Drones in Multispectral Photogrammetry and Thermoscanning –A Review. *BULETINUL INSTITUTULUI POLITEHNIC DIN IAȘI. Secția Matematică. Mecanică Teoretică. Fizică*, 68(4). <https://doi.org/10.2478/bipmf-2022-0018>
- Ishimwe, R., Abutaleb, K., & Ahmed, F. (2014). Applications of Thermal Imaging in Agriculture—A Review. *Advances in Remote Sensing*, 03(03). <https://doi.org/10.4236/ars.2014.33011>
- Jan, S., Rather, I. A., Sofi, P. A., Wani, M. A., Sheikh, F. A., Bhat, M. A., & Mir, R. R. (2021). Characterization of common bean (*Phaseolus vulgaris* L.) germplasm for morphological and seed nutrient traits from Western Himalayas. *Legume Science*, 3(2). <https://doi.org/10.1002/leg3.86>
- Jang, H., Hinton, H., Jung, W. Bin, Lee, M. H., Kim, C., Park, M., Lee, S. K., Park, S., & Ham, D. (2022). In-sensor optoelectronic computing using electrostatically doped silicon. *Nature Electronics*, 5(8). <https://doi.org/10.1038/s41928-022-00819-6>
- Jones, H. G. (2018). Opportunities and pitfalls in the use of thermal sensing for monitoring water stress and transpiration. *Acta Horticulturae*, 1197. <https://doi.org/10.17660/ActaHortic.2018.1197.5>
- Julio Villodre Carrilero. (2019). *Estimación de la evapotranspiración y el estrés hídrico en la dehesa a alta resolución temporal y espacial mediante teledetección*.
- Junior, C. P., Cavallieri, G. V., da Silva, F. A., Fernandes, G. L., Nai, G. A., Salge, A. K. M., Puhle, J. G., de Resende e Silva, D. T., Pereira, D. R., de Azevedo Mello, F., Favareto, A. P. A., & Rossi, R. C. (2021). Digital image processing: a useful tool in the analysis of lung injuries caused by chronic inhalation of agricultural herbicides. *Environmental Science and Pollution Research*, 28(41). <https://doi.org/10.1007/s11356-021-14692-x>
- K Ganapathi Babu, Sunil Kumar Dasari, & C Yosepu. (2023). An Overview: Image Processing Techniques and Its Applications. *International Journal of Engineering Technology and Management Sciences*, 7(3). <https://doi.org/10.46647/ijetms.2023.v07i03.135>
- Kachiguma, N. A., Ifie, B. E., Maliro, M. F. A., Tongoona, P. B., & Ofori, K. (2024). Characterization of Common Bean (*Phaseolus vulgaris* L.) Genotypes for Drought Tolerance. *Agricultural Science Digest*, 44(1). <https://doi.org/10.18805/ag.DF-460>
- Kacira, M., Ling, P. P., & Short, T. H. (2002). Establishing crop water stress index (CWSI) threshold values for early, non-contact detection of plant water stress. *Transactions of the*

American Society of Agricultural Engineers, 45(3). <https://doi.org/10.13031/2013.8844>

Kamienski, C., Soininen, J. P., Taumberger, M., Dantas, R., Toscano, A., Cinotti, T. S., Maia, R. F., & Neto, A. T. (2019). Smart water management platform: IoT-based precision irrigation for agriculture. *Sensors (Switzerland), 19*(2). <https://doi.org/10.3390/s19020276>

Kanatas, P., Gazoulis, I., Antonopoulos, N., Tataridas, A., & Travlos, I. (2023). The Potential of a Precision Agriculture (PA) Practice for In Situ Evaluation of Herbicide Efficacy and Selectivity in Durum Wheat (*Triticum durum* Desf.). *Agronomy, 13*(3). <https://doi.org/10.3390/agronomy13030732>

Kapoulas, I. K., Hatziefremidis, A., Baldoukas, A. K., Valamontes, E. S., & Statharas, J. C. (2023). Small Fixed-Wing UAV Radar Cross-Section Signature Investigation and Detection and Classification of Distance Estimation Using Realistic Parameters of a Commercial Anti-Drone System. *Drones, 7*(1). <https://doi.org/10.3390/drones7010039>

Karavidas, I., Ntatsi, G., Vougeleka, V., Karkanis, A., Ntanasi, T., Saitanis, C., Agathokleous, E., Ropokis, A., Sabatino, L., Tran, F., Iannetta, P. P. M., & Savvas, D. (2022). Agronomic Practices to Increase the Yield and Quality of Common Bean (*Phaseolus vulgaris* L.): A Systematic Review. In *Agronomy* (Vol. 12, Issue 2). <https://doi.org/10.3390/agronomy12020271>

Karri, V., & Nalluri, N. (2024). Enhancing resilience to climate change through prospective strategies for climate-resilient agriculture to improve crop yield and food security. In *Plant Science Today* (Vol. 11, Issue 1). <https://doi.org/10.14719/pst.2140>

Katsoulas, N., Elvanidi, A., Ferentinos, K. P., Kacira, M., Bartzanas, T., & Kittas, C. (2016). Crop reflectance monitoring as a tool for water stress detection in greenhouses: A review. In *Biosystems Engineering* (Vol. 151). <https://doi.org/10.1016/j.biosystemseng.2016.10.003>

Kazai, P., Noulas, C., Khah, E., & Vlachostergios, D. (2019). Yield and seed quality parameters of common bean cultivars grown under water and heat stress field conditions. *AIMS Agriculture and Food, 4*(2). <https://doi.org/10.3934/AGRFOOD.2019.2.285>

Khan, Z., Rahimi-Eichi, V., Haefele, S., Garnett, T., & Miklavcic, S. J. (2018). Estimation of vegetation indices for high-throughput phenotyping of wheat using aerial imaging. *Plant Methods, 14*(1). <https://doi.org/10.1186/s13007-018-0287-6>

Khoza, S. B. (2022). Digital Images to the Rescue of Academics as Knowledge Resources for Educating Curriculum Studies Students. *Knowledge, 2*(4). <https://doi.org/10.3390/knowledge2040038>

Koch, G. (2023). *The Color Sensor*. https://doi.org/10.1007/978-1-4842-9280-8_9

Kumari, S., & Bains, G. (2023). Agrifood and Climate Change. In *Global Climate Change and Plant Stress Management*. <https://doi.org/10.1002/9781119858553.ch7>

Labbé, S., Lebourgeois, V., Jolivot, A., & Marti, R. (2012). *Thermal infra-red remote sensing for water stress estimation in agriculture*.

Lakshmi Kumari. (2023). A Study Of AI Techniques In Image Processing. *International Journal For Multidisciplinary Research*, 5(2). <https://doi.org/10.36948/ijfmr.2023.v05i02.1997>

Laonamsai, J., Julphunthong, P., Saprathet, T., Kimmany, B., Ganchanasuragit, T., Chomcheawchan, P., & Tomun, N. (2023). Utilizing NDWI, MNDWI, SAVI, WRI, and AWEI for Estimating Erosion and Deposition in Ping River in Thailand. *Hydrology*, 10(3). <https://doi.org/10.3390/hydrology10030070>

Leitão, S. T., Bicho, M. C., Pereira, P., Paulo, M. J., Malosetti, M., Araújo, S. de S., van Eeuwijk, F., & Vaz Patto, M. C. (2021). Common bean SNP alleles and candidate genes affecting photosynthesis under contrasting water regimes. *Horticulture Research*, 8(1). <https://doi.org/10.1038/s41438-020-00434-6>

Lemes, E. M., Coelho, L., Andrade, S. L. de, Oliveira, A. dos S., Marques, M. G., Nascimento, F. M. A. do, & Cunha, J. P. A. R. da. (2022). Triangular Greenness Index to Evaluate the Effects of Dicamba in Soybean. *AgriEngineering*, 4(3). <https://doi.org/10.3390/agriengineering4030049>

Liang, Z., Liu, X., Xiong, J., & Xiao, J. (2020). Water allocation and integrative management of precision irrigation: A systematic review. In *Water (Switzerland)* (Vol. 12, Issue 11). <https://doi.org/10.3390/w12113135>

Lin, R., Wei, Z., Hu, R., Chen, H., Li, Y., Zhang, B., Wang, F., & Hu, D. (2024). Construction and Validation of Surface Soil Moisture Inversion Model Based on Remote Sensing and Neural Network. *Atmosphere*, 15(6), 647. <https://doi.org/10.3390/atmos15060647>

Lin, S., Li, J., Liu, Q., Li, L., Zhao, J., & Yu, W. (2019). Evaluating the effectiveness of using vegetation indices based on red-edge reflectance from Sentinel-2 to estimate gross primary productivity. *Remote Sensing*, 11(11). <https://doi.org/10.3390/rs11111303>

Lindgren, D. T. (1985). Land use planning and remote sensing. *Land Use Planning and Remote Sensing*. <https://doi.org/10.1007/978-94-017-2035-9>

Lipovac, A., Bezdan, A., Moravčević, D., Djurović, N., Ćosić, M., Benka, P., & Stričević, R. (2022). Correlation between Ground Measurements and Uav Sensed Vegetation Indices for Yield Prediction of Common Bean Grown Under Different Irrigation Treatments and Sowing Periods. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4162287>

Liu, S., Wu, Y., Zhang, G., Lin, N., & Liu, Z. (2023). Comparing Water Indices for Landsat Data for Automated Surface Water Body Extraction under Complex Ground Background: A Case Study in Jilin Province. *Remote Sensing*, 15(6). <https://doi.org/10.3390/rs15061678>

Llanes Cárdenas, O., Estrella Gastélum, R. D., Parra Galaviz, R. E., Gutiérrez Ruacho, O. G., Ávila Díaz, J. A., & Troyo Diéguez, E. (2024). Modeling Yield of Irrigated and Rainfed

- Bean in Central and Southern Sinaloa State, Mexico, Based on Essential Climate Variables. *Atmosphere*, 15(5), 573. <https://doi.org/10.3390/atmos15050573>
- Lu, X., Liu, S., & Du, K. (2022). Multi-temporal change detection based on China's domestic hyperspectral remote sensing satellite images. <https://doi.org/10.1111/12.2638888>
- Luna Flores, W., Estrada Medina, H., Jiménez Osornio, J., & Pinzón López L. L.2. (2018). Efecto del estrés hídrico sobre el crecimiento y eficiencia del uso del agua en plántulas de tres especies arbóreas caducifolias. *Terra Latinoamericana*, 30.
- Lupton, G., Oprea, J., & Scoville, N. A. (2022). Subdivision of Maps of Digital Images. *Discrete and Computational Geometry*, 67(3). <https://doi.org/10.1007/s00454-021-00350-z>
- Macedo, F., Schettini, C. A., & Arigony-Neto, J. (2023). Obtaining surface current field from drone imaging. *Ocean and Coastal Research*, 71. <https://doi.org/10.1590/2675-2824071.22109fm>
- Malveaux, C., Hall, S., & Price, R. R. (2014). Using drones in agriculture: Unmanned aerial systems for agricultural remote sensing applications. *American Society of Agricultural and Biological Engineers Annual International Meeting 2014, ASABE 2014*, 6. <https://doi.org/10.13031/aim.20141911016>
- Marcelino López, Fernando Fernández, & Aart van Schoonhoven. (1985). *FRIJOL: Investigación y Producción*.
- Marin, D. B., Alves, M. de C., Pozza, E. A., Gandia, R. M., Cortez, M. L. J., & Mattioli, M. C. (2019). Sensoriamento remoto multiespectral na identificação e mapeamento das variáveis bióticas e abióticas do cafeiro. *Revista Ceres*, 66(2). <https://doi.org/10.1590/0034-737x201966020009>
- Mataa, M., Kalima, P., & Lungu, D. (2021). Morphophysiological Responses of Common Bean (*Phaseolus vulgaris* L.) Genotypes to Water Stress. *University of Zambia Journal of Agricultural and Biomedical Sciences*, 5(1), 1–17. <https://doi.org/10.53974/unza.jabs.5.1.611>
- Mather, P. M. (2000). Remote Sensing: Introduction. In *Encyclopedia of Analytical Chemistry*. <https://doi.org/10.1002/9780470027318.a2301>
- Mayo-Prieto, S., Porteous-álvarez, A. J., Mezquita-García, S., Rodríguez-González, Á., Carro-Huerga, G., Del Ser-Herrero, S., Gutiérrez, S., & Casquero, P. A. (2021). Influence of physicochemical characteristics of bean crop soil in trichoderma spp. Development. *Agronomy*, 11(2). <https://doi.org/10.3390/agronomy11020274>
- Mayorga Arias, D., Pazos Roldan, M. V. H., & Uvidia Vélez, M. (2019). USO DEL ÍNDICE NORMALIZADO DE VEGETACIÓN PARA LA ELABORACIÓN DE PLANOS DE

CULTIVO. *Opuntia Brava*, 11(2). <https://doi.org/10.35195/ob.v11i2.760>

Mbinya Manetu, W., Momanyi Mironga, J., & Haywood Ondiko, J. (2023). Remote Sensing for Land Resources: A Review on Satellites, Data Availability and Applications. *American Journal of Remote Sensing*. <https://doi.org/10.11648/j.ajrs.20221002.12>

McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7). <https://doi.org/10.1080/01431169608948714>

Meena, S. V., Dhaka, V. S., & Sinwar, D. (2020). Exploring the role of vegetation indices in plant diseases identification. *PDGC 2020 - 2020 6th International Conference on Parallel, Distributed and Grid Computing*. <https://doi.org/10.1109/PDGC50313.2020.9315814>

Mehla, M. K. (2022). Regional water footprint assessment for a semi-arid basin in India. *PeerJ*, 10. <https://doi.org/10.7717/peerj.14207>

Mehla, M. K., Kothari, M., Singh, P. K., Bhakar, S. R., & Yadav, K. K. (2023). Water footprint assessment and its importance in Indian context: a meta-review. *Water Supply*, 23(8). <https://doi.org/10.2166/ws.2023.174>

Mejía, E., Palacios, E., Exebio, A. E., & Santos, A. L. (2002). Problemas operativos en el manejo del agua en distritos de riego. *Terra*, 20(2).

Mennel, L., Polyushkin, D. K., Kwak, D., & Mueller, T. (2022). Sparse pixel image sensor. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-09594-y>

Meron, M., Sprintsin, M., Tsipris, J., Alchanatis, V., & Cohen, Y. (2013). Foliage temperature extraction from thermal imagery for crop water stress determination. *Precision Agriculture*, 14(5). <https://doi.org/10.1007/s11119-013-9310-0>

Michael Abrams, J. (1982). *Effects of spatial resolution*.

Moffiet, T., Armston, J. D., & Mengersen, K. (2010). Motivation, development and validation of a new spectral greenness index: A spectral dimension related to foliage projective cover. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1). <https://doi.org/10.1016/j.isprsjprs.2009.08.002>

Mohsan, S. A. H., Khan, M. A., Noor, F., Ullah, I., & Alsharif, M. H. (2022). Towards the Unmanned Aerial Vehicles (UAVs): A Comprehensive Review. In *Drones* (Vol. 6, Issue 6). <https://doi.org/10.3390/drones6060147>

Mohsan, S. A. H., Othman, N. Q. H., Li, Y., Alsharif, M. H., & Khan, M. A. (2023). Unmanned aerial vehicles (UAVs): practical aspects, applications, open challenges, security issues, and future trends. In *Intelligent Service Robotics* (Vol. 16, Issue 1). <https://doi.org/10.1007/s11370-022-00452-4>

Mora, O. E., Lenzano, M. G., Toth, C. K., & Grejner-Brzezinska, D. A. (2014). Analyzing the

- effects of spatial resolution for small landslide susceptibility and hazard mapping. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 40(1). <https://doi.org/10.5194/isprsarchives-XL-1-293-2014>
- Nafarin, N. A., & Novitasari, N. (2023). Relationship between Normalized Difference Vegetation Index (NDVI) and Rice Growth Phases in Danda Jaya Swamp Irrigation Area Regency Barito Kuala. *IOP Conference Series: Earth and Environmental Science*, 1184(1). <https://doi.org/10.1088/1755-1315/1184/1/012019>
- Näsi, R., Mikkola, H., Honkavaara, E., Koivumäki, N., Oliveira, R. A., Peltonen-Sainio, P., Keijälä, N. S., Änäkkälä, M., Arkkola, L., & Alakukku, L. (2023). Can Basic Soil Quality Indicators and Topography Explain the Spatial Variability in Agricultural Fields Observed from Drone Orthomosaics? *Agronomy*, 13(3). <https://doi.org/10.3390/agronomy13030669>
- Nethaji, V., & Shanmugasundaram, A. P. (2020). The analysis and manipulation of a digitized image processing. *ACCENTS Transactions on Image Processing and Computer Vision*, 6(18). <https://doi.org/10.19101/tipcv.2020.618015>
- Nugroho, A. K., Permadi, I., & Faturrahim, M. (2022). Improvement Of Image Quality Using Convolutional Neural Networks Method. *Scientific Journal of Informatics*, 9(1). <https://doi.org/10.15294/sji.v9i1.30892>
- Nunes, E. C. (2023). *Employing Drones in Agriculture: An Exploration of Various Drone Types and Key Advantages*. <http://arxiv.org/abs/2307.04037>
- Olvera-Salgado, M. D., Bahena-Delgado, G., Alpuche Garcés, Ó., & García Matías, F. (2014). La tecnificación del riego ante la escasez del agua para la generación de alimentos. Estudio de caso en Chihuahua, México. *Ambiente y Desarrollo*, 18(35). <https://doi.org/10.11144/javeriana.ayd18-35.trea>
- P., K., M., M. T., O., S., A., L., R., Y., R., M., & S., K. (2020). Lime requirements for bean production on two contrasting soils of Lake Victoria Crescent agro-ecological zone. *African Journal of Agricultural Research*, 15(4). <https://doi.org/10.5897/ajar2019.14455>
- Pacheco Gallardo, & Luis Lautaro. (2018). *Analizar los NDVI (índice de vegetación normalizados) con los GNDVI (índice de vegetación diferenciada normalizada verde) mediante imágenes lansadt 8 (satélite de observación terrestre) en la parroquia de Mulaló, Latacunga 2018*.
- Pangestu, K. H., Jauhari, A., & Udiansyah, U. (2023). ANALISIS KORELASI NILAI NDVI (NORMALIZED DIFFERENCE VEGETATION INDEX) DENGAN VEGETATION DENSITY DI KHDTK UNIVERSITAS LAMBUNG MANGKURAT. *Jurnal Sylva Scientiae*, 6(3). <https://doi.org/10.20527/jss.v6i3.9214>
- Papathanasiou, F., Ninou, E., Mylonas, I., Baxevanos, D., Papadopoulou, F., Avdikos, I.,

- Sistanis, I., Koskosidis, A., Vlachostergios, D. N., Stefanou, S., Tigka, E., & Kargiotidou, A. (2022). The Evaluation of Common Bean (*Phaseolus vulgaris* L.) Genotypes under Water Stress Based on Physiological and Agronomic Parameters. *Plants*, 11(18). <https://doi.org/10.3390/plants11182432>
- Pavithra, A., Kalpana, G., & Vigneswaran, T. (2023). Deep learning-based automated disease detection and classification model for precision agriculture. *Soft Computing*. <https://doi.org/10.1007/s00500-023-07936-0>
- Pazzi, B. M., Pistoia, D., & Alberti, G. (2022). RGB-Detector: A Smart, Low-Cost Device for Reading RGB Indexes of Microfluidic Paper-Based Analytical Devices. *Micromachines*, 13(10). <https://doi.org/10.3390/mi13101585>
- Pereira, L. E., Amorim, G., Grigio, A. M., & Filho, A. C. P. (2018). Comparative analysis of normalized difference water index (NDWI) methods in continental wetland. *Anuario Do Instituto de Geociencias*, 41(2). https://doi.org/10.11137/2018_2_654_662
- Pettorelli, N., Ryan, S., Mueller, T., Bunnefeld, N., Jedrzejewska, B., Lima, M., & Kausrud, K. (2011). The Normalized Difference Vegetation Index (NDVI): Unforeseen successes in animal ecology. In *Climate Research* (Vol. 46, Issue 1). <https://doi.org/10.3354/cr00936>
- Pilar Barreiro, C. V. (2013). *DRONES EN LA AGRICULTURA*.
- Pilau, F. G., Santos, T. L., Battisti, R., & Reichardt, K. (2023). *Why may consider rainfall space-time variability in Precision Agriculture?* <https://doi.org/10.21203/rs.3.rs-2827581/v1>
- Poma, X. S. (2019). Single sensor multi-spectral imaging. *Electronic Letters on Computer Vision and Image Analysis*, 18(Specialissue2). <https://doi.org/10.5565/rev/elcvia.1194>
- Postolache, O. (2017). Remote sensing technologies for physiotherapy assessment. *2017 10th International Symposium on Advanced Topics in Electrical Engineering, ATEE 2017*. <https://doi.org/10.1109/ATEE.2017.7905141>
- Pratt, W. K. (2013). Introduction to Digital Image Processing. In *Introduction to Digital Image Processing*. <https://doi.org/10.1201/b15731>
- Preite, L., Solari, F., & Vignali, G. (2023). Technologies to Optimize the Water Consumption in Agriculture: A Systematic Review. In *Sustainability (Switzerland)* (Vol. 15, Issue 7). <https://doi.org/10.3390/su15075975>
- Qiao, T., Chen, L., Pang, Y., & Yan, G. (2018). Integrative Multi-Spectral Sensor Device for Far-Infrared and Visible Light Fusion. *Photonic Sensors*, 8(2). <https://doi.org/10.1007/s13320-018-0401-4>
- Quemada, C., Pérez-Escudero, J. M., Gonzalo, R., Ederra, I., Santesteban, L. G., Torres, N., &

- Iriarte, J. C. (2021). Remote sensing for plant water content monitoring: A review. In *Remote Sensing* (Vol. 13, Issue 11). <https://doi.org/10.3390/rs13112088>
- Quiloango-Chimarro, C. A., Coelho, R. D., Costa, J. D. O., & Gomez-Arrieta, R. (2021). CROP WATER STRESS INDEX FOR PREDICTING YIELD LOSS IN COMMON BEAN. *IRRIGA*, 1(4). <https://doi.org/10.15809/irriga.2021v1n4p687-695>
- Raderschall, C. A., Vico, G., Lundin, O., Taylor, A. R., & Bommarco, R. (2021). Water stress and insect herbivory interactively reduce crop yield while the insect pollination benefit is conserved. *Global Change Biology*, 27(1). <https://doi.org/10.1111/gcb.15386>
- RadhaKrishna, M. V. V., Venkata Govindh, M., & Krishna Veni, P. (2021). A review on image processing sensor. *Journal of Physics: Conference Series*, 1714(1). <https://doi.org/10.1088/1742-6596/1714/1/012055>
- Radočaj, D., Šiljeg, A., Marinović, R., & Jurišić, M. (2023). State of Major Vegetation Indices in Precision Agriculture Studies Indexed in Web of Science: A Review. In *Agriculture (Switzerland)* (Vol. 13, Issue 3). <https://doi.org/10.3390/agriculture13030707>
- Ramachandran, G., & kannan, S. (2021). Agriculture General Applications: A Study of Digital Imaging Processing. *Emperor Journal of Economics and Social Science Research*, 03(05). <https://doi.org/10.35338/ejessr.2021.3502>
- Ramirez, G., Montes De Oca, A., & Flores, G. (2023). 3D maps of vegetation indices generated onboard a precision agriculture UAV. *2023 International Conference on Unmanned Aircraft Systems, ICUAS 2023*. <https://doi.org/10.1109/ICUAS57906.2023.10156582>
- Revelo, L. D. A., Mejía, M. J., Montoya, B. B., & Hoyos, G. J. (2021). Análisis de los índices de vegetación NDVI, GNDVI y NDRE para la caracterización del cultivo de café (*Coffea arabica*). *Ingeniería y Desarrollo*, 38(2).
- Roales, J., Moscoso, F. G., Vargas, A. P., Lopes-Costa, T., & Pedrosa, J. M. (2023). Colorimetric Gas Detection Using Molecular Devices and an RGB Sensor. *Chemosensors*, 11(2). <https://doi.org/10.3390/chemosensors11020092>
- Roh, Young, Geun., Kim, Hyo, & Chul. (2021). *Hyperspectral image sensor and hyperspectral image pickup apparatus including the same*.
- Rominiyi, O. L., Salau, A. O., Adaramola, B. A., Ogunlade, M. A., Olanibi, T. O., & Akintoye, F. A. (2023). Development of a Precision Agricultural Based Unmanned Aerial Vehicle for Pest Control. *2023 International Conference on Cyber Management and Engineering, CyMaEn 2023*. <https://doi.org/10.1109/CyMaEn57228.2023.10051014>
- SADER (2022) Estima Agricultura crecimiento de 11.4% de la producción de frijol en 2021; mantiene tendencia al alza. Consulta: 04 junio 2024. Disponible en: <https://www.gob.mx/agricultura/prensa/estima-agricultura-crecimiento-de-11-4-de-la-produccion-de-frijol-en-2021-mantiene-tendencia-al-alza>

Safitri, F., Adrianto, L., & Nurjaya, I. W. (2023). Pemetaan Kerapatan Ekosistem Mangrove Menggunakan Analisis Normalized Difference Vegetation Index di Pesisir Kota Semarang. *Jurnal Kelautan Tropis*, 26(2). <https://doi.org/10.14710/jkt.v26i2.18173>

Santos, E. F. dos, Santos, S. R. dos, Carvalho, A. J. de, Aspiazu, I., & Oliveira, P. M. de. (2020). Soil water availability for drip-irrigated common bean crop. *Pesquisa Agropecuária Tropical*, 50. <https://doi.org/10.1590/1983-40632020v5057367>

Sayago, S., Ovando, G., & Bocco, M. (2016). *Radiación solar a partir de datos satelitales*. <http://flashflux.larc.nasa.gov/>

Schwerz, F., Caron, B. O., Elli, E. F., Stolzle, J. R., Eloy, E., Schmidt, D., Schwerz, L., & de Souza, V. Q. (2017). Greater water availability increases the water use efficiency and productivity of corn and bean species grown in secondary crop systems. *Australian Journal of Crop Science*, 11(1). <https://doi.org/10.21475/ajcs.2017.11.01.pne205>

Scudiero, E., Corwin, D. L., Anderson, R. G., Yemoto, K., Clary, W., Wang, Z., & Skaggs, T. H. (2017). Remote sensing is a viable tool for mapping soil salinity in agricultural lands. *California Agriculture*, 71(4). <https://doi.org/10.3733/ca.2017a0009>

Shah, S. A., Lakho, G. M., Keerio, H. A., Sattar, M. N., Hussain, G., Mehdi, M., Vistro, R. B., Mahmoud, E. A., & Elansary, H. O. (2023). Application of Drone Surveillance for Advance Agriculture Monitoring by Android Application Using Convolution Neural Network. *Agronomy*, 13(7). <https://doi.org/10.3390/agronomy13071764>

Shaik, N. E. K., Widdicombe, B., Sun, D., John, S. E., Ryu, D., Nirmalathas, A., & Unnithan, R. R. (2023). Longwave infrared multispectral image sensor system using aluminum-germanium plasmonic filter arrays. *Nano Research*, 16(7). <https://doi.org/10.1007/s12274-023-5669-z>

Shi, H., Guo, J., An, J., Tang, Z., Wang, X., Li, W., Zhao, X., Jin, L., Xiang, Y., Li, Z., & Zhang, F. (2023). Estimation of Chlorophyll Content in Soybean Crop at Different Growth Stages Based on Optimal Spectral Index. *Agronomy*, 13(3). <https://doi.org/10.3390/agronomy13030663>

Sierra Figueredo, P., & Baca, M. (2014). *IBERO-AMERICAN PROGRAMME FOR SCIENCE, TECHNOLOGY AND DEVELOPMENT IBERO-AMERICAN NETWORK OF BIOECONOMICS AND CLIMATE CHANGE*.

Silva, A. V., Filho, J. F. S., Silva, M. C. T., Vaz, N. C. A., & Silva, M. L. G. (2020). Edaphoclimatic aptitude and agricultural production environments of the bean culture. *Scientific Electronic Archives*, 13(10). <https://doi.org/10.36560/131020201114>

Simanca, F. A., Jaime, H., Páez, P., Díaz, E., José, C., & Palacio, V. (2023). *LA AGRICULTURA DE PRECISIÓN Y HERRAMIENTAS TIC DE APOYO*.

Singh, D. K., Shivam, Singh, V. K., Singh, V. K., Kumar, M., & Mishra, P. K. (2023). Agricultural Water Footprint Studies for Sustainable Agricultural Water Management -A Review. *International Journal of Environment and Climate Change*, 13(9). <https://doi.org/10.9734/ijecc/2023/v13i92259>

Singh, E., Pratap, A., Mehta, U., & Azid, S. I. (2024). Smart Agriculture Drone for Crop Spraying Using Image-Processing and Machine Learning Techniques: Experimental Validation. *IoT*, 5(2), 250–270. <https://doi.org/10.3390/iot5020013>

Son Le, M., Liou, Y. A., & Pham, M. T. (2023). Crop Response to Disease and Water Scarcity Quantified by Normalized Difference Latent Heat Index. *IEEE Access*, 11. <https://doi.org/10.1109/ACCESS.2023.3283033>

Sonkar, S., Kumar, P., Puli, Y. T., George, R. C., Philip, D., & Ghosh, A. K. (2023). Design & Implementation of an Electric Fixed-wing Hybrid VTOL UAV for Asset Monitoring. *Journal of Aerospace Technology and Management*, 15. <https://doi.org/10.1590/jatm.v15.1297>

Sönmez, M., Pelin, C. E., Georgescu, M., Pelin, G., Stelescu, M. D., Nituica, M., Stoian, G., Alexandrescu, L., & Gurau, D. (2022). UNMANNED AERIAL VEHICLES – CLASSIFICATION, TYPES OF COMPOSITE MATERIALS USED IN THEIR STRUCTURE AND APPLICATIONS. *ICAMS Proceedings of the International Conference on Advanced Materials and Systems*. <https://doi.org/10.24264/icams-2022.I.11>

Spalević, Ž., Ilić, M., & Savija, V. (2018). The use of drones in agriculture: ICT policy, legal and economical aspects. *Ekonomika*, 64(4). <https://doi.org/10.5937/ekonomika1804091s>

Suárez, P. L., Sappa, A. D., & Vintimilla, B. X. (2021). Deep learning-based vegetation index estimation. In *Generative Adversarial Networks for Image-to-Image Translation*. <https://doi.org/10.1016/B978-0-12-823519-5.00013-0>

Szparaga, A., Kuboń, M., Kocira, S., Czerwińska, E., Pawłowska, A., Hara, P., Kobus, Z., & Kwaśniewski, D. (2019). Towards sustainable agriculture-agronomic and economic effects of biostimulant use in common bean cultivation. *Sustainability (Switzerland)*, 11(17). <https://doi.org/10.3390/su11174575>

Tang, H., & Li, Z.-L. (2014). *Applications of Thermal Remote Sensing in Agriculture Drought Monitoring and Thermal Anomaly Detection*. https://doi.org/10.1007/978-3-642-42027-6_7

Tapia, G., Méndez, J., Inostroza, L., & Lozano, C. (2022). Water Shortage Affects Vegetative and Reproductive Stages of Common Bean (*Phaseolus vulgaris*) Chilean Landraces,

Differentially Impacting Grain Yield Components. *Plants*, 11(6).
<https://doi.org/10.3390/plants11060749>

Tavan, M., Wee, B., Brodie, G., Fuentes, S., Pang, A., & Gupta, D. (2021). Optimizing Sensor-Based Irrigation Management in a Soilless Vertical Farm for Growing Microgreens. *Frontiers in Sustainable Food Systems*, 4. <https://doi.org/10.3389/fsufs.2020.622720>

Thomasset, L. (2019). *Drone de type multirotor comportant une unite de gestion de la vitesse de rotation de chacun des rotors et procede de commande d'un tel drone*.

Tinghua, A., & Yaolin, L. (2003). Spatial relation resolution and spatial relation abstraction. *Geo-Spatial Information Science*, 6(4). <https://doi.org/10.1007/BF02826944>

Tornés Olivera, N. I., Oscar Brown Manrique, D. I., Gómez Masjuan, Y. I., & Arnaldo Manuel Guerrero Alega, I. I. (2016). *Maximización física y económica del agua de riego en la producción del cultivo del frijol* (Vol. 25, Issue 2).

Unnikrishnan, R., & Ramanand, A. C. (2020). A Study of Different Enhancement Algorithms on Thermal Images. *Proceedings of the 2020 IEEE International Conference on Communication and Signal Processing, ICCSP 2020*. <https://doi.org/10.1109/ICCP48568.2020.9182182>

Valaboju, R., Vaishnavi, Harshitha, C., Kallam, A. R., & Babu, B. S. (2023). Drone Detection and Classification using Computer Vision. *7th International Conference on Trends in Electronics and Informatics, ICOEI 2023 - Proceedings*. <https://doi.org/10.1109/ICOEI56765.2023.10125737>

van der Merwe, D., Burchfield, D. R., Witt, T. D., Price, K. P., & Sharda, A. (2020). Drones in agriculture. In *Advances in Agronomy* (Vol. 162). <https://doi.org/10.1016/bs.agron.2020.03.001>

Vance, W. H., Bell, R. W., Johansen, C., Haque, M. E., Musa, A. M., & Shahidullah, A. K. M. (2021). Soil disturbance levels, soil water content and the establishment of rainfed chickpea: Mechanised seeding options for smallholder farms in north-west Bangladesh. *Journal of Agronomy and Crop Science*, 207(2). <https://doi.org/10.1111/jac.12455>

VANGU, G. M., MILUȚ, M., CROITORU, A., CROITORU, I., & DINUCĂ, N. C. (2023). THE USE OF DRONES AND SENSORS IN AGRICULTURE. *"Annals of the University of Craiova - Agriculture Montanology Cadastre Series"*, 52(2). <https://doi.org/10.52846/aamc.v52i2.1416>

Vasilyev, V. B. (2020). A spectral resolution for digital pseudo-differential operators. *Journal of Analysis*, 28(3). <https://doi.org/10.1007/s41478-019-00193-1>

- Vázque Chun, C., Peña Uribe, G. de J., López Santos, A., & Meraz Jiménez, A. de J. (2023). An index of environmental and cultural suitability for the cultivation of climate-resilient castor bean in rainfed low-productivity common lands in Mexico. *Italian Journal of Agronomy*. <https://doi.org/10.4081/ija.2022.2107>
- Verde, N., Mallinis, G., Tsakiri-Strati, M., Georgiadis, C., & Patias, P. (2018). Assessment of radiometric resolution impact on remote sensing data classification accuracy. *Remote Sensing*, 10(8). <https://doi.org/10.3390/rs10081267>
- Verma, B., Porwal, M., Jha, A. K., Vyshnavi, R. G., Rajpoot, A., & Nagar, A. K. (2023). Enhancing Precision Agriculture and Environmental Monitoring Using Proximal Remote Sensing. *Journal of Experimental Agriculture International*, 45(8). <https://doi.org/10.9734/jeai/2023/v45i82168>
- Vidya, K. N., Parvathaneni, S. S., Haritha, Y., & Phaneendra Kumar, B. L. N. (2023). Change Detection in Multispectral Remote Sensing Images. *Lecture Notes in Mechanical Engineering*. https://doi.org/10.1007/978-981-99-1665-8_36
- Vilakazi, B., Ogola, J. B. O., Odindo, A. O., & Ncama, K. (2023). Water Stress Affected Seed Accumulation of Non-reducing Soluble Sugars and Germination Performance of Three Chickpea Cultivars. *Legume Research*, 46(7). <https://doi.org/10.18805/LRF-708>
- Virtue, J., Turner, D., Williams, G., Zeliadt, S., McCabe, M., & Lucieer, A. (2021). Thermal sensor calibration for unmanned aerial systems using an external heated shutter. *Drones*, 5(4). <https://doi.org/10.3390/drones5040119>
- Wald, L. (2019). Basics in Solar Radiation At Earth Surface. *HAL Science Ouverte*, 1(July).
- Walton, J. S., Hodgson, P., Hallamasek, K., & Palmer, J. (2003). 4DCAPTURE: a general purpose software package for capturing and analyzing two- and three-dimensional motion data acquired from video sequences. *25th International Congress on High-Speed Photography and Photonics*, 4948. <https://doi.org/10.1117/12.516775>
- Walton, J. S., Hodgson, P. N., & Hallamasek, K. G. (2007). 4DCapture/4DPlayer: evolving software packages for capturing, analyzing and displaying two- and three-dimensional motion data. *27th International Congress on High-Speed Photography and Photonics*, 6279. <https://doi.org/10.1117/12.725053>
- WANG, F., HUANG, J., TANG, Y., & WANG, X. (2007). New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. *Rice Science*, 14(3). [https://doi.org/10.1016/s1672-6308\(07\)60027-4](https://doi.org/10.1016/s1672-6308(07)60027-4)
- Wilson, K. (2023). Digital Images, Resolution, and Color Models. In *Introduction to Photoshop*. https://doi.org/10.1007/978-1-4842-8963-1_9
- Wisayataksin, S., Junta, N., & Kuanpreeyawat, J. (2022). Vegetation Health Monitoring System for Smart Farm using NDVI Analysis. *19th International Conference on*

Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, ECTI-CON 2022. <https://doi.org/10.1109/ECTI-CON54298.2022.9795582>

Wójcik-Gront, E., Gozdowski, D., & Stępień, W. (2022). UAV-Derived Spectral Indices for the Evaluation of the Condition of Rye in Long-Term Field Experiments. *Agriculture (Switzerland)*, 12(10). <https://doi.org/10.3390/agriculture12101671>

Woodstock, T. K., & Karlicek, R. F. (2020). RGB Color Sensors for Occupant Detection: An Alternative to PIR Sensors. *IEEE Sensors Journal*, 20(20). <https://doi.org/10.1109/JSEN.2020.3000170>

Wuest, V., Ajanic, E., Muller, M., & Floreano, D. (2022). Accurate Vision-based Flight with Fixed-Wing Drones. *IEEE International Conference on Intelligent Robots and Systems, 2022-October*. <https://doi.org/10.1109/IROS47612.2022.9981921>

Xiao, F., Liu, Q., Li, S., Qin, Y., Huang, D., Wang, Y., & Wang, L. (2023). A Study of the Method for Retrieving the Vegetation Index from FY-3D MERSI-II Data. *Remote Sensing*, 15(2). <https://doi.org/10.3390/rs15020491>

Xing, N., Huang, W., Xie, Q., Shi, Y., Ye, H., Dong, Y., Wu, M., Sun, G., & Jiao, Q. (2020). A transformed triangular vegetation index for estimating winter wheat leaf area index. *Remote Sensing*, 12(1). <https://doi.org/10.3390/RS12010016>

Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. In *Journal of Sensors* (Vol. 2017). <https://doi.org/10.1155/2017/1353691>

Yalcin, I., Kocaman, S., Saunier, S., & Albinet, C. (2021). Radiometric quality assessment for maxar hd imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 43(B3-2021). <https://doi.org/10.5194/isprs-archives-XLIII-B3-2021-797-2021>

Yang, W., Li, Z., Chen, G., Cui, S., Wu, Y., Liu, X., Meng, W., Liu, Y., He, J., Liu, D., Zhou, Y., Tang, Z., Xiang, Y., & Zhang, F. (2024). Soybean (*Glycine max* L.) Leaf Moisture Estimation Based on Multisource Unmanned Aerial Vehicle Image Feature Fusion. *Plants*, 13(11), 1498. <https://doi.org/10.3390/plants13111498>

Yang, W., Wang, X., Wheaton, A., Cooley, N., & Moran, B. (2009). Automatic optical and IR image fusion for plant water stress analysis. *2009 12th International Conference on Information Fusion, FUSION 2009*.

Zerené Harcha, J., & Cardoso Pereira, P. (2014). Revolutions of Resolution. *TripleC: Communication, Capitalism & Critique. Open Access Journal for a Global Sustainable Information Society*, 12(1). <https://doi.org/10.31269/triplec.v12i1.510>

Zhang, Y., Zhang, Y., Lian, X., Zheng, Z., Zhao, G., Zhang, T., Xu, M., Huang, K., Chen, N.,

Li, J., & Piao, S. (2023). Enhanced dominance of soil moisture stress on vegetation growth in Eurasian drylands. *National Science Review*, 10(8).
<https://doi.org/10.1093/nsr/nwad108>

Zheng, Z., Wang, J., Wu, Y., Cai, Q., Yu, H., Zhang, R., Tu, J., Meng, J., Lu, G., & Gao, F. (2023). *Roller-Quadrotor: A Novel Hybrid Terrestrial/Aerial Quadrotor with Unicycle-Driven and Rotor-Assisted Turning*.

Zhenming Ding, Zhangqi Dang, Xinhong Jiang, & Ziyang Zhang. (2023). Solar spectrum measured by waveguide spectral lens. *TechRxiv*.

Zou, X., Haikarainen, I., Haikarainen, I. P., Mäkelä, P., Möttus, M., & Pellikka, P. (2018). Effects of crop leaf angle on LAI-sensitive narrow-band vegetation indices derived from imaging spectroscopy. *Applied Sciences (Switzerland)*, 8(9).
<https://doi.org/10.3390/app8091435>.

