

Ricardo Hugo Lira-Saldivar y Francisco Marcelo Lara-Viveros

# Uso de Drones

---

## en la Agricultura de Precisión

---



Ricardo Hugo Lira-Saldivar y Francisco Marcelo Lara-Viveros

# Uso de Drones

---

## en la Agricultura de Precisión

---



<b>Editora chefe</b>	
Profª Drª Antonella Carvalho de Oliveira	
<b>Editora executiva</b>	
Natalia Oliveira	
<b>Assistente editorial</b>	
Flávia Roberta Barão	
<b>Bibliotecária</b>	
Janaina Ramos	
<b>Projeto gráfico</b>	
Camila Alves de Cremo	2023 by Atena Editora
Ellen Andressa Kubisty	Copyright © Atena Editora
Luiza Alves Batista	Copyright do texto © 2023 Os autores
Nataly Evilin Gayde	Copyright da edição © 2023 Atena
Thamires Camili Gayde	Editora
<b>Imagens da capa</b>	Direitos para esta edição cedidos à
iStock	Atena Editora pelos autores.
<b>Edição de arte</b>	Open access publication by Atena
Luiza Alves Batista	Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição Creative Commons. Atribuição-Não-Comercial-NãoDerivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo do texto e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

#### **Conselho Editorial Ciências Agrárias e Multidisciplinar**

Prof. Dr. Alexandre Igor Azevedo Pereira – Instituto Federal Goiano

Profª Drª Amanda Vasconcelos Guimarães – Universidade Federal de Lavras

Prof. Dr. Arinaldo Pereira da Silva – Universidade Federal do Sul e Sudeste do Pará

Prof. Dr. Antonio Pasqualetto – Pontifícia Universidade Católica de Goiás

Profª Drª Carla Cristina Bauermann Brasil – Universidade Federal de Santa Maria

- Prof. Dr. Cleberton Correia Santos – Universidade Federal da Grande Dourados  
Prof<sup>a</sup> Dr<sup>a</sup> Diocléa Almeida Seabra Silva – Universidade Federal Rural da Amazônia  
Prof. Dr. Écio Souza Diniz – Universidade Federal de Viçosa  
Prof. Dr. Edevaldo de Castro Monteiro – Universidade Federal Rural do Rio de Janeiro  
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul  
Prof. Dr. Fágner Cavalcante Patrocínio dos Santos – Universidade Federal do Ceará  
Prof<sup>a</sup> Dr<sup>a</sup> Girene Santos de Souza – Universidade Federal do Recôncavo da Bahia  
Prof. Dr. Guilherme Renato Gomes – Universidade Norte do Paraná  
Prof. Dr. Jael Soares Batista – Universidade Federal Rural do Semi-Árido  
Prof. Dr. Jayme Augusto Peres – Universidade Estadual do Centro-Oeste  
Prof. Dr. Júlio César Ribeiro – Universidade Federal Rural do Rio de Janeiro  
Prof<sup>a</sup> Dr<sup>a</sup> Lina Raquel Santos Araújo – Universidade Estadual do Ceará  
Prof. Dr. Pedro Manuel Villa – Universidade Federal de Viçosa  
Prof<sup>a</sup> Dr<sup>a</sup> Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão  
Prof. Dr. Renato Jaqueto Goes – Universidade Federal de Goiás  
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará  
Prof<sup>a</sup> Dr<sup>a</sup> Talita de Santos Matos – Universidade Federal Rural do Rio de Janeiro  
Prof. Dr. Tiago da Silva Teófilo – Universidade Federal Rural do Semi-Árido  
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas

## Uso de drones en la agricultura de precisión

**Diagramação:** Ellen Andressa Kubisty  
**Correção:** Flávia Roberta Barão  
**Indexação:** Amanda Kelly da Costa Veiga  
**Revisão:** Os autores  
**Autores:** Ricardo Hugo Lira-Saldivar  
Francisco Marcelo Lara-Viveros

Dados Internacionais de Catalogação na Publicação (CIP)	
L768	Lira-Saldivar, Ricardo Hugo Uso de drones en la agricultura de precisión / Ricardo Hugo Lira-Saldivar, Francisco Marcelo Lara-Viveros. – Ponta Grossa - PR: Atena, 2023.
	Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-65-258-1841-2 DOI: <a href="https://doi.org/10.22533/at.ed.412232709">https://doi.org/10.22533/at.ed.412232709</a>
	1. Agricultura. 2. Drones. I. Lira-Saldivar, Ricardo Hugo. II. Lara-Viveros, Francisco Marcelo. III. Título. CDD 338.1
Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166	

Atena Editora

Ponta Grossa – Paraná – Brasil

Telefone: +55 (42) 3323-5493

[www.atenaeditora.com.br](http://www.atenaeditora.com.br)

contato@atenaeditora.com.br

## DECLARAÇÃO DOS AUTORES

Os autores desta obra: 1. Atestam não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao conteúdo publicado; 2. Declararam que participaram ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certificam que o texto publicado está completamente isento de dados e/ou resultados fraudulentos; 4. Confirmam a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhecem terem informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autorizam a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.

## DECLARAÇÃO DA EDITORA

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código Penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, desta forma não os comercializa em seu site, sites parceiros, plataformas de e-commerce, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.

ANTECEDENTES .....	1
TIPOS DE DRONES PARA LA AGRICULTURA .....	3
BENEFICIOS DE LOS DRONES EN LA AGRICULTURA.....	6
MEJORAN LA RESOLUCIÓN TEMPORAL Y ESPACIAL.....	10
FACILITAN LA AGRICULTURA DE PRECISIÓN .....	12
MONITOREAN EL DESARROLLO DE CULTIVOS .....	16
MEJORAN LA APLICACIÓN DE AGROQUÍMICOS .....	19
MONITOREAN EL ESTRÉS HÍDRICO Y SALINO .....	22
ESTIMAN LA BIOMASA Y RENDIMIENTO .....	25
DETECTAN MALEZAS, PLAGAS Y ENFERMEDADES .....	28
DRONES E INTELIGENCIA ARTIFICIAL PARA AGROPROCESOS .....	31
AUTOMATIZACIÓN E INTELIGENCIA ARTIFICIAL.....	31
MONITOREO EN TIEMPO REAL DE VARIABLES BIÓTICAS Y ABIÓTICAS.....	34
DRONES Y EL INTERNET DE LAS COSAS (IOT).....	36
DRONES PARA EL MANEJO DE LA FERTILIDAD DEL SUELO.....	39
EN CULTIVOS DE ÁRBOLES FRUTALES .....	39
EN ESPECIES DE CULTIVOS HORTÍCOLAS.....	43
EN CULTIVOS DE ESPECIES GRAMÍNEAS.....	47
DRONES PARA ESTIMAR Y APLICAR EL AGUA DE RIEGO .....	50
USO DE IMÁGENES DIGITALES EN EL CÁLCULO DE ÍNDICES VEGETALES.....	53
LAS PLANTAS Y LA LUZ .....	53
ÍNDICES CALCULADOS A PARTIR DE IMÁGENES DE DRONES .....	56
CONSIDERACIONES ACERCA DEL USO DE ÍNDICES VEGETALES.....	62
USO DE IMÁGENES DIGITALES Y SU ANÁLISIS MEDIANTE SISTEMAS DE INTELIGENCIA ARTIFICIAL.....	64
CONCLUSIONES .....	68
REFERENCIAS .....	69
SOBRE LOS AUTORES .....	81

## ANTECEDENTES

Los drones se desarrollaron durante el siglo XX originalmente para misiones militares demasiado aburridas, sucias o peligrosas para los humanos, y en el siglo XXI ya se convirtieron en equipos esenciales para la mayoría de las fuerzas armadas. Con el reciente avance en la industria de los drones, estos aparatos ahora se fabrican no solo como juguetes, sino que también se adaptan para la entrega de documentos y para un sinnúmero de otras aplicaciones con el uso de sensores sofisticados (Hutagalung et al., 2023).

Debido al mayor uso de drones en diversos sectores profesionales e industriales, el mercado comercial de los vehículos aéreos no tripulados (VANT) o drones crecerá exponencialmente en los próximos años. Estos aparatos voladores se pueden utilizar comercialmente para objetivos que abarcan las facetas sociales, económicas y ambientales de las empresas y los productores agrícolas (Kapoor et al., 2023). En la agricultura los drones pueden estimar con cámaras e imágenes RGB el área foliar, la altura del follaje, así como muchas otras variables indicadoras de la fisiología del cultivo (Valluvan et al., 2023).

Desde la última década en la investigación agrícola, los datos de imágenes han crecido exponencialmente utilizando drones y satélites. Debido a eso y al uso de la inteligencia artificial se les está brindando a los agricultores la oportunidad de utilizar la tecnología moderna en el campo (Abdulridha et al., 2023; Sundar et al. 2023).

Con los drones se puede leer con mayor eficiencia índices de plantas obtenidos del análisis multiespectral para tomar decisiones dentro del campo. Ahora se están desarrollando diferentes metodologías para drones en todo el mundo que se usan para la detección de plagas y enfermedades de los cultivos y para predecir las necesidades de agua y nitrógeno (Chiranjeeb et al., 2023).

Esto se puede lograr desarrollando un modelo para recopilar imágenes geolocalizadas utilizando un dron integrado con una cámara multiespectral y obteniendo índices de fitovariables utilizando técnicas de procesamiento de imágenes. Las imágenes de alta calidad permiten a los agricultores tomar decisiones con precisión mucho antes de que la enfermedad u otro problema se propague en el campo (Choubey y Reddy 2023).

La agricultura de precisión (AP) es una industria que ha sido vaticinada como un importante lugar de innovación para los VANT. Sin embargo, este no ha sido el caso a nivel mundial. Los datos de Rodríguez (2023) sobre la adopción de drones en Estados Unidos muestran que existen diferencias regionales en su adopción, ya que los estados del este y el oeste tienen una mayor tasa de adopción, mientras que los estados del centro tienen tasas de adopción más bajas. Eso tiene implicaciones para los operadores, fabricantes y reguladores de drones, ya que esta industria continúa desarrollándose a un ritmo acelerado.

La AP y la agricultura inteligente tienen grandes beneficios con el Internet de las cosas (IoT por sus siglas en inglés), ya que permiten obtener y procesar datos para toda

la granja y su entorno. Los dispositivos IoT como los drones son útiles para numerosas aplicaciones de gestión o manejo de cultivos, porque pueden grabar imágenes de alta calidad con una resolución fina y durante un determinado período de tiempo.

En el estudio de Pandiyan et al. (2023) predicen que la agricultura se transformará como resultado de estas tecnologías en evolución, lo que permitirá tomar decisiones en días en lugar de semanas, así como tener reducciones considerables de costos y aumentos en el rendimiento. Cuando se toman tales decisiones, se hace posible la aplicación exitosa de insumos agrícolas en apoyo de la agricultura de precisión (Rifat et al., 2022).

La teledetección con drones es un punto de inflexión en la AP, ya que ofrece una resolución espectral, espacial y temporal sin precedentes, pero también puede proporcionar datos detallados de la altura de la vegetación y observaciones multiangulares. Maes y Steppe (2019) revisaron el progreso de la teledetección del estrés hídrico con drones, en la detección de malezas y patógenos, en la evaluación del estado nutricional, en el vigor del crecimiento y en la predicción del rendimiento.

Para transferir este conocimiento a la práctica cotidiana de la AP, la investigación futura debe centrarse en explotar como integrar los datos hiperespectrales o multiespectrales con los datos térmicos, pudiendo completar las observaciones en modelos matemáticos robustos de transferencia, en lugar de usar modelos de regresión lineal (Sarma, y Nidamanuri (2023). Con base en esas consideraciones el objetivo de este trabajo, es mostrar la literatura más reciente sobre el estado del arte respecto al uso de drones en la agricultura moderna de precisión, revelando sus ventajas y algunas de sus desventajas.

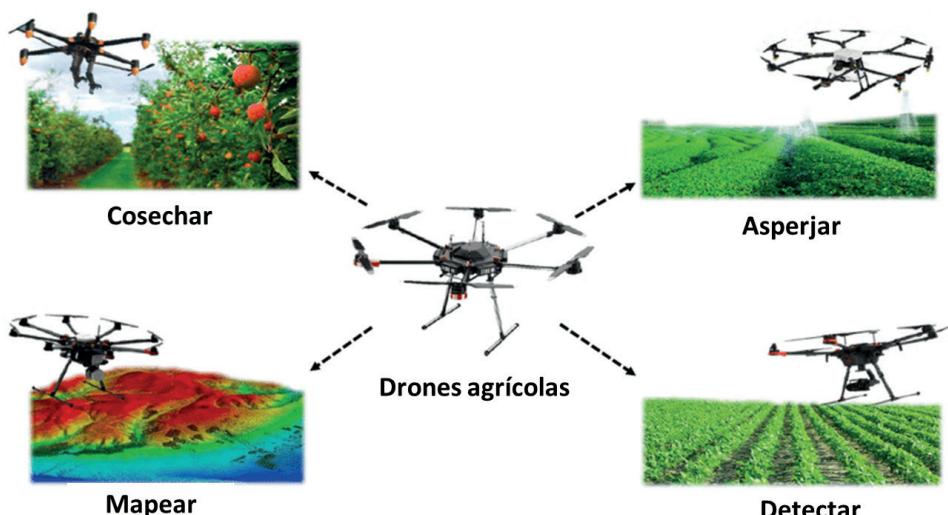
# TIPOS DE DRONES PARA LA AGRICULTURA

En el mercado ya se encuentran un gran tipo y variedad de drones para la agricultura. Pewira et al. (2023) consignan que el modelo 2EVRP-MOD puede generar doce instancias pequeñas basadas en el área de mapeo agrícola de un caso real en Indonesia. Luego se genera el plan para las operaciones de mapeo resolviendo el modelo de optimización.

Los resultados indican que este tipo de dron es capaz de resolver problemas de mapeo de forma óptima. El resultado hasta ahora obtenido indica que el algoritmo aún no puede funcionar bien. Sin embargo, todavía hay muchos procedimientos que se pueden implementar para mejorar el resultado.

Acorde con Javaid et al. (2023) diversas empresas están desarrollando varias tecnologías para facilitar el seguimiento de los cultivos y la salud del suelo agrícola usando drones. Las imágenes hiperespectrales y el escaneo láser 3D son las principales tecnologías basadas en la inteligencia artificial (IA) que pueden ayudar a garantizar la salud de los cultivos. Estas tecnologías impulsadas por la IA recopilan datos precisos sobre la salud de los cultivos en mayor volumen para su análisis.

Los drones son considerados el mayor invento de la humanidad (Dileep et al., 2020). Los drones se pueden utilizar en muchas áreas, pudiendo usarse también en la agricultura. El uso de drones en la actividad agrícola es variado (Figura 1) y proporcionan un gran beneficio económico y de ahorro de tiempo, debido a sus sorprendentes características de vuelo (Islam et al., 2021). Respecto a la colecta y análisis de fitovariables, los drones pueden cubrir de 10 a 15 veces el área que se pudiera cubrir con las técnicas terrestres tradicionales.



**Figura 1.** Hay diferentes tipos de drones que son usados para tareas diversas como determinar el momento de la cosecha, para realizar aspersiones de agroquímicos, para el mapeo de suelos y para detectar el potencial hídrico de los cultivos, así como la presencia de plagas, enfermedades, etc. (Adaptado de: Islam et al., 2021).

Los drones se pueden concentrar de manera general en dos grupos dependiendo del tipo de ala: (1) ala fija y (2) multirrotor (Ghazali et al. 2022). El dron de ala fija consta de un par de alas que generan sustentación pasivamente para el dron mientras corta el aire en un ángulo específico, mientras que el dron multirotor utiliza la velocidad y la dirección del motor para moverse. El multirrotor en función del número de aspas se puede clasificar en: un solo rotor, cuadricóptero, hexacóptero y octocóptero.

En comparación con el dron de ala fija, el multirrotor tiene una velocidad de vuelo más baja, con menor distancia y duración de vuelo porque necesita una gran cantidad de potencia para generar sustentación en el aire. Dependiendo del peso del dron, la cámara y sensores, los drones actualmente tienen un promedio de 20-30 minutos o menos en el aire.

La función más común de los drones en la agricultura es como una plataforma de detección remota para evaluar y monitorear cultivos, pero las aplicaciones agrícolas emergentes incluyen la distribución precisa de agroquímicos y agentes de control biológico, el monitoreo de la salud del ganado y el muestreo remoto. El artículo de van der Merwe et al. (2020) relata que el uso de sensores con ángulos amplios de visión a altitudes relativamente bajas sobre el nivel del suelo, presenta desafíos que requieren procedimientos únicos de captura y procesamiento de datos para superarlos.

El trabajo de Pathak et al. (2020) señala que un nuevo tipo de dron llamado multirrotor, alimentado por baterías recargables, se presentó en China para aplicar agroproductos para protección de los campos cultivados. Este dron equipado con solo un tanque de 5-10 litros puede tratar hasta una hectárea de arroz en 10 a 15 minutos. Este dron multirrotor vuela y aterriza de forma autónoma, tiene un tanque de llenado automático diseñado al tamaño exacto del campo, puede trazar el terreno y mantener una altura constante sobre el cultivo bajo un sensor de altura y los modelos recientes pueden detectar y evitar obstáculos durante el vuelo.

También Pathak et al. (2020) menciona que los drones DJI Agras MG-1 (DJI, 2017) están diseñados para la aplicación de pesticidas líquidos, fertilizantes y herbicidas. El sistema de propulsión del MG-1 permite que el dron pueda transportar hasta 10 kg de carga útil líquida, incluidos pesticidas y fertilizantes para cubrir un área de 4,000-6,000 m<sup>2</sup> en solo 10 minutos, que es entre 40 y 60 veces más rápido que la aplicación manual.

De igual manera estos autores señalan que la FAO ha estado usando drones en Filipinas, que cuentan con equipos de navegación y fotogrametría con resolución de terreno de hasta 3 cm. Usando este dron, equipado con cámaras multiespectrales que permiten estimar índices vegetales en tiempo real, también se puede detectar el estrés hídrico o la falta de nutrientes en los cultivos, mediante la correlación de dichos índices con datos de campo.

Han aparecido en el mercado fumigadores más pequeños basados en drones, como el DJI AGRAS MG-1S con una carga útil de 10 kg. Filho et al. (2020) indican que una colaboración entre la Universidad Saga de Japón y OPTiM Corporation, dieron como

resultado el llamado AgriDrone, que puede realizar la aplicación de pesticidas. AgriDrone también está equipado con un eliminador de insectos UV, que reconoce y mata más de 50 variedades de plagas agrícolas durante la noche. Hassanalian y Abdelkefi (2017) clasificaron a los drones en seis categorías: 1) Nanodrones, 2) Microdrones, 3) Minidrones, 4) Drones chicos, 5) Drones tácticos y 6) Drones Male/Hale strike.

# BENEFICIOS DE LOS DRONES EN LA AGRICULTURA

Cronológicamente se puede relatar que, en 2014, el Instituto Tecnológico de Massachusetts (MIT) colocó a los drones agrícolas en el primer lugar de entre las diez tecnologías más innovadoras (Anderson, 2014). Posteriormente se expresó que tal ventaja es consecuencia de un creciente interés por el uso de drones en investigación y desarrollo agrícola en todo el mundo (Marinello et al., 2016).

Banu et al. (2016) destacaron que los drones han encontrado su aplicabilidad en la silvicultura, donde un creciente interés se da a este segmento debido a los datos de alta resolución que se pueden recopilar de forma flexible en poco tiempo y con un precio relativamente bajo. Además, los drones tienen una acción importante para llenar los vacíos de datos comunes recopilados por teledetección mediante aviones tripulados o satélites.

Los drones se están volviendo más inteligentes al integrar tecnología de código abierto, sensores inteligentes, mejor integración, más tiempo de vuelo, seguimiento de delincuentes, detección problemas en bosques y otras áreas de desastre. Puri et al. (2017) señalan que los drones son instrumentos confiables de alta gama que pueden ser utilizados por los agricultores para inspeccionar la condición del campo agrícola o la granja al comienzo del año de cultivo, así como durante todo el ciclo biológico.

Los drones generan mapas 3D para el análisis del suelo con la finalidad que los agricultores tomen sus precauciones durante el manejo agronómico del cultivo (Valluvan et al., 2023). El análisis de suelo y campo a través de drones también proporciona datos útiles para el riego y el manejo del N y otros fertilizantes para el mejor desarrollo de los cultivos.

El muestreo de suelo mediante drones es una herramienta importante para recopilar información para tomar decisiones adecuadas con respecto a la fertilización de los cultivos agrícolas. Dependiendo de la normativa nacional, la frecuencia mínima de muestreo puede ser una vez cada cinco años en cada diez hectáreas, pero para fines de agricultura de precisión Huuskonen y Oksanen (2018), consideran que esto no es suficiente. En la agricultura de precisión, el desafío es recolectar con drones las muestras de las regiones que sean internamente consistentes mientras se limita la cantidad de muestras requeridas.

Stehr (2015) publicó que los drones han sido utilizados por los militares para la vigilancia remota, pero en la última década, los agricultores comenzaron a usarlos para monitorear sus campos y ayudar a los programas de agricultura de precisión. Hay estimaciones de que entre 80 y 90% del crecimiento del mercado de drones en la próxima década provendrá de la agricultura, ya que proporcionan muchos beneficios y ayudan en diversas tareas en el campo (Figura 2).



**Figura 2.** Son muchos los beneficios proporcionados de manera práctica y económica por los drones en muchas operaciones agrícolas, incluyendo la presencia de malezas, insectos, enfermedades, grado de madurez, biomasa, salinidad, estrés hídrico, etc. (Adaptado de: <https://www.tractorjunction.com/blog/agriculture-drones-uses-and-benefits/>).

La agricultura de precisión en la actualidad es parte muy importante de los proyectos de investigación que utilizan drones. La agricultura necesita drones comerciales desde que la industria despegó, usando análisis y software sofisticados que se combinan para dar soluciones evolucionadas permitiendo avances agropecuarios. Budiharto et al. (2019) señalan que, para la agricultura del futuro, los drones son una herramienta esencial en la AP, ya que mediante ecuaciones matemáticas y algoritmos robustos permiten a los agricultores monitorear y controlar las condiciones de los cultivos y el ganado desde el aire.

El uso de drones tiene un gran potencial para convertirse en un elemento de las tecnologías verdes en el futuro cercano, debido a su apoyo en la agricultura sustentable. Actualmente los agricultores están enfrentando muchos problemas como la falta de disponibilidad o el alto costo de los trabajos o maquilas y problemas de salud humana al estar en contacto con productos químicos (fertilizantes, pesticidas, etc.) al ser aplicados en el campo.

En este contexto, Rani et al. (2019) aseguran que los drones pueden ayudar a los agricultores a evitar estos problemas, pero además proporcionan beneficios al usar una tecnología verde o ecológica. Debido a eso los drones emergen como un componente de la agricultura de precisión, además de contribuir a la agricultura sustentable.

A pesar de sus beneficios, las tasas de adopción de drones son bajas y la literatura

sobre la adopción de drones en la agricultura es escasa. Michels et al. (2021) averiguaron si un modelo de aceptación de tecnología puede contribuir a la comprensión de los factores que influyen en la intención de los agricultores de adoptar un dron.

Obtuvieron una muestra de 167 agricultores alemanes recopilada en 2019 con una encuesta en línea. De acuerdo con los resultados, aumentar la conciencia de los agricultores sobre las áreas específicas de la granja para el uso de drones y el nivel de confianza de usar un dron, puede aumentar la intención de los agricultores de adoptar un dron para la agricultura de precisión (Figura 3).



**Figura 3.** Globalmente los agricultores están usando drones para la agricultura de precisión, así como tecnologías de automatización para mejorar sus operaciones en los campos agrícolas, ya sea usando robots para eliminar malezas, para cosechar o tractores autónomos que facilitan las operaciones y ayudan a reducir los costos de mano de obra (Tomado de: <https://www.bearingtips.com/precision-agriculture-the-hype-around-drone-technology/>).

Las aplicaciones de los drones en la agricultura ya están muy desarrolladas en Asia, mientras que, en otras partes del mundo, se permite el uso de drones para pruebas limitadas y específicas y en algunos casos, para operaciones comerciales en horticultura, agricultura y silvicultura. Patak et al. (2020) indican que los drones pueden realizar con mucha precisión la aspersión o pulverización de herbicidas contra malezas, así como de plaguicidas contra insectos y enfermedades, esparciendo insumos micro-granulados, así como haciendo plantaciones en nuevos bosques. Estas y otras actividades para el uso de drones, ha sido apoyado por el gobierno chino para su uso comercial en la agricultura.

La tecnología de drones ya no está disponible solo para organizaciones militares. Esta herramienta está tan avanzada y es tan económica que cualquier entusiasta de la tecnología podría adquirir un dron y comenzar a usarlo en solo un par de minutos, sin necesidad de capacitación específica (Bikov et al., 2022). Este nivel de accesibilidad de la tecnología de drones permite expandir su aplicación y llegar a varias industrias, incluida la agricultura.

Entre las actividades de las que son capaces los drones modernos, hay una que podría ayudar al agricultor, y no solo es reducir su necesidad de mano de obra, sino también el costo mensual requerido para monitorear sus plantas y para proteger su ganado, monitoreándolo regularmente desde el cielo (Raj et al., 2022).

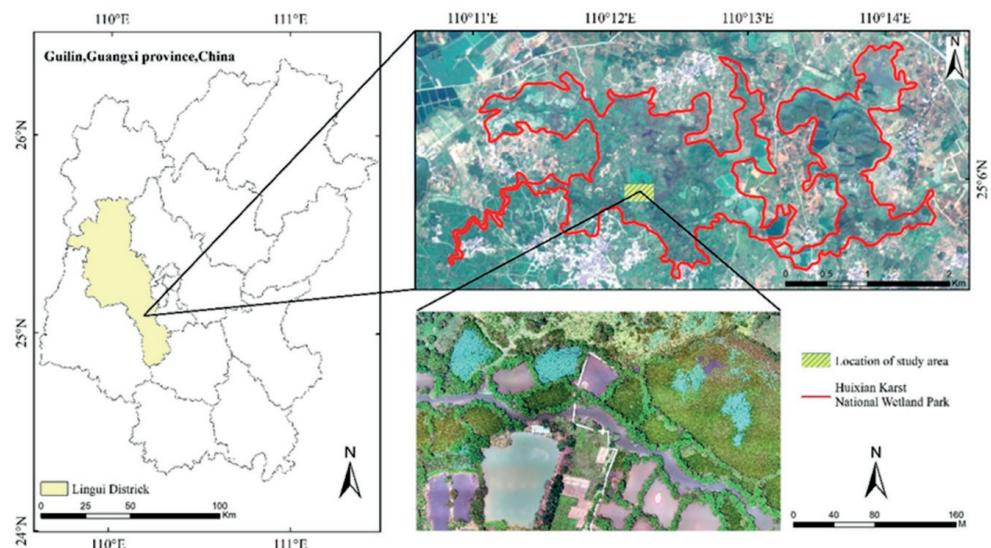
Nduku et al. (2023) señalan que los drones se han convertido en una parte integral de varias industrias, desde la agricultura hasta los servicios de entrega. Sin embargo, controlar drones en entornos dinámicos puede ser desafiante, especialmente cuando se realizan tareas complejas. Los métodos tradicionales para la automatización de drones se basan en programas pre programados por instrucciones, limitando su flexibilidad y adaptabilidad.

Por su parte, Haque y Chowdhury (2023) indican que, en los últimos años, las técnicas de aprendizaje automático, han emergido como un prometedor enfoque para la automatización de drones, lo que permite que aprendan de sus interacciones con el ambiente y mejoren su rendimiento a lo largo del tiempo.

# MEJORAN LA RESOLUCIÓN TEMPORAL Y ESPACIAL

El trabajo reportado por Medeiros et al. (2023) indica que los drones modernos han surgido con el objetivo principal de producir mapas e imágenes con una resolución espacial extremadamente alta. La información refinada proporciona una buena oportunidad para cuantificar la distribución de la vegetación a través de paisajes heterogéneos (Li et al., 2023), revelando una estrategia importante para la conservación de la biodiversidad. Sin embargo, Chen et al. (2023) señalan que este tipo de datos son difíciles y costosos de obtener en cultivos extensivos como el trigo y otros cultivos, así como en áreas donde se requiere una gran resolución espacial y precisión para la clasificación de especies de vegetación de humedales y objetos terrestres (Figura 4).

Las crecientes resoluciones temporales y espaciales de la teledetección basadas en drones volando a baja altitud, proporcionan una forma factible de monitorear la variabilidad de la madurez de las bayas en plantas de café. Debido a eso Martins et al. (2023) realizaron un estudio que tuvo como dos objetivos: (1) predecir la madurez de la fruta usando variables espectrales y texturales; y (2) determinar las mejores variables para desarrollar mapas de variabilidad espacio-temporal de la madurez de la fruta. Este trabajo demostró la viabilidad de utilizar variables espectrales y texturales derivadas de imágenes de drones para mapear y monitorear los cambios espacio-temporales en la madurez de la fruta.



**Figura 4.** Vista aérea obtenida por un dron en la zona central de un humedal en China, donde se mantiene un paisaje ecológico que es crucial para el estudio y la preservación del humedal de Huixian. La zona núcleo de este humedal tiene un área que cubre 77,398 m<sup>2</sup> (Tomado de Chen et al., 2023).

La adquisición de datos de teledetección se ha convertido en una de las herramientas

más importantes utilizadas en la AP para analizar y evaluar la producción y el uso de los recursos. Arza-García y Burgess, (2022) señalan que la disponibilidad de imágenes de teledetección, utilizando una gama de sensores del espacio, ha transformado por completo la forma de monitorear un cultivo agrícola. Sin embargo, la gestión agrícola eficaz a escala local requiere de la obtención de imágenes con una alta resolución espacial y temporal.

En la AP el uso de drones ha cambiado las prácticas agrícolas al ofrecer a los agricultores ahorros sustanciales en costos, mayor eficiencia operativa y mas rentabilidad. En las últimas décadas, el tema de los drones ha atraído una notable atención por los académicos, ya que ayudan mucho a obtener imágenes de alta resolución para la investigación agrícola (Rejeb et al., 2022).

El monitoreo de la variabilidad de los cultivos dentro del campo con una resolución espacial y temporal fina, puede ayudar a los agricultores a tomar decisiones confiables durante el manejo agronómico; sin embargo, tradicionalmente implica un proceso manual puntual que requiere mucha mano de obra y consume mucho tiempo (Li et al., 2022).

La determinación del fenotipo de plantas ha atraído una gran atención en los últimos años, lo que ha llevado al desarrollo de nuevas estrategias para medir y evaluar la biométrica de interés en las plantas. Para la adquisición de datos de campos grandes, se requieren dispositivos y sensores que proporcionen información temporal y espacial detallada y reproducible sobre el cultivo.

El trabajo de Pallottino et al. (2021) propone el uso de drones ligeros de bajo costo para caracterizar el fenotipo en cultivos de cereales. El método propuesto por ellos permite obtener medidas precisas de color y altura de las plantas para las parcelas individuales. El método se basa en un algoritmo de calibración de color (función de interpolación TPS-3D) y una reconstrucción de ortoimagen 3D; el cual ha obtenido información sobre el color real con un error inferior a 12/256 y la altura de las plantas en cada parcela individual.

Reportes pioneros sobre el tema de drones en la agricultura como el de Turner et al. (2011) consignan que los drones son una nueva herramienta de teledetección capaz de adquirir alta resolución de datos espaciales en campos agrícolas. Estos autores han desarrollado un dron que es capaz de recolectar datos e imágenes multiespectrales, con hiperresolución, e imágenes térmicas para su aplicación a la viticultura de precisión.

Ellos señalan que los modos tradicionales de recopilación de datos no están bien adecuados para la detección de cambios sutiles, pero son muy importantes en la estructura del viñedo dada las bajas resoluciones temporal y espacial. Por lo tanto, el mapeo con drones tiene el potencial de proporcionar imágenes en un espacio y tiempo sin precedentes.

## FACILITAN LA AGRICULTURA DE PRECISIÓN

En el estudio de ur Rehman et al. (2023) se consigna que la agricultura de precisión es un enfoque de la agricultura habilitada por la tecnología que mide, observa y analiza las necesidades individuales de los campos y cultivos. El principal objetivo de este tipo de agricultura en comparación con la agricultura tradicional, es que los insumos se utilicen en cantidades precisas para aumentar el rendimiento y la rentabilidad de los cultivos. Esto hace que, mediante el uso de drones y la inteligencia artificial, la agricultura moderna sea más precisa, rentable y sustentable.

Ajakaiye (2023) reporta que existe una aplicación deficiente de la tecnología de drones en la agricultura africana a pesar de su pequeño tamaño de banda de bajo costo, teniendo los drones el potencial de ayudar a muchas naciones africanas con un creciente desarrollo económico. La producción de alimentos en el África Subsahariana está disminuyendo debido a factores como: sequía, invasión de plagas de langostas, conflictos regionales, pandemia de Covid, agricultura dependiente del clima, malas condiciones del suelo, mala calidad y cantidad del agua de riego, así como desafíos logísticos entre otros factores.

Por eso la introducción de tecnologías avanzadas como los drones y la IoT pueden aportar soluciones a esos retos mediante la AP, ya que los drones pueden ayudar a aumentar la productividad, al tiempo que minimiza costos operativos y mejora la eficiencia en el uso de insumos (Singh et al., 2022).

Los resultados revelaron que los drones se han utilizado para monitorear el crecimiento y desarrollo de los cultivos, para el manejo de fertilizantes y el mapeo de cultivos, pero también tienen el potencial de facilitar otras prácticas de AP. Sin embargo, debido a los continuos avances tecnológicos y las reducciones en los costos de este tipo de drones, sigue habiendo muchos motivos para el optimismo con respecto a las aplicaciones futuras de los drones y las tecnologías asociadas para la planificación y la toma de decisiones operativas.

Como parte de un enfoque agrícola de precisión, los drones se han empleado cada vez más en la agricultura durante más de una década y han demostrado que brindan muchos beneficios. Sin embargo, Zuo et al. (2021) revelan que hasta la fecha se han realizado pocas investigaciones sobre la adopción de drones por parte de los agricultores de Australia.

En 2015-2016, se descubrió que solo entre el 4 y 8% de los agricultores de riego habían adoptado la tecnología de drones. Sin embargo, los resultados señalan que hasta un tercio de los agricultores de riego declararon que planeaban usar drones en los siguientes cinco años, y es más probable que la adopción ocurra cuando los productores al aplicar el riego se puedan lograr beneficios tangibles, como ahorro de agua y mano de obra.

Las aplicaciones de los drones en la AP son muchas y muy variadas (Cuadro 1),

razón por la que estos vehículos aéreos no tripulados o drones, tienen un gran potencial en la agricultura moderna, ya que también pueden ayudar a los agricultores y procesadores de alimentos a rastrear el movimiento de productos de la granja a la mesa, optimizar la logística y garantizar la seguridad alimentaria.

Cuadro 1. Diversos usos o aplicaciones de los drones en las actividades agrícolas.

Aplicaciones	
- Detectar el daño a los cultivos	- Identificación de plagas
- Identifican deficiencias nutricionales	- Infestación de enfermedades
- Monitorear desarrollo del cultivo	- Evaluación de humedad del suelo
- Identificación de los cultivos	- Monitoreo del riego
- Detección de estreses	- Supervisión del riego
- Predicción de rendimientos	- Mapeo de suelos
- Obtención de datos climáticos	- Monitoreo de inundaciones

Las enfermedades de las plantas afectan la calidad y cantidad de los productos agrícolas y tienen un impacto negativo en la seguridad alimentaria. Estos efectos se traducen en una pérdida de ingresos en los sectores productivos que son particularmente críticos para los países en desarrollo. Por otro lado, la inspección visual realizada por expertos en la materia requiere mucho tiempo, es costosa y no es escalable para granjas grandes.

Es por eso que Chin et al. (2023) señalan que la automatización en la detección de fitoenfermedades es una solución factible para evitar pérdidas en el rendimiento, siendo este uno de los enfoques más populares para el uso de drones. Además consideran que el algoritmo de aprendizaje automático más aplicado es la red neuronal convolucional (Furukawa et al., 2020).

Se reporta que el tipo de dron más utilizado es el cuadricóptero y la tarea de aprendizaje automático más aplicada es la clasificación. Las imágenes en la banda infrarrojo (CIR) son los datos preferidos y las imágenes de campo son el enfoque principal. El algoritmo de aprendizaje automático más aplicado es la red neuronal convolucional (CNN).

El aprendizaje automático y la inteligencia artificial están transformando rápidamente la agricultura de precisión al proporcionar soluciones basadas en datos para el manejo del agua, cultivos y ganado. Vishwakarma et al. (2023) reportan que los algoritmos obtenidos pueden analizar grandes cantidades de datos de varias fuentes como sensores, drones e imágenes satelitales para proporcionar información que puede ayudar a los agricultores a optimizar el uso de los recursos, mejorar el rendimiento y la calidad de los cultivos, controlar la salud de plantas y ganado, pudiendo también predecir brotes de enfermedades.

En aplicaciones agrícolas, los vehículos aéreos no tripulados son capaces de

aumentar la productividad agrícola y reducir la carga de trabajo de los agricultores. Fikri et al. (2023) reportan que el uso de los drones en fumigación (Figura 5) y monitoreo de cultivos se basa en estudios previos realizados por muchos grupos científicos e investigadores que trabajan en estrecha colaboración para proponer soluciones que ayuden a resolver problemas relacionados con la agricultura moderna y la tradicional.



**Figura 5.** Algunos drones permiten llevar un sistema de aspersión de alta calidad con atomizadores rotativos, carga electrostática de las gotas y control de flujo preciso para realizar aplicaciones de agroquímicos para la agricultura de precisión. (Tomado de: <https://kray.technology/uas-drone-affordable-crop-spraying/>).

El aumento de la población mundial ha provocado nuevas necesidades de alimentos, en ese contexto la AP es uno de los focos de nuevas políticas tendientes a optimizar el manejo de los cultivos y mejorar el desarrollo de las plantas a través de la tecnología. Algunos autores como García et al. (2020) relatan que los drones han ido ganando popularidad en la AP para realizar actividades de detección remota mediante la captura de fotos y videos, así como fertilización o asustar animales. Estos drones también podrían usarse para proporcionar una guía para elegir los mejores drones para una transmisión de datos WiFi exitosa entre los nodos sensores y el puerto de enlace en los sistemas de AP para el mejor manejo de cultivos.

Debido a eso Daponte et al. (2019) consignan que, en los últimos años, ha habido una fuerte actividad en la AP, particularmente en el aspecto de monitoreo, no solo para mejorar la productividad, sino también para satisfacer la demanda de una población creciente. A gran escala, el monitoreo preciso de los campos agrícolas es una tarea bastante desafiante.

Por eso el monitoreo de fitovariables y la sanidad de los cultivos en la AP, mediante el

uso de drones equipados con cámaras multiespectrales, térmicas y visibles, está cambiando el paradigma de la agricultura moderna. Esta tecnología tiene un amplio alcance en varios campos como la detección de enfermedades y plagas, detección del estrés hídrico o salino, estimación de rendimiento/madurez, detección de la flora de malezas, control de recursos hídricos y monitoreo de trabajadores.

Es reconocido y aceptado que el uso de drones ahorra tiempo de operación, consumo de agua y uso de pesticidas en la agricultura; además permiten detectar con facilidad cuando aparecen síntomas en el follaje de la presencia de plagas, enfermedades, malezas, así como estreses hídrico y salino debido a los cambios en el color del follaje (Figura 6).



**Figura 6.** Mediante el uso de drones se puede cubrir hasta 25 acres en unos cinco minutos y brinda una descripción general del campo, hace una exploración automatizada y brinda informes de campo utilizando mapas cargados por el usuario e imágenes tomadas por el dron (Tomado de: <https://droneXL.co/2021/01/21/ai-drones/>).

## MONITOREAN EL DESARROLLO DE CULTIVOS

El monitoreo continuo de la dinámica de los cultivos es fundamental para hacer frente al riesgo climático, garantizar la seguridad alimentaria y hacer un inteligente y eficiente uso del agua de riego (Zhao et al., 2023). Las imágenes de teledetección proporcionan fuentes de datos vitales para el seguimiento de desastres naturales, el seguimiento del crecimiento y desarrollo de los cultivos, la estimación del rendimiento y otras aplicaciones.

Li et al. (2023a) consideran que, con el progreso de la tecnología de hardware de sensores satelitales, se han desarrollado más y más satélites de alta resolución espacial para proporcionar información precisa sobre la superficie terrestre. Aunque las imágenes satelitales se ven afectadas por las condiciones climáticas, se pueden obtener imágenes múltiples en una temporada de cultivo, lo que tiene una función importante en las aplicaciones agrícolas a escala de todo el campo.

La determinación de las etapas clave de desarrollo y crecimiento fenológico de las plantaciones de banano, como son la aparición de flores y el establecimiento de la planta, es difícil debido al crecimiento asincrónico de las plantas de banano. Aeberli et al. (2023) reportan que el monitoreo fenológico demanda observaciones manuales repetidas de las etapas de crecimiento de las plantas individuales, lo cual es muy laborioso y requiere poco tiempo siendo necesario el manejo e integración de grandes conjuntos de datos de campo.

La teledetección satelital ha demostrado su eficacia en el seguimiento espacial y temporal de la fenología de los cultivos en amplias superficies. Sin embargo, para el cultivo de banano, se requieren imágenes de muy alta resolución espacial y temporal para permitir el monitoreo a nivel de planta individual. Las tecnologías de detección basadas en drones brindan una solución rentable, con el potencial de obtener información sobre la fitosanidad, el rendimiento y el crecimiento de manera consistente y cuantificable (Li et al. 2023b).

El estudio reportado por Ma et al. (2023) indica que el rápido desarrollo de la tecnología ha hecho que los vehículos aéreos no tripulados sean ampliamente conocidos ahora y se puedan emplear en pronosticar el desarrollo de cultivos como el arroz, así como la aparición de las diferentes etapas fenológicas. También se prevé que el mercado de vehículos aéreos no tripulados siga creciendo en el futuro.

Por su parte, Meng et al. (2023) reportan que la implementación de drones en la agricultura ha abierto un nuevo horizonte para aumentar la producción agrícola y el acceso en tiempo real a información de alta calidad durante el desarrollo de los cultivos. El monitoreo de plantas se ha convertido en una tarea simple con el surgimiento de la recopilación de datos basada en drones, que reemplaza la recopilación de datos tradicional que requiere mucha mano de obra y consume considerable tiempo.

Kumar et al. (2023) sugieren que los drones pueden ayudar en la AP al realizar el monitoreo de la salud del suelo, la siembra de semillas, la aplicación de fertilizantes, el manejo del estrés de los cultivos, la planificación del programa de riego, el manejo de

malezas y el análisis del clima. También los drones con sensores infrarrojos, multiespectrales e hiperespectrales pueden analizar la salud de los cultivos y las condiciones del suelo con precisión. Además, los drones de fumigación pueden ayudar a reducir la exposición del operador, al mismo tiempo que mejoran la capacidad de distribuir productos químicos de manera oportuna.

En el trabajo de Sorbelli et al. (2022) se usó un dron para recopilar información dentro de los huertos con el fin de detectar plagas de la chinche apestosa (*Halyomorpha halys*) y además, determinar el desarrollo del cultivo. Para monitorear la presencia de insectos, un dron vuela cerca de los árboles y toma videos y/o fotografías que se analizarán sin conexión.

Como la energía del dron es limitada, solo se puede visitar con una batería bien cargada un subconjunto de ubicaciones en el huerto, por eso se deben seleccionar aquellos lugares que tienen más posibilidades de estar infestados para detectar rápidamente la plaga. Los drones también pueden ayudar en la tarea de la siembra de semillas, cuando se realiza al voleo en áreas extensas de siembra de pastos, gramíneas y especies forestales (Figura 7).



**Figura 7.** Las siembras de semillas para cultivos de grano o pastos se facilitan con drones ya que permiten hacer una buena y rápida dispersión de las semillas, de manera similar se pueden realizar acciones de agroforestería para la siembra de semillas de plantas leñosas perennes como arbustos  
(Tomado de: <https://www.rpas-drones.com/tag/reforestacion/>).

El uso de modelos de altura del dosel e índices de vegetación y teledetección (RS) basada en drones puede permitir evaluaciones a gran escala del crecimiento de las plantas y su estado nutricional. El objetivo de Metiva (2021) fue evaluar el RS basado en drones para abordar los desafíos de investigación, desarrollo y producción de zanahorias y

tomates. Se encontró que el rendimiento y la biomasa aumentaron con dosis más altas de N. En tomates el RS se integró en un cultivo de cobertura por la tasa de fertilizante N para comparar las medidas de RS con las medidas manuales de la altura de la planta, contenido de N en las hojas y las lecturas del medidor de clorofila foliar (SPAD).

Los huertos frutales requieren un manejo específico del sitio o incluso de un solo árbol individual durante la temporada de crecimiento. En ese aspecto Nambi et al (2022) señalan que la detección remota a través de drones o vehículos aéreos no tripulados se está volviendo más común entre los productores y es muy útil para el monitoreo de cultivos en tiempo real, detección de malezas, clasificación de árboles, evaluación del estrés hídrico, detección de enfermedades, estimación del rendimiento y calidad de la fruta, así como para implementar varias estrategias de manejo de plagas y nutrientes.

## MEJORAN LA APLICACIÓN DE AGROQUÍMICOS

Los drones se pueden utilizar para facilitar las operaciones en el sector agropecuario y forestal al recopilar datos e informar sobre el desarrollo rural en términos de límites de tierras agrícolas, recursos hídricos y su superficie, límites de poblados, monitoreo de áreas forestales, observación de regiones montañosas y de plantas altas, así como la condición del suelo en términos de contenido de agua, humedad, conductividad eléctrica, pH y temperatura (Mandla et al., 2023).

Para mitigar los devastadores problemas actuales, el sector agrícola necesita impulsar su producción utilizando técnicas avanzadas, equipos basados en sensores y el uso de drones a gran escala. Los drones son máquinas muy avanzadas que pueden realizar funciones como aplicar una dosis requerida de fertilizantes y pesticidas, lo que reduce el costo de las operaciones en la agricultura extensiva (Mukhamediev et al., 2023).

Los drones están conectados con varios sensores para detectar la condición de déficit de agua y así programar el riego de las plantas cultivadas (Chiranjeeb et al., 2023). Los drones utilizan diferentes imágenes espectrales (lineal, espectral lineal, hiperespectral, etc.), junto con GPS para monitorear y localizar las enfermedades que ocurren en las plantas, con esos datos es más sencillo controlar las plagas.

El raleo o aclareo es una práctica importante para que los productores de manzanas manejen la carga de la cosecha y mejoren el tamaño y la calidad de la fruta, lo que se puede lograr mediante la manipulación manual, química o mecánica de flores y frutos. El raleo de flores se basa en la evaluación visual de la carga floral por parte de expertos humanos, un indicador principal de la carga de cultivo, que puede ser impreciso y propenso a errores.

El estudio de Yuan et al. (2023) tuvo como objetivo desarrollar un algoritmo de la densidad de la flor del manzano utilizando nubes de puntos reconstruidos a través de imágenes y fotogrametría RGB basadas en drones, indicando donde y cuando aplicar agroquímicos para realizar el raleo de frutos. El algoritmo obtenido resultó ser muy útil y se basó en la reducción del muestreo promedio de la cuadrícula y el umbral de color blanco, pudiendo generar mapas de densidad de flores de las regiones altas de los árboles.

Las imágenes hiperespectrales y el escaneo láser 3D son las principales tecnologías basadas en inteligencia artificial que pueden ayudar a garantizar la salud de los cultivos mediante el uso de drones. Estas tecnologías impulsadas por la IA recopilan datos precisos sobre la salud de los cultivos en mayor volumen para su análisis. En el trabajo de Javaid et al. (2023) se estudió la IA y su uso en la agricultura. Los resultados orientan sobre el proceso de la IA en la agricultura y algunos parámetros agrícolas monitoreados mediante la IA, identificando y discutiendo sus aplicaciones significativas en la agricultura.

Wang et al. (2022) reporta que, en China, mediante el uso de drones se puede reducir el uso de fertilizantes, pesticidas y agua, mejorar la eficiencia operativa, abrir nuevos mercados a través del modo 'venta + servicios' y reducir los costos de producción

y escasez de mano de obra. Este trabajo concluye que la fumigación usando drones y los servicios relacionados de defensa contra plagas y enfermedades, también son adecuados para los modos de producción descentralizados a pequeña escala.

La implementación de tecnologías de producción agrícolas innovadoras puede cumplir con los objetivos relacionados con la necesidad global de aumentar la producción de alimentos. Los drones y otras tecnologías agrícolas avanzadas, tienen la capacidad de resolver muchos problemas. El cambio climático está teniendo un efecto negativo en la agricultura, lo que representa un grave peligro para la seguridad alimentaria mundial.

Debido a eso, Kumar et al. (2022) hacen notar que los agricultores deben adoptar tecnologías que les ayuden a tomar mejores decisiones basadas en información fiable, datos precisos y oportunos. A diferencia de los costosos satélites, los drones equipados con un conjunto de sensores e instrumentos tienen un gran potencial para ayudar a los agricultores en la planificación basada en evidencia. y recopilación de datos geográficos.

El mundo recibe más de 200,000 personas por día y se espera que la población mundial total alcance los 9,600 millones para el año 2050. Esto dará como resultado una demanda adicional de alimentos, que solo puede satisfacerse mediante un mayor rendimiento de los cultivos. Hafeez et al. (2022) reportan que la modernización agrícola se convierte en la necesidad del momento. Hay muchas limitaciones que restringen la baja producción de cultivos, lo que se pueden superar mediante el uso de la tecnología de drones. Por lo tanto, este trabajo presenta un análisis de las tecnologías de drones y sus modificaciones en la última década para apoyar al sector agrícola y la agricultura de precisión.

En los últimos años la aplicación de agroquímicos utilizando drones ha recibido mucha atención por parte de los investigadores, los productores y el mercado. Los fabricantes propusieron el concepto de usar drones para la fumigación colaborativa para mejorar la operativa y la eficiencia del trabajo. En el estudio de Chen et al. (2022), se construyeron dos drones para experimentos de campo.

La densidad de gotas y la uniformidad de distribución de las gotas se evaluaron en múltiples áreas de superposición. Ellos encontraron que la fumigación simultánea fue mejor que la fumigación secuencial. Además, el resultado de la distribución de gotas de la pulverización secuencial, resultó ser mejor que el de la pulverización simultánea en el área de superposición del centro de la ruta de vuelo.

La aplicación tardía o inadecuada de pesticidas puede favorecer un aumento en la pérdida de las cosechas. Aunque los agricultores siguen tratando de conservar los cultivos, no pueden tener éxito en el nivel máximo, debido al inadecuado seguimiento y prácticas de gestión o manejo de los cultivos. Además, la mayoría de los productores están adoptando métodos para el seguimiento de los cultivos debido a la falta de instalaciones suficientes.

Manobharathi et al. (2022) reportan que la alta tecnología agrícola y su influencia en el sector agropecuario han sido siempre productivas. En los últimos años, se introdujeron

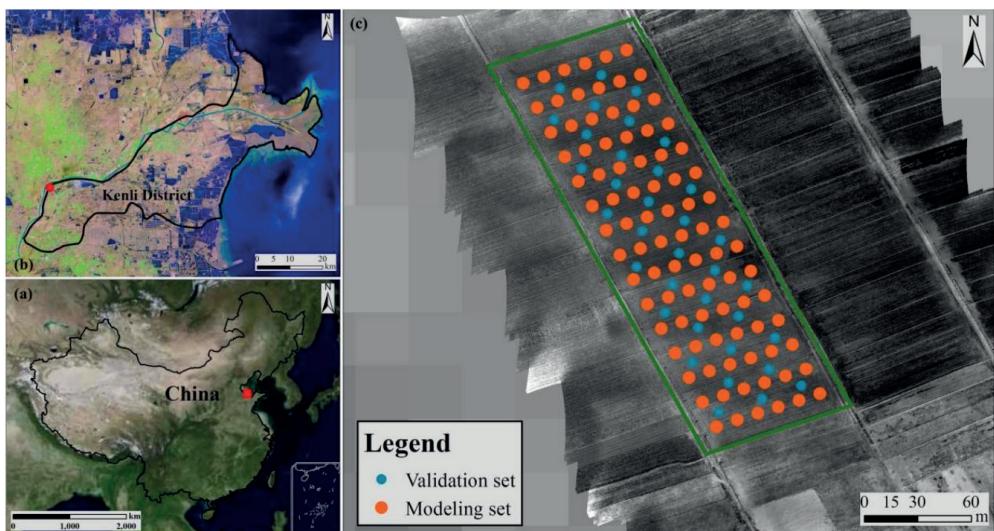
diversas técnicas innovadoras para reemplazar la operación manual. Esto aplica para la protección contra plagas, aplicación de nutrientes, el monitoreo del crecimiento de cultivos, etc. Es por eso que la tecnología sobre el uso de drones tiene el potencial de proporcionar una solución sostenible en el contexto de mejorar la productividad del sector agrícola.

La agricultura es un proceso interminable que no se puede detener ni cambiar. Como es bien sabido, las mejoras tecnológicas han llevado al desarrollo de la agricultura de precisión con el objetivo de conservar los recursos mientras se maximiza la rentabilidad financiera de un número limitado de insumos y se minimiza el impacto en el ambiente agrícola.

En este sentido Vishal y Mahanta (2022) dicen que la AP es una herramienta prometedora específica del sitio para identificar y abordar las variaciones en los parámetros agronómicos como el manejo de enfermedades, suelos, nutrientes y estrés hídrico en el campo. La fotografía aérea con drones y fotografías satelitales se han utilizado en el pasado para estudiar variaciones agronómicas debido a la aplicación de diversos agroquímicos.

# MONITOREAN EL ESTRÉS HÍDRICO Y SALINO

En los últimos años se están usando imágenes tomadas por drones para identificar de manera remota el estado hídrico y las enfermedades de los cultivos (Figura 8). Sin embargo, los métodos existentes para hacer esas determinaciones fisiológicas en el campo son técnicas manuales, las cuales consumen mucho tiempo y requieren una considerable mano de obra especializada (Er-Raki y Chehbouni, 2023).



**Figura 8.** El monitoreo de la información de salinidad del suelo realizado de manera eficiente y precisa utilizando drones es fundamental para el manejo agrícola y el desarrollo sustentable de los recursos en tierras cultivables (Tomado de: Yu et al., 2022).

Para atenuar el problema de la falta de mano de obra durante el monitoreo de los cultivos, Tejarasi et al. (2023) propusieron un modelo para identificar el estrés hídrico en plantas de maíz utilizando imágenes RGB y datos multiespectrales. Ellos concluyeron que los datos multiespectrales funcionan mejor que los datos RGB que fueron capturados por los drones.

La población mundial en constante aumento, la gran demanda de suministro de alimentos y la falta de agricultura de temporal o secano para satisfacer esas demandas, han aumentado la importancia del riego, debido a eso, el manejo eficiente del agua para evitar los efectos de estrés hídrico provocado por el cambio climático se ha incrementado.

Samreen et al. (2023) relatan que el uso de sensores para recopilar remotamente esos datos ha despertado mucho interés, consecuentemente las tecnologías de detección remota para el riego de precisión son utilizadas para calcular la salinidad, evapotranspiración, el estado hídrico de los cultivos su crecimiento y el potencial rendimiento (Yu et al., 2002).

El agua y el nitrógeno (N) son necesarios para el rendimiento y la calidad de los cultivos, la aplicación excesiva de N aumenta los costos de producción y la degradación ambiental. Sahoo et al. (2023) realizaron un experimento usando sensores remotos hiperespectrales y

examinaron numerosas imágenes de modelos para la evaluación no invasiva del contenido relativo de agua y de azúcar en las plantas de arroz utilizando datos de reflectancia recopilados por drones en la región espectral de 350–2500 nm.

Los autores concluyen que los procedimientos establecidos son rápidos, de bajo costo y no invasivos, proporcionando una alternativa viable a los enfoques tradicionales. Estas técnicas que emplean drones ahora se están utilizando para caracterizar el fenotipo de plantas de alto rendimiento, en condiciones de escasez de agua y deficiencia de nutrientes.

Cada vez se recomienda más la reutilización de aguas residuales tratadas. A medida que los suministros de agua siguen siendo más escasos causando estrés hídrico en los cultivos, las aguas residuales tratadas se vuelven más importantes en la agronomía. Para la agricultura de riego la información precisa sobre la calidad del agua es crucial.

Tallou et al. (2023) reportan que los datos de drones sobre la calidad del agua en el campo podrían ayudar a reducir la escasez de información geográfica al cubrir un gran espacio en un período corto. Sin embargo, los drones deben estar provistos de equipos de navegación adicionales o sistemas de localización acústica, para poder entregar resultados que pueden conducir a una poderosa base de datos e información, para el tratamiento de aguas residuales y para su reutilización en el sector agrícola (Barela et al., 2023).

La gestión o manejo del agua de riego se está convirtiendo en un tema crítico para la agricultura sustentable, especialmente en las zonas semiáridas, donde los problemas globales de escasez de agua están aumentando año con año. En la agricultura de precisión se requiere un conocimiento puntual del estado hídrico en los cultivos para un riego preciso a través de tecnologías de detección remota (Awais et al., 2022).

La literatura reciente cuenta con varios enfoques de detección remota para monitorear el estado hídrico de los cultivos en el entorno del cultivo. Establecer la cantidad adecuada de agua por aplicar con diferentes sistemas de riego maximizando el rendimiento o eficiencia en el uso del agua (EUA) para un gran número de cultivos, es un problema que sigue sin resolverse. Por eso para cada cultivo, será necesario crear una conexión más fuerte entre el estado hídrico del cultivo y el rendimiento del mismo (Brahmanand y Singh, 2022).

En medio de las razones de seguridad por el uso de drones, la república de Uzbekistán está adoptando tecnologías innovadoras de estos vehículos aéreos no tripulados a medida que las instituciones de investigación locales y las agencias estatales adoptan la facilidad de uso, la precisión y su multifuncionalidad. Mirzaliev et al. (2022) reporta que, debido a la creciente preocupación por la escasez de agua, el aumento de la aridez y la disminución de los rendimientos, la industria agrícola de Uzbekistán está mostrando un gran interés por el

uso de drones en la producción agrícola.

Las ciencias hidrológicas y la gestión de los recursos hídricos han dependido durante mucho tiempo de una combinación de mediciones *in situ* y datos de detección remota para fines de investigación y regulación, ya que las mediciones *in situ* están limitadas en su distribución espacial tanto por la logística como por los costos. Achayra et al. (2021) reportan que la teledetección basada en satélites y aeronaves tripuladas proporciona datos espacialmente amplios, pero de una resolución aproximada.

Además, estos métodos de recopilación de datos tienen una capacidad limitada para responder a eventos específicos a corto plazo, cuando los datos y las imágenes podrían informar la evaluación y la toma de decisiones en tiempo real, especialmente durante e inmediatamente después de los desastres naturales.

Debido a eso, investigadores y productores usan cada vez más los drones para llenar estos vacíos de datos, tanto espaciales como temporales, ya que los drones son más rentables que las metodologías tradicionales de recopilación de datos *in situ* o de detección remota (Gago et al., 2015).

Acorde con McDonald (2019), los drones han tenido un surgimiento entre los investigadores y profesionales de recursos hídricos y ambientales; sin embargo, se ha prestado menos atención a su potencial para el manejo de aguas pluviales. Por lo tanto, se señala que los drones son una herramienta valiosa que puede respaldar el manejo del agua, realizar el monitoreo del flujo y la calidad del recurso hídrico, para así recopilar datos de alta resolución espacial y poder mejorar la parametrización de un modelo predictivo.

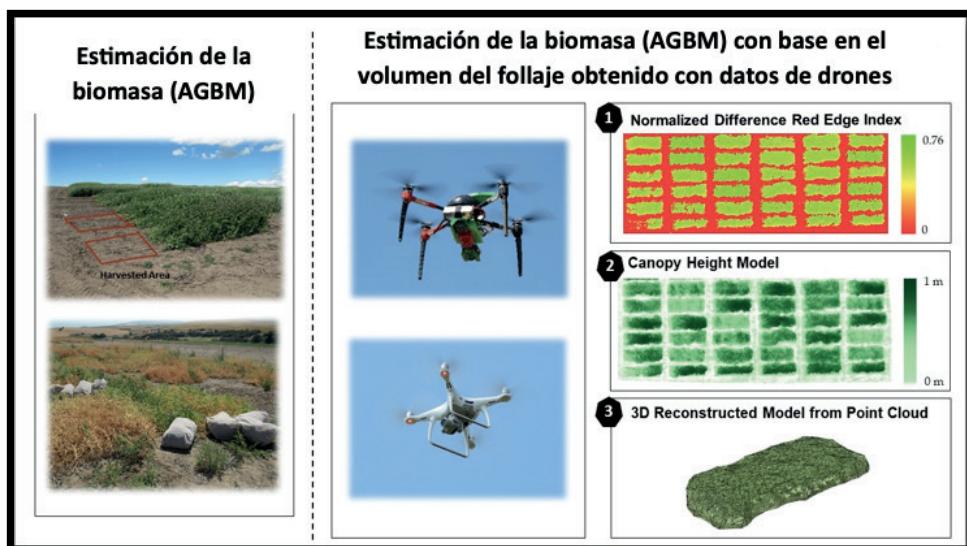
El concepto de control y optimización del riego en tiempo real se encuentra en sus etapas de desarrollo, pero ya ha demostrado potencial para el ahorro de agua. Koech y Langat (2018) indican que es probable que en el futuro se vea un mayor uso de técnicas de detección remota con drones, así como sistemas de comunicación inalámbricos y sensores más versátiles para mejorar la EUA. En muchos casos, el agua ahorrada por el uso de tecnologías eficientes termina siendo reutilizada para ampliar el área de tierra bajo riego, lo que resulta en un aumento neto en el consumo total de agua a escala de cuenca.

Estas tecnologías tienen mucho potencial en el riego inteligente porque permiten la recopilación de datos ambientales en tiempo real. Alvino y Marino (2017) señalan que ya se están utilizando drones que tienen una función esencial en diversas aplicaciones relacionadas con el manejo de cultivos, ya que ofrecen una gran oportunidad para rastrear campos de cultivo con sensores remotos de alta resolución espacial y temporal para mejorar el manejo del estrés hídrico en los cultivos.

# ESTIMAN LA BIOMASA Y RENDIMIENTO

Los drones pueden ayudar a la agricultura de precisión en una variedad de tareas que incluyen el monitoreo de la salud del suelo, la siembra de semillas, la aplicación de fertilizantes, el manejo del estrés de los cultivos, la planificación del programa de riego, el manejo de malezas, estimación del rendimiento de los cultivos y el análisis del clima; además, los drones pueden ofrecer varias soluciones en muchas áreas de la agricultura y ciencias afines, como el monitoreo del crecimiento y rendimiento (Kumar et al., 2023).

La biomasa aérea (AGBM) es una característica vital y el componente principal del rendimiento. Sin embargo, el método estándar de medición de la AGBM es un proceso destructivo y laborioso. Debido eso Sangjan et al. (2022) utilizaron un dron para estimar el AGBM del chícharo (*Pisum sativum L.*) usando tres técnicas de procesamiento: índice de vegetación, modelo de superficie digital (DSM) y modelo de reconstrucción 3D a partir de nubes de puntos, para así extraer la altura y volumen asociados con la biomasa (Figura 9).



**Figura 9.** Mediante el uso de drones es factible determinar con buen grado de precisión la biomasa aérea de cultivos, lo que permite tener un buen conocimiento del rendimiento de biomasa fresca de cultivos forrajeros (Adaptado de: Sangjan et al., 2022).

El índice de área foliar del maíz (LAI, por sus siglas en inglés) está estrechamente relacionado con los procesos fisiológicos de los cultivos, los cuales están bastante relacionados con su productividad. Por lo tanto, comprender el LAI del maíz es fundamental para evaluar su rendimiento. Las imágenes de drones junto con los índices de vegetación obtenidos con alta resolución espacial, proporcionan tecnologías apropiadas para determinar el LAI del maíz a escala de parcela o finca, pudiendo con esto predecir la acumulación de

biomasa y el rendimiento esperado (Buthelezi et al., 2023).

El reporte de Xiao et al. (2023) indica que dos campos de maíz se dividieron en cuatro parcelas para evaluar los efectos de las diversas prácticas de manejo del cultivo (programa y profundidad de siembra y método de fertilización), en el crecimiento y rendimiento del cultivo de maíz. Se montaron cámaras multiespectrales RGB y MicaSense en drones para recopilar imágenes de los campos de maíz.

Este trabajo utilizó drones para proporcionar información precisa y conocimientos valiosos sobre las prácticas agrícolas del maíz, lo que puede ayudar a los agricultores a optimizar el rendimiento de esa gramínea. Las técnicas aplicadas en este estudio podrían extrapolarse para mejorar los procesos de maíz a otros cultivos.

Los pastizales son uno de los ecosistemas más grandes del mundo y representan el 30% de la biomasa terrestre total (Bengtsson et al., 2019). Teniendo en cuenta que la biomasa aérea (AGB) es uno de los parámetros más esenciales en los pastizales, un método preciso y rápido para estimar el valor AGB es fundamental para gestionar, proteger y promover la sustentabilidad del ecosistema.

Debido a eso Bazzo et al. (2023) utilizaron datos espectrales y estructurales para estimar la biomasa de pastizales, mostraron que los modelos que incorporaban ambos tipos de datos superaron a los modelos que utilizaban solo uno. A pesar de estas limitaciones, y con base en los rápidos avances, los autores consideran que los métodos con drones para estimar la biomasa en pastizales seguirán mejorando y pueden comercializarse para aplicaciones agrícolas en un futuro próximo.

La predicción del rendimiento del grano de arroz con imágenes multiespectrales impulsadas por drones está resurgiendo a favor de la agricultura de precisión, y un tiempo de detección óptimo es un factor importante. Los objetivos de un estudio reportado por Bascon et al. (2022), fueron predecir el rendimiento de arroz utilizando la biomasa aérea estimada y el índice de área foliar. Los resultados muestran que esas variables podrían estimarse entre la etapa del amacollamiento y el inicio del espigamiento. Estos resultados permiten a los investigadores a ahorrar recursos y tiempo para numerosos vuelos de drones para predecir el rendimiento del grano de arroz.

La detección remota por drones ha abierto una oportunidad sin precedentes para monitorear eficientemente la biomasa de cultivos en lugar de mediciones terrestres que requieren mucha mano de obra. Xu et al. (2022) reportan que, aunque el uso combinado de características estructurales y espectrales recolectadas por drones pueden aliviar estos problemas hasta cierto punto, aún existen incertidumbres en la estimar la biomasa de cultivos con diferencias significativas en la arquitectura del dosel y la composición de biomasa durante la temporada de crecimiento. Los autores concluyen que ese estudio proporciona un enfoque novedoso para estimar la biomasa de arroz en el campo.

Las estimaciones oportunas y precisas de la biomasa y el rendimiento de grano son cruciales para el manejo agrícola. Las técnicas de teledetección óptica mediante drones

pueden proporcionar parámetros de cultivo (biomasa, cobertura vegetal y rendimiento) a escalas regionales y mayores. El modelo AquaCrop de Yue et al. (2021) se puede utilizar para estimar la biomasa y la producción de rendimiento de grano en el cultivo de trigo en función de los parámetros ambientales de crecimiento como temperatura, lluvia, riego, etc.

Los chícharos forrajeros proporcionan nutrientes esenciales para las dietas del ganado, pudiendo influir en la salud del ganado y reducir las emisiones de gases de efecto invernadero. La biomasa aérea es una de las características vitales y el componente principal del rendimiento en los programas de mejoramiento de chícharos forrajeros.

El estudio realizado por Sangjan et al. (2022) menciona que un método estándar de medición de la biomasa es un proceso destructivo y laborioso. En cambio, el trabajo de estos autores utilizó un dron equipado con un RGB de color verdadero y una cámara multiespectral de cinco bandas para estimar eficientemente la biomasa del chícharo de invierno en tres ensayos de mejoramiento genético.

Los rendimientos de los cultivos son importantes para la seguridad alimentaria y el nivel de vida de las personas y, por lo tanto, es muy importante predecir el rendimiento de manera oportuna. El estudio de Feng et al. (2022) utilizó diferentes índices de vegetación del cultivo de trigo y parámetros calculados con base a la reflectancia del dosel obtenida a partir de datos hiperespectrales cercanos a la superficie habiendo utilizado los métodos de regresión de mínimos cuadrados parciales y una red neuronal artificial para estimar el rendimiento de trigo de invierno en diferentes etapas de crecimiento.

Ese estudio mostró que el uso de una combinación de índices de vegetación y parámetros de borde rojo logró una mejor estimación del rendimiento en comparación con el uso de índices de vegetación solos. En el futuro, se deben seleccionar drones, sensores y métodos adecuados al construir modelos para estimar el rendimiento de los cultivos.

## DETECTAN MALEZAS, PLAGAS Y ENFERMEDADES

El mapeo de malezas preciso y oportuno entre y dentro de los cultivos se considera uno de los principales desafíos en los sistemas de manejo de malezas. La investigación realizada por El Imani et al. (2023), presenta el primer enfoque de computación en la nube basado en la incorporación de imágenes multiespectrales de drones en el entorno de programación Google Earth Engine (GEE), con el objetivo de mejorar el mapeo de parches de malezas entre y dentro de los árboles en una huerta de cítricos.

Por otro lado, el consumo excesivo de herbicidas ha llevado gradualmente al fenómeno de las malezas resistentes a herbicidas, lo que solo puede solventarse mediante la aplicación de estrategias de alta tecnología, como métodos basados en drones (Figura 10). Hay algunas herramientas y tecnologías basadas en IA disponibles para controlar la maleza, ya que el aprendizaje automático hace que el proceso de clasificación sea más fácil que la detección remota, la robótica y el análisis espectral (Ghatrehsamani et al., 2023).



**Figura 10.** La detección de malezas, plagas, enfermedades, etc., se puede realizar con el uso de drones que incorporan cámaras multiespectrales para obtener muy buenas imágenes de manera rápida y precisa que indican variaciones en el color del follaje (Tomado de: <https://www.linkedin.com/pulse/types-agriculture-drone-cameras-how-choose-avirtech>).

Shavanov et al. (2022) consideran que la amenaza que representan las plagas y enfermedades para la producción de cultivos, es uno de los factores clave que podrían reducir la seguridad alimentaria mundial. Debido a eso la detección temprana es de vital importancia para hacer predicciones precisas, optimizar las estrategias de control y prevenir pérdidas en los cultivos.

He et al. (2023) señalan que, las metodologías de biodetección con drones ofrecen soluciones potenciales para el monitoreo automatizado en tiempo real, también permiten avances en la detección temprana y precisa de plagas y, por lo tanto, respaldan la protección sustentable de los cultivos.

Los métodos tradicionales que se basan en equipos terrestres, dispositivos y los ojos desnudos de los agricultores, enfrentan muchas limitaciones en términos de precisión y tiempo requerido para cubrir grandes campos. Bouguettaya et al. (2023) consignan que la agricultura de precisión basada en el uso de algoritmos y drones, proporciona una solución eficaz para aplicaciones agrícolas, incluida la identificación y el tratamiento de enfermedades de las plantas. En los últimos años, el monitoreo fitopatológico utilizando drones, es una de las aplicaciones agrícolas más importantes habiendo ganado un interés creciente por parte de los investigadores.

Azafar et al. (2023) señalan que la tecnología del internet de las cosas (IOT) y los drones son un paso hacia la modernización. Todo, desde el monitoreo de campo hasta la identificación de plagas, se realiza mediante esas tecnologías. Estos autores propusieron un marco de IoT para detectar insectos con sensores de detección de movimiento y luego recibir una respuesta automática haciendo una aspersión dirigida y basado en drones.

Por su parte, Rehman et al. (2022) comentan que el aumento de la población mundial hace que sea necesario luchar contra desafíos como el cambio climático y producir alimentos de manera eficiente y rápida. El trabajo de Aslan et al (2022) revela que, con el uso de tecnologías IOT con drones, se puede obtener datos en tiempo real, teniendo un gran potencial para optimizar las soluciones a los problemas que enfrenta la agricultura moderna. El documento enfatiza esta deficiencia y proporciona una revisión exhaustiva del uso de drones para tareas agrícolas destacando la importancia de la localización y el mapeo simultáneos para una solución con drones en invernadero y en campo abierto.

Kaivosa ja et al. (2021) señalan que la recopilación de datos sobre la presencia de malezas, plagas y enfermedades en los cultivos es laboriosa y requiere mucho tiempo. La mayoría de los estudios revisados por esos autores utilizaron observaciones visuales subjetivas de imágenes de drones y solo unos pocos realizaron mediciones *in situ*.

La conclusión de esos autores es que hay una falta de soluciones de medición de datos de referencia cuantitativos y repetibles en las áreas de mapeo de plagas, malezas y enfermedades. Además, los resultados de los estudios deben reflejarse en las referencias aplicadas. Una opción en el enfoque futuro podría ser el uso de datos sintéticos como referencia.

Muchas veces las plagas alcanzan niveles de población explosivos en los cultivos que provocan graves pérdidas para los productores. Las plagas causan daños a gran escala, lo que provoca un retraso en el crecimiento y una reducción drástica en el rendimiento. En las prácticas agrícolas modernas, la tecnología actual permite un mejor manejo de los cultivos. Maslekar et al. (2020) reportan que la IOT, la teledetección y las técnicas de análisis de

datos se han convertido en los salvadores de cultivos.

La teledetección mediante drones puede capturar imágenes de alta resolución, que no solo permiten la identificación de plagas, sino que también facilitan su control. Los drones con cámaras pueden resolver muchos problemas en la protección de cultivos frutales como los almendros, que las herramientas convencionales de control de plagas no pueden hacerlo (Martínez-Heredia et al., 2023).

Para el crecimiento efectivo de los cultivos, se utilizan muchos agroquímicos como fertilizantes y pesticidas, sin embargo, el uso excesivo de ellos da como resultado daños a la tierra y los recursos hídricos. Shankar et al. (2018) mencionan que hay varias tecnologías de monitoreo de cultivos disponibles que son muy costosas y no todos los agricultores pueden pagarlas.

Además, los agricultores no comprenden el funcionamiento y manejo de una tecnología tan sofisticada. Por eso el sistema propuesto por esos autores usa una tecnología de aprendizaje automático y algoritmos ANN usando drones que ayudan a ubicar regiones afectadas por enfermedades y plagas, para que se concentren en las regiones afectadas y se apliquen productos químicos solo en esa área en particular.

# DRONES E INTELIGENCIA ARTIFICIAL PARA AGROPROCESOS

## AUTOMATIZACIÓN E INTELIGENCIA ARTIFICIAL

La producción agrícola es un tema de preocupación en todo el mundo debido al rápido aumento sin precedentes de la población, lo que tiene una influencia clave en el estado mundial de la producción de alimentos, la seguridad ambiental y la economía. Agnihotri y Mitra (2023) señalan que el cambio climático y la agricultura están entrelazados de muchas maneras, ya que el cambio climático es la fuerza impulsora detrás de las presiones bióticas y/o abióticas que marca las tendencias poblacionales en una agricultura global en transición decidida a automatizar procesos agrícolas (Milner y Boldsen, 2023).

La inteligencia artificial son los algoritmos diseñados para tomar decisiones, por lo general utilizando volúmenes grandes de datos en tiempo real, para realizar actividades que a veces van más allá de las capacidades humanas. Hay una brecha cada vez mayor entre la oferta y la demanda agrícola en todo el mundo, ampliada aún más por la pandemia del COVID-19.

La pandemia descarriló el progreso de los Objetivos de Desarrollo Sustentable (ODS) de la ONU. La brecha de financiamiento de los ODS por año se amplió de USD 2.5 billones a cerca de USD 4.2 billones y esto requiere de enfoques innovadores y rentables para fortalecer la producción de alimentos (Ziesche et al., 2023).

El trabajo de Javaid et al (2023) señala que, en la agricultura, la IA ha demostrado un potencial inmenso de aplicaciones para lograr mayor productividad y mejorar las cadenas de suministro agropecuarias, los sistemas de entrega al mercado y para lograr mejores precios en los países desarrollados y en desarrollo.

En los últimos años, la IA está ayudando a elegir la variedad y semilla óptima para un escenario climático determinado; debido a eso y por otras aplicaciones, las soluciones impulsadas por la IA ayudarán a los agricultores a producir más con menos recursos y podrán mejorar la calidad de los cultivos y las cosechas.

Los estreses abióticos tienen consecuencias negativas en los cultivos, provocando la disminución del crecimiento y el rendimiento, los cuales dependen de manera crucial de las condiciones climáticas. Las diversas tecnologías que dependen de la IA ayudan a mejorar la producción y la eficacia del sector agrícola, es decir, el rendimiento de los cultivos, el monitoreo de su estado fenológico, la detección de sales y nutrientes del suelo, el riego y el deshierbe (Saxena et al., 2023). Estas tecnologías también se utilizan para la protección de los diferentes aspectos como el cambio climático, el aumento de la población, los desafíos laborales y los problemas de seguridad alimentaria.

Acorde con Witte et al. (2023) la IA ha ayudado a los agricultores a generar más productos con la más alta calidad con una inversión mucho menor, al tiempo que garantiza una disponibilidad de mercado más rápida para los alimentos producidos. La IA ha ayudado

al sector agrícola de diversas formas, incluido el reconocimiento y la percepción de imágenes, las habilidades y la mano de obra, y la maximización de la productividad.

La IA también puede ayudar a los agricultores y procesadores de alimentos a rastrear el movimiento de productos de la granja a la mesa, optimizar la logística y garantizar la seguridad alimentaria. En general, la IA en la agricultura están contribuyendo a una mayor productividad, costos reducidos, mayor sostenibilidad y mejor seguridad alimentaria para la creciente población mundial., así como para desarrollar técnicas de purificación del agua y su uso racional (Vanitha et al., 2023).

La IA puede revolucionar la agricultura, lo que impacta a una economía global que emplea más del 30% de la población mundial directa o indirectamente. También puede satisfacer las necesidades de una población mundial en constante crecimiento a través de la automatización de prácticas agrícolas como el deshierbe, fumigación con pesticidas, riego, el monitoreo del estado nutricional y la humedad del suelo, etc., todo eso se puede realizar más rápido usando robots, sensores, drones y algoritmos (Karmaoui et al., 2023).

Dawn et al. (2023) señalan que la IA reduce el desperdicio de agua y el uso excesivo de pesticidas, mantiene la fertilidad del suelo, ayuda a reducir la mano de obra y mejora el rendimiento y la productividad de los cultivos a pesar de todos los problemas. Sin embargo, su penetración en la agricultura aún está en pañales debido a su naturaleza antieconómica, falta de experiencia y requisito de big data para la precisión, entre otros.

Actualmente el interés por la IA está enfocada a los impactos que esta herramienta puede provocar en la agricultura, al desarrollo de nuevas herramientas y software que se están utilizando, así como en los desafíos y alcances futuros relacionados con este campo. Combinado con modelos artificiales de redes neuronales (ANN) y máquinas de aprendizaje (ML), junto con sistemas expertos (ES) e Internet de las cosas (IoT), la IA puede hacer maravillas en la agricultura en los años por venir (Wakchaure et al., 2023).

La seguridad alimentaria es una de las prioridades de todos los países del mundo. Sin embargo, diferentes factores están dificultando el cumplimiento de los objetivos globales en materia de seguridad alimentaria. Algunas perturbaciones sin precedentes están obstaculizando la seguridad alimentaria a nivel mundial.

Se han aplicado diversas técnicas para la seguridad alimentaria y se ha demostrado que la IA es uno de los métodos modernos que se están utilizando en varias etapas del sistema alimentario (Kutyauripo et al., 2023). Actualmente se están aplicando varios algoritmos de inteligencia artificial en todas las etapas del sistema alimentario, desde la producción de cultivos o en la ganadería, hasta el manejo de alimentos o residuos agrícolas.

Las aplicaciones de la IA y las imágenes satelitales en la agricultura sustentable son muy amplias, es decir, cómo asignar recursos en las tierras de cultivo en función de los resultados del monitoreo de las imágenes satelitales. En primer lugar, Efremova et al. (2023) proponen un marco novedoso para abordar los problemas relacionados con el cambio climático en el sector agroalimentario, el cual considera los avances recientes de la

IA y datos de observación de la Tierra, que describen un enfoque a alto nivel.

Estos autores caracterizaron la política de asignación óptima de recursos considerando varios parámetros físicos de biomonitordeo, como la biomasa del pasto, el área foliar, el porcentaje de sobrepastoreo y muchos otros. Este monitoreo luego se combina con una política simple de asignación de recursos.

# MONITOREO EN TIEMPO REAL DE VARIABLES BIÓTICAS Y ABIÓTICAS

El reporte de Wang et al. (2023) indica que el monitoreo se puede aplicar en tiempo real en grandes territorios con una estimación muy precisa de los parámetros de biomonitorio; el método de asignación de recursos propuestos supera las prácticas de monitoreo de pastizales existentes, y además puede usarse para estimar si las prácticas agrícolas actuales están alineadas con los Objetivos de Desarrollo Sustentable, específicamente con el ODS 2 de “hambre cero” de la ONU.

Las malezas son plantas no deseadas en el suelo agrícola. Siempre compiten con los cultivos por la luz solar, los nutrientes, el espacio y el agua. El crecimiento descontrolado de las malezas puede causar importantes pérdidas económicas y ecológicas. Por lo tanto, las malezas deben diferenciarse de manera eficiente de los cultivos para realizar una fumigación inteligente. Ong et al. (2023) utilizaron la red neuronal convolucional (CNN) para realizar la detección de malezas entre un cultivo comercial de col china, utilizando las imágenes adquiridas por drones.

Las imágenes obtenidas se preprocesaron y luego se segmentaron en las clases de cultivo, suelo y malas hierbas, utilizando el algoritmo Superpixel de agrupamiento iterativo lineal simple. Luego, las imágenes segmentadas se usaron para construir el clasificador basado en CNN. Se aplicó la técnica Random Forest para comparar con el desempeño de CNN.

En el manejo moderno del riego para la producción agrícola, se necesita un monitoreo preciso del consumo de agua de los cultivos con una alta resolución espacial y temporal a escala de finca. Shao et al. (2023) desarrollaron modelos para la estimación de coeficientes de cultivo ( $K_c$ ) utilizando técnicas de detección remota y aprendizaje automático de drones para el maíz de riego en una región semiárida en el noroeste de China.

Los valores de  $K_c$  se calcularon usando un procedimiento del manual FAO56 usando mediciones de campo. Los índices de vegetación multiespectrales, la fracción de vegetación, los datos basados en temperatura y la información de textura se derivaron de imágenes infrarrojas térmicas, RGB y multiespectrales basadas en drones.

Estas variables de detección remota y sus combinaciones se usaron para desarrollar modelos de predicción utilizando seis algoritmos. Los resultados muestran que la integración de la detección remota proporciona una herramienta prometedora para ayudar a los agricultores a tomar decisiones utilizando el consumo de agua de cultivos mapeado oportunamente, especialmente en condiciones de escasez de agua o sequía.

Por otro lado, la agricultura de la India actualmente está experimentando un cambio drástico hacia la mecanización y el uso de herramientas modernas de tecnología

de la información y la comunicación, como apoyo del poderoso trabajo realizado por los agricultores en sus respectivos campos para servir alimentos a millones de personas.

Debido a los diversos esfuerzos realizados por científicos y académicos agrícolas, el alcance de la inteligencia artificial también ha influido en la agricultura y está encontrando soluciones a los problemas actuales como la escasez de mano de obra, la menor productividad y otras consecuencias similares (Sundar y Asokhan, 2023).

Un componente importante es el uso drones y sus aplicaciones en la agricultura. Por eso, los gobiernos estatales de la India se están enfocando en proporcionar drones a los agricultores como parte del fomento del concepto de agricultura sostenible.

Ese estudio presenta un enfoque a microescala para la evaluación de la capacidad de las tierras de cultivo basado en un dron de bajo costo equipado con un sensor RGB disponible comercialmente. El área de estudio escogido por Radočaj et al. (2023) se dividió en dos subconjuntos (A y B) que contienen plantaciones de naranja mandarina realizadas durante los años 2000 y 2008. El trabajo de campo se realizó utilizando un VAN Mavic 2 Pro equipado con un sensor RGB comercial.

La idoneidad de las tierras de cultivo se realizó en un proceso de clasificación de dos pasos, utilizando: (1) clasificación supervisada con algoritmos de aprendizaje automático para crear una máscara de vegetación; y (2) la clasificación no supervisada para evaluación de idoneidad según el estándar de la ONU para la Agricultura y la Alimentación (FAO).

Los niveles resultantes indicaron una idoneidad positiva en ambos subconjuntos de estudio, con 63.1% de área adecuada en el subconjunto A y 59.0% en el subconjunto B. A pesar de eso, la eficiencia de la producción agrícola se puede mejorar mediante el manejo de las propiedades del cultivo y del suelo en el área actualmente no adecuada.

Los científicos fitomejoradores de soya deben desarrollar variedades de maduración temprana, estándar y de maduración tardía, para plantar en diferentes latitudes y así garantizar que las plantas de soya usen totalmente la radiación solar.

Por lo tanto, el monitoreo oportuno de la madurez de la línea de cultivo de soya es crucial para el manejo agronómico de la cosecha y la medición del rendimiento. Actualmente, los modelos de aprendizaje profundo utilizados se centran más en extraer características de imágenes profundas, mientras que se ignora la información de características de imágenes superficiales (Padmapriya y Sasikala, 2023).

Debido a eso en el estudio de Zhang et al. (2023) se diseñó una nueva arquitectura de red neuronal convolucional (CNN), llamada DS-SoybeanNet, para mejorar el rendimiento del monitoreo de información de madurez de soya basado en drones.

DS-SoybeanNet puede extraer y utilizar funciones de imágenes profundas y superficiales. Los resultados muestran que: (1) Los métodos convencionales de aprendizaje automático tuvieron tiempos de cálculo más rápidos que los métodos de aprendizaje profundo (InceptionResNetV2, MobileNetV2 y ResNet50) y el método propuesto DS-SoybeanNet.

## DRONES Y EL INTERNET DE LAS COSAS (IOT)

Güven et al. (2023) argumentan que la sustentabilidad agrícola es un concepto complejo que apunta a la rentabilidad económica y la equidad socio económica, además de la salud ambiental. La agricultura inteligente es la revolución agrícola más reciente que se basa en el uso de tecnologías de la información y la comunicación. Conecta máquinas inteligentes y sensores en granjas mediante el internet de las cosas (IOT) y hace que las prácticas agrícolas sostenibles estén basadas en datos (Figura 11).



**Figura 11.** La tecnología del Internet de las cosas está cambiando radicalmente algunos sectores que prometen cambios fundamentales en la agricultura. La calidad de la cosecha, el mayor rendimiento de los cultivos, la conservación de los recursos y el control de costos, son solo algunas de las formas en que IOT promete transformar la industria agrícola y la producción de alimentos (Tomado de: <https://livity.com/iot-in-agriculture-practical-uses>).

El punto clave de la agricultura inteligente es la “optimización”; que tiene como objetivo perfeccionar cada variable e insumo durante la etapa de producción. Debido a eso, el uso de la tecnología de la información aumenta la cantidad y calidad de los productos agrícolas al preservar los recursos naturales (Wakchaure et al., 2023). Queda claro que la industria agrícola moderna necesita aprender a hacer más con menos, siendo eso posible mediante la implementación de métodos de producción más eficientes y sostenibles; por lo tanto, la robótica, la IA y el IOT podrían nivelar el camino hacia un futuro mejor.

El aprendizaje automático (ML) y la IA están transformando rápidamente la

agricultura al proporcionar soluciones basadas en datos para el manejo de cultivos y ganado, agricultura de precisión, y gestión de la cadena de suministro. Los algoritmos de ML pueden analizar grandes cantidades de datos de varias fuentes como sensores, drones e imágenes satelitales, para proporcionar información que puede ayudar a los agricultores a optimizar el uso de los recursos, mejorar el rendimiento y la calidad de los cultivos, controlar la salud del ganado, y predecir brotes de enfermedades (Vishwakarma et al., 2023).

La agricultura de precisión es posible gracias a los rápidos avances en el aprendizaje profundo (DL) y el IOT para la agricultura, lo que permite a los agricultores actualizar sus operaciones agrícolas para satisfacer de manera sostenible el suministro de alimentos en el futuro. El documento de Saranya et al. (2023), presenta una descripción general completa de las contribuciones de investigación recientes en DL e IOT para la agricultura de precisión.

En ese trabajo se examinan diversas investigaciones sobre las aplicaciones de DL en la agricultura, como la detección de plagas, enfermedades, rendimiento, malezas y calidad del suelo. Además, describe la arquitectura de la IOT y analiza la categorización de sensores agrícolas y drones utilizados en investigaciones recientes. Los resultados obtenidos muestran que el modelo propuesto para la detección de plagas supera a todos los demás modelos con una precisión del 96.58%.

El trabajo de Dwivedi et al. (2023) relata que la información espacial precisa de la distribución de los cultivos es vital para que el gobierno y las organizaciones de investigación supervisen las actividades agrícolas, como el control de la salud de los cultivos, la predicción del rendimiento y la seguridad alimentaria. Con una extensión de la IA, una red neuronal artificial tiene la capacidad de aprender la característica espectral de las imágenes satelitales multiespectrales y asignarlas a una clase de cobertura terrestre.

La agricultura es la columna vertebral de la economía india; para el 2050, se espera que la población mundial alcance los 9,700 millones, lo que requerirá un aumento del 70% en la producción mundial de alimentos (Pal y Joshi, 2023). Estos autores señalan que las prácticas agrícolas tradicionales son cada vez más ineficientes y poco confiables debido a problemas, que incluyen la degradación del suelo, el estrés hídrico, la escasez de nutrientes, los enlaces de infraestructura insuficientes, la pérdida poscosecha y la asimetría de la información.

Por lo tanto, la agricultura inteligente (AI) o agricultura digital ahora se considera una práctica mucho más sostenible, ya que incluye el manejo de granjas a través de tecnologías de vanguardia como el IOT, robótica, inteligencia artificial, drones, big data, etc.

La agricultura inteligente se refiere al uso de tecnologías de manejo de información y datos. La AI conduce a sistemas agrícolas altamente productivos y sostenibles, ya que proporciona al agricultor muchas ventajas para la toma de decisiones para un mejor manejo agronómico. Las tecnologías agrícolas inteligentes recopilan medidas precisas de los factores que determinan los resultados.

También permite que la agricultura sea más confiable, predecible y sostenible. Asimismo, mejora la salud de los cultivos, reduce la huella ecológica de la agricultura, ayuda a alimentar a la creciente población mundial, brinda seguridad alimentaria en escenarios de cambio climático y logra mayores rendimientos, al tiempo que reduce los costos operativos en la granja o finca (Prajapati et al., 2023).

Por su parte, Gokool et al. (2023) realizaron un análisis bibliométrico para evaluar el estado del arte con respecto a las aplicaciones reales de las tecnologías de drones para guiar las prácticas de agricultura de precisión (AP) dentro de las fincas de pequeños agricultores. Ellos señalan que los drones son una de las herramientas más prometedoras para monitorear cultivos y guiar las prácticas de AP para mejorar la productividad agrícola y promover el uso sostenible y óptimo de recursos críticos.

Los resultados de estas investigaciones revelaron que los drones se han utilizado en gran medida para monitorear el crecimiento y desarrollo de los cultivos, guiar la aplicación de los fertilizantes y el mapeo de cultivos, pero también tienen el potencial de facilitar otras prácticas de la agricultura de precisión.

El trabajo realizado por Goodrich et al. (2023) desarrolló un algoritmo que optimizó las rutas de vuelo de múltiples agentes para escanear sensores en un campo agrícola simulado. Las ubicaciones de los sensores de suelo para un campo de riego con pivote central imitado de 400 m, se usaron para determinar las rutas de vuelo de enjambres de 1 a 8 drones.

El aumento de la cantidad de drones tuvo un efecto insignificante en el gasto total de energía, pero redujo el tiempo para escanear los sensores de 19 minutos a menos de tres minutos. Se concluyó que el algoritmo de reducción secuencial de brechas propuesto maximiza la cobertura de cualquier campo agrícola de forma arbitraria y con menos sensores que una distribución basada en cuadrícula.

# DRONES PARA EL MANEJO DE LA FERTILIDAD DEL SUELO

## EN CULTIVOS DE ÁRBOLES FRUTALES

La tecnología de drones trae un cambio revolucionario en todos los sectores de producción, suministro y servicio. Llegaron como una nueva revolución al campo de la agricultura de precisión. Al ser dispositivos ligeros, fáciles de manejar e inteligentes, los drones junto con el IOT y sensores, ayudan a que aumente la presición de la agricultura inteligente.

Esto puede considerarse como la revolución de la moderna agricultura 4.0. Gupta et al. (2023) mencionan que el uso de la tecnología de drones no solo ayuda a mejorar la producción, sino que también pueden ayudar a evitar el desperdicio de las cosechas y de los cultivos establecidos en lugares de difícil acceso para el ser humano debido a las condiciones geográficas.

El control de la calidad, el volumen y el desarrollo de los frutos en la plantación es fundamental para garantizar que la fruta se coseche en el momento óptimo. Las frutas son más susceptibles a la enfermedad mientras están creciendo activamente. Es posible mejorar la productividad agrícola mediante la detección temprana de enfermedades. Una granja grande hace que sea difícil inspeccionar cada árbol para conocer sus frutos.

Nambi et al. (2022) señalan que los huertos de frutales requieren un manejo específico del sitio o incluso de un árbol individual durante la temporada de crecimiento. Por eso, la detección remota a través de drones se está volviendo más común entre los productores y es muy útil para el monitoreo de cultivos en tiempo real.

Una empresa en Israel combina la inteligencia que recopila de drones con tecnología de imágenes multidimensionales de alta resolución, sensores terrestres y muestras recopiladas por equipos en el terreno para proporcionar datos sobre árboles individuales y grupos de árboles (Figura 12).



**Figura 12.** En arbóles frutales los drones pueden detectar de manera rápida y precisa información de algún posible problema que se presente en árboles individuales o de toda la huerta (Tomado de: <https://www.timesofisrael.com/barking-up-the-right-tree-israeli-startup-seetree-aims-at-better-fruit-yield/>).

Kabilesh et al. (2023) consignan que existen varias aplicaciones para el procesamiento de imágenes con el IOT en diversos campos. Por ejemplo, proteger los árboles frutales de enfermedades y condiciones climáticas, es difícil para los agricultores y sus trabajadores que deben examinar regularmente grandes áreas. Con la llegada de la agricultura de precisión, ha surgido una nueva forma de pensar sobre la agricultura, que incorpora innovaciones tecnológicas de vanguardia como los drones.

En el reporte de Ali et al (2023) se plantea que uno de los mayores desafíos de los agricultores modernos es detectar las enfermedades de las frutas en sus primeras etapas. Si las infecciones no se identifican a tiempo, los agricultores podrían ver reducidos sus ingresos. Por lo tanto, con los drones es posible monitorear con precisión grandes áreas, identificar plantas enfermas y decidir el producto químico a rociar y la dosis precisa a usar.

El dron está conectado a un servidor en la nube que recibe imágenes y genera información a partir de estas imágenes, incluidas las proyecciones de producción de cultivos. La base de la granja puede interactuar con el sistema con una interfaz humano-robot fácil de usar. Por lo tanto, con esta nueva tecnología es posible manejar una gran área de tierras de cultivo diariamente utilizando drones agrícolas para reducir el impacto ambiental y aumentar la productividad de los cultivos.

El diagnóstico oportuno de la nutrición de árboles frutales como el manzano es muy importante para la utilización eficiente de los nutrientes y para mejorar el rendimiento y la calidad de la manzana. El estudio de Chen et al. (2022) estableció un modelo de predicción del contenido de N, P y K en las hojas de manzanos basado en la reflectancia del dosel.

Se realizaron experimentos de campo de dos años con cuatro niveles de aplicación de N durante el 2018 y 2019. Los datos, incluida la reflectancia hiperespectral a escala del dosel y los contenidos de N, P y K de las hojas, se recopilaron desde la etapa de fruta joven hasta la etapa de crecimiento de la fruta.

Los resultados mostraron que el modelo basado en máquinas de aprendizaje logró mejores resultados de predicción, pero los resultados del modelo optimizado por el algoritmo de evolución diferencial eran propensos a sobreajustarse. Se concluye que el método fue confiable para la predicción *in situ* de los contenidos de N, P y K en hojas de manzano.

Los algoritmos de aprendizaje profundo necesitan una mayor exploración en la evaluación del estado del N de los cultivos a partir de datos hiperespectrales del dosel. Por lo tanto, el uso de drones puede proporcionar un apoyo técnico para promover las aplicaciones de la teledetección hiperespectral en la evaluación del estado del N de los cultivos.

El mapeo oportuno y preciso del índice de área foliar (LAI) en los viñedos tiene una función importante para las opciones de manejo en las prácticas agrícolas de precisión. Sin embargo, solo se ha trabajado poco para extraer el LAI de viñedos entrenados con pérgola utilizando datos de teledetección de mayor resolución espacial. Debido a eso, el objetivo principal de Ilniyaz et al. (2023) fue evaluar la capacidad de las imágenes de drones para estimar el LAI de viñedos entrenados con pérgola, utilizando métodos de aprendizaje automático superficiales y profundos.

Los ensayos de campo se realizaron en diferentes temporadas de crecimiento en 2021 mediante la recolección de 465 muestras de LAI. Los resultados indicaron que los índices texturales se desempeñaron mejor que los índices espectrales, mientras que la combinación de ellos puede mejorar los resultados de la estimación, y el método de aprendizaje conjunto mostró ser el mejor entre los modelos ML clásicos.

La adquisición rápida y precisa del contenido de nutrientes N-P-K en otros frutales como la vid es también muy importante, por eso el análisis de hojas de *Vitis vinifera* es fundamental para mejorar el rendimiento y la calidad de la uva y para el desarrollo industrial. En un estudio realizado por Penget al. (2022), el crecimiento del cultivo fue monitoreado de forma no destructiva en base a la tecnología de detección remota con drones.

En ese estudio se establecieron tres niveles de riego (W1, W2 y W3) y cuatro niveles de fertilización (F3, F2, F1 y F0). Se realizó un análisis de correlación utilizando datos de imágenes multiespectrales y los valores de contenido de N foliar (LNC), contenido de K foliar (LKC) y contenido de P foliar (LPC) medidos en el campo; a partir de los resultados se determinaron los índices de vegetación que fueron sensibles a LNC, LKC y LPC.

Los resultados mostraron que: (1) hubo altas demandas de N durante los períodos de crecimiento y floración de nuevos brotes, el K fue el principal nutriente absorbido en el período de expansión de la fruta, y el P fue el principal nutriente absorbido en los períodos de envero y madurez. (2) La combinación de múltiples variables espectrales con

los modelos RF, SVM y ELM podría resultar en predicciones mejoradas de LNC, LPC y LKC. En conclusión, las imágenes multiespectrales de drones tienen buenos efectos de aplicación al predecir el contenido de nutrientes en las hojas de vid. Este estudio puede proporcionar apoyo técnico para un manejo preciso de los nutrientes de los viñedos usando drones.

Trabajando con plantas de vid (*V. labruscana*) variedad Concord, Chancia et al. (2021) identificaron los conjuntos óptimos de bandas espectrales para monitorear múltiples nutrientes en viñedos. Usaron datos espectrales que abarcan de 400 a 2500 nm y muestras de 100 hojas de vid. Los datos espectrales del dosel se obtuvieron con drones utilizando sensores hiperespectrales. El novedoso uso de estas imágenes para evaluar el estado nutricional de la vid, llena el vacío existente entre el muestreo espectral *in situ* y las imágenes multiespectrales, evitando sus compensaciones inherentes entre resolución espacial y espectral.

En este estudio se identificó un conjunto de bandas bioquímicamente consistentes (606, 641 y 1494 nm) para predecir el contenido de N con un margen de error de 0.17%. Por lo tanto, se concluye que son requeridos más estudios para confirmar la relevancia y consistencia de las longitudes de onda seleccionadas para cada nutriente, pero la selección de características del conjunto resultó prometedora en la identificación de conjuntos estables de longitudes de onda para evaluar el contenido de nutrientes a partir de los espectros del dosel.

El trabajo realizado por Rustioni et al. (2018) tuvo como objetivo la identificación de los síntomas de deficiencia de diversos minerales por espectroscopia de reflectancia. Las plantas de *V. vinifera* fueron sometidas a 5 diferentes nutrientes minerales hidropónicos: control y deficiencias de Fe, Mg, N y K. Se estudiaron hojas basales, jóvenes y apicales.

Los espectros se recolectaron a lo largo de las venas, en las áreas intervenales y en los márgenes de las hojas. La espectroscopia pareció ser capaz de discriminar las deficiencias minerales, produciendo pigmentaciones características y distribución de síntomas. Estos resultados parecen ser coherentes con la función fisiológica de cada nutriente y podrían respaldar futuras investigaciones, incluido el desarrollo de índices para la cuantificación de la intensidad de los síntomas y la definición de valores umbral para manejar la fertilización.

## EN ESPECIES DE CULTIVOS HORTÍCOLAS

En cultivos de cucurbitáceas como: pepinos, calabazas y melones la floración es uno de los procesos de polinización más importantes. Los polinizadores naturales como las abejas y las mariposas están disminuyendo, lo que reduce drásticamente las cosechas. Por lo tanto, el objetivo de Mithra y Nagamalleswari (2023) fue utilizar imágenes de vehículos aéreos no tripulados para crear un aprendizaje de transferencia profunda, que les permitiera detectar patrones florales en la polinización autónoma de ese tipo de cucurbitáceas.

Las imágenes tomadas por el dron equipado con una cámara OpenMV en diversas situaciones se recopilan y almacenan en la base de datos CuCuflower para la identificación de flores. Para la autopolinización, se observa el área de polen y otras características identificables para la clasificación del género y la familia de las flores. Los resultados revelaron que el modelo propuesto funciona mejor en la detección de la flor polinizadora y el factor de impulso AP50 con 0.95 es 91% y 92%, respectivamente, que son mejores que otros métodos de detección.

El estudio de Go et al. (2022), tuvo como objetivo determinar las etapas de crecimiento basadas en la estimación remota de la altura del repollo con drones y evaluar el impacto de la textura del suelo en la altura del repollo. La variación de la serie temporal según el crecimiento del repollo Kimchi exhibe una curva sigmoidal en forma de S.

El modelo logístico de la curva de crecimiento indica la altura y la variación del crecimiento de la col o repollo kimchi y, por lo tanto, se puede derivar la tasa de crecimiento y la fórmula de aceleración del crecimiento del cultivo. Ese modelo de crecimiento producido expresa la variación en el valor del modelo de superficie del repollo para cada fecha de observación del repollo en cada condición de textura del suelo con un alto grado de precisión.

Las mediciones realizadas utilizando imágenes hiperespectrales, obtenidas en varias etapas diferentes del desarrollo de la planta, se aplicaron en un experimento. Se desarrolló un algoritmo de aprendizaje automático denominado Backpropagation Neural Network, Random Forest, Naive Bayes y Support Vector Machine, para clasificar plantas de cuatro variantes de fertilización con fósforo. La precisión de predicción más baja se obtuvo para la primera etapa medida del desarrollo de la planta.

Los análisis estadísticos mostraron correlaciones entre los constituyentes bioquímicos de las hojas, la fertilización con P y la biomasa de hojas y raíces de las plantas. Los resultados obtenidos demuestran que las imágenes hiperespectrales combinadas con métodos de inteligencia artificial tienen potencial para la detección no invasiva de fertilización de P no homogénea en los cultivos.

El suelo es la base para el crecimiento de Brasicáceas como la col o repollo, y es importante evaluarlo no solo para brindar información sobre cómo afecta el crecimiento de las plantas, sino también para el manejo del cultivo. Hasta ahora, las mediciones de

campo sobre el repollo han medido las variaciones de tamaño y crecimiento, pero este método requiere mucho tiempo y esfuerzo. En cambio, los drones y los sensores brindan oportunidades para capturar y utilizar con precisión los datos de crecimiento y variación del repollo. Los drones también se usan en cultivos de solanáceas como el tomate para inspeccionar y detectar posibles problemas bióticos o abióticos (Figura 13).



**Figura 13.** En hortalizas de invernadero como el tomate, los drones pueden inspeccionar toda la superficie sembrada para detectar plagas, enfermedades, grado de madurez de los frutos y otras variables (Tomado de: <https://www.hortidaily.com/article/9459785/drones-fly-through-tomato-rows-in-international-greenhouse-challenge/>).

La agricultura moderna se esfuerza por manejar de forma sustentable los fertilizantes por motivos económicos y ambientales. El seguimiento de cualquier deficiencia nutricional en las plantas es un desafío para la tecnología de producción de hortalizas en el contexto de la agricultura de precisión. Siedliska et al. (2021) realizaron un estudio sobre tres especies hortícolas: 1) apio (*Apium graveolens* L., cv. Neon); 2) remolacha azucarera (*Beta vulgaris* L., cv. Tapir) y 3) fresa (*Fragaria × ananassa* Duchesne, cv. Honeoye), fertilizadas con cuatro dosis diferentes de P.

En la literatura se evidencia la falta de estudios realizados sobre sensores remotos hiperespectrales para evaluar el estado nutrimental de cultivos hortícolas en condiciones de invernadero. Según Nguyen et al. (2020) esto puede atribuirse a problemas técnicos asociados con condiciones de iluminación durante la adquisición de datos en el día debido a las sombras y la dispersión espectral dentro de las estructuras del invernadero.

Por lo tanto, estos autores desarrollaron un novedoso sistema de detección remota hiperespectral basado en la noche con iluminación halógena adjunta para estudiar la reflectancia de las hojas de bok choy [*Brassica rapa* L. var *Chinensis*] y espinacas [*Spinacia*

oleracea L. var. Correnta] cultivadas en invernadero con fertilización alta, media y baja.

Los resultados señalan que: 1) la reflectancia de la hoja podría usarse para diferenciar regímenes de fertilización bajos versus medios/altos con una precisión del 75 % (bok choy) y del 80 % (espinacas), y 2) las regiones espectrales a: 700–709 nm, 780–787 nm y 817–821 nm se asociaron con los niveles de N, K, Mg y Ca en bok choy y espinacas. Se concluye indicando que el análisis de sensibilidad propuesto tiene gran relevancia como método práctico para examinar a fondo la solidez de los algoritmos basados en la reflectancia que se utilizan para clasificar los productos agrícolas.

Las aplicaciones de la teledetección con drones son importantes para mejorar la producción de los cultivos de papas mediante la adopción de la agricultura de precisión. Esta tecnología podría ser útil para disminuir la posible contaminación del suelo y el agua debido a la sobreertilización de los cultivos. Jasim et al. (2020) evaluaron sensores activos (Crop Circle™, Holland Scientific, Inc., Lincoln, NE, EE.UU. y GreenSeeker™, Trimble Navigation Limited, Sunnyvale, CA, EE. UU.) y sensores pasivos (imágenes multiespectrales con drones) para predecir el rendimiento de papa y la absorción de fósforo.

Los índices de vegetación y la clorofila se calcularon en varios momentos durante el ciclo de crecimiento y se correlacionaron con los rendimientos totales y la absorción de P mediante el ajuste gradual de modelos de regresión lineal múltiple. Los datos generados por Crop Circle™ y GreenSeeker™ tuvieron un valor predictivo bajo de los rendimientos de papa, especialmente al principio de la temporada. Crop Circle™ se desempeñó mejor que GreenSeeker™ en la predicción de la absorción de P de la planta.

Por el contrario, los datos de los sensores pasivos proporcionaron buenas estimaciones de los rendimientos totales a principios de la temporada, pero tuvieron una correlación deficiente con la absorción de P. El uso combinado de sensores activos y pasivos presenta una oportunidad para un mejor manejo del P en cultivos de papa.

Considerando lo antes mencionado, se debe señalar que el monitoreo satelital continuo dentro nutriente como el N, ayudaría a comprender la eficiencia del uso de N por los cultivos y plantas individuales y, por lo tanto, permitiría el manejo adecuado de N en un sitio específico. Debido a que los sensores de imágenes hiperespectrales proporcionan mediciones detalladas de la actividad óptica de los constituyentes químicos, tienen una ventaja sobre los métodos de detección multiespectral para el contenido de N.

Berger et al. (2020) indican que los métodos de detección se pueden agrupar en: (1) métodos de regresión paramétrica, (2) métodos de regresión no paramétrica lineal o quimiometría, (3) métodos de regresión no paramétrica no lineal o algoritmos de regresión de aprendizaje automático, (4) basados en modelos de transferencia radiativa (RTM), (5) uso de fuentes de datos alternativas (fluorescencia inducida por el sol, SIF) y (6) técnicas híbridas o combinadas.

El óptimo manejo del N es esencial para la producción rentable de cultivos hortícolas y para minimizar las pérdidas de N en el ambiente, las cuales son consecuencia de un

suministro excesivo de N. Padilla et al. (2018) indican que los sensores ópticos proximales colocados en contacto o cerca del cultivo pueden proporcionar una evaluación rápida del estado de N del cultivo. Hay tres tipos de sensores ópticos: medidores de clorofila; sensores de reflectancia del dosel, y medidores de flavonoles basados en fluorescencia, que permiten monitorear el estado del N en los cultivos de hortalizas.

## EN CULTIVOS DE ESPECIES GRAMÍNEAS

En los últimos años, se han utilizado métodos de detección remota para evaluar el estado nutricional del suelo y los cultivos, así como la variabilidad dentro del campo. El objetivo principal del estudio de Mazur et al. (2023) fue calcular la relación entre la reflectancia espectral derivada de un dron, para el cultivo de centeno (*Secale cereale L.*) y para diferentes fertilizaciones con fósforo y potasio.

El efecto de la fertilización con P y K sobre la reflectancia espectral fue más fuerte en el experimento con monocultivo que en el experimento con una rotación de cultivos. La correlación del contenido de P y K fue muy débil en el experimento con rotación de cultivos, mientras que, en el experimento con el monocultivo de centeno, la correlación fue ligeramente más fuerte, lo que indica un efecto más fuerte de la deficiencia de nutrientes en el monocultivo.

El nitrógeno es uno de los elementos decisivos para el crecimiento de las plantas, la acumulación de biomasa de cultivos y el rendimiento de los cultivos de cereales como trigo, centeno, arroz, maíz, etc. Sin embargo, el manejo del N en la producción de cultivos y la comparación de la eficiencia del uso de N son un gran desafío sin un conocimiento previo del estado del N del cultivo durante. Li et al. (2022) reportan que el desarrollo de curvas de dilución críticas de N basadas en la alometría entre los compartimentos metabólico y estructural de las plantas permite estimar el estado nutricional de N del cultivo mediante la determinación del índice de nutrición de N. Esto permite hacer un uso más eficiente de este nutriente y a la vez se ahorra dinero.

El trabajo de Yang et al. (2021) exploró la recuperación de nutrientes de potasio en hojas de trigo utilizando espectros de reflectancia. Los datos espectrales se recopilaron de hojas de trigo en diferentes etapas de crecimiento, en diferentes cultivares y después de diferentes tratamientos de fertilización de 2016 a 2019. Se recopilaron datos de reflectancia de 350 a 2500 nm y se usaron datos de 400 a 2400 nm en la recuperación.

Los datos arrojaron un contenido de potasio foliar (LKC, %) y potasio foliar por área (LKA, g/m<sup>2</sup>). Los modelos de recuperación LKC tenían valores R<sup>2</sup> más altos que los modelos LKA. Este análisis exhaustivo de diferentes métodos reveló la importancia de la reflectancia a 1883 nm y 2305 nm. En conclusión, los autores señalan que es factible recuperar los niveles de potasio en la hoja de trigo utilizando datos espectrales.

La optimización del manejo del N en el arroz es crucial para la seguridad alimentaria y el desarrollo agrícola sostenible de China. El monitoreo no destructivo del crecimiento de los cultivos basado en tecnologías de detección remota puede evaluar con precisión el estado del N del cultivo, que puede usarse para guiar las recomendaciones de N durante la temporada. Zha et al. (2020) reportan que la detección remota basada en drones de ala fija, es una tecnología de bajo costo y fácil de operar para recopilar imágenes de reflectancia espectral, una fuente de datos importante para el manejo preciso del N.

Se concluye que la regresión de aprendizaje automático puede mejorar la estimación del estado de N del arroz utilizando la detección remota de drones. Los métodos de aprendizaje automático de la aplicación ofrecen una nueva oportunidad para utilizar mejor los datos de detección remota para monitorear las condiciones de crecimiento de los cultivos y guiar el manejo de cultivos de precisión. Sin embargo, se necesitan más estudios para mejorar aún más estos modelos basados en el aprendizaje automático mediante la combinación de datos de teledetección y otra información relacionada con el suelo, el clima y el manejo del N en la agricultura de precisión.

La concentración de nitrógeno vegetal (PNC) es un indicador crítico del estado del N para los cultivos y puede usarse para el diagnóstico y manejo de la nutrición del N. Zheng et al. (2018) exploraron el potencial de las imágenes multiespectrales de drones para la estimación de PNC y mejorar la precisión de la estimación con datos hiperespectrales recopilados en el campo con un radiómetro.

Esos autores realizaron experimentos dos años consecutivos (2015 y 2016) con diferentes dosis de N, densidades de siembra y cultivares de arroz (*Oryza sativa* L.). Los resultados demostraron que los drones se desempeñaron consistentemente bien en todas las etapas de crecimiento. Por lo tanto, la integración de índices espectrales de banda estrecha basados en tierra con información textural basada en drones podría ser una técnica prometedora en el monitoreo del crecimiento de cultivos.

El N está muy relacionado con la capacidad fotosintética de los cultivos. La aplicación excesiva o insuficiente de fertilizantes nitrogenados no solo limita la productividad de los cultivos, sino que también genera impactos ambientales negativos. Con tal dilema, una solución factible es hacer coincidir el suministro de N con las necesidades de los cultivos en el tiempo y el espacio.

Debido a eso, Fu et al. (2021) señalan que la teledetección hiperespectral se ha considerado gradualmente como una opción muy rentable al muestreo destructivo tradicional en el campo, ya que ahora los algoritmos de aprendizaje automático han ejercido gradualmente ventajas en el modelado de las relaciones no lineales entre los datos espectrales y el N de los cultivos.

Determinar la cantidad precisa de fertilizante nitrogenado para el maíz en un campo y año en particular, es un gran desafío debido a la complejidad de las entradas, transformaciones y salidas de N durante el ciclo del N. La detección remota de la deficiencia de N en el maíz puede ser una forma de mejorar las aplicaciones de fertilizantes nitrogenados. Burns et al. (2022) establecieron ensayos en franjas en dos lugares de Arkansas, EE. UU., con una tasa de N como tratamiento principal.

Los datos de teledetección se recopilaron semanalmente con un dron equipado con un sensor térmico y multiespectral. Se evaluaron las relaciones entre el valor del índice, la tasa de fertilizante nitrogenado y la etapa de crecimiento del maíz. Concluyen diciendo que el índice de clorofila-verde y el índice de vegetación fueron los mejores predictores del rendimiento de maíz a principios de la temporada de crecimiento cuando la aplicación de N

adicional aún era agronómicamente factible. Sin embargo, se debe considerar la logística de la aplicación de N al final de la temporada.

Brasil es uno de los mayores productores de maíz a nivel mundial. Sin embargo, esta producción se ve amenazada por la baja fertilidad del suelo, especialmente por los bajos niveles de potasio. El K es uno de los nutrientes más importantes en el metabolismo de las plantas, actuando sobre la activación enzimática y también sobre los procesos fotosintéticos.

Furlanetto et al. (2021) reportan que la identificación de su deficiencia mediante el uso de métodos tradicionales es difícil. Por eso, el uso de cámaras modificadas de bajo costo conectadas a drones son herramientas importantes para el monitoreo agrícola. Considerando eso realizaron este estudio que tuvo como objetivo explorar la posibilidad de identificar la deficiencia de K y cuantificar el contenido foliar de nutrientes mediante el uso de un Índice de Vegetación.

Se establecieron los siguientes tratamientos: deficiencia severa de K (SPD), deficiencia moderada de K (DMP) y aporte adecuado de K (ASP). Las evaluaciones se realizaron en el cultivo de maíz variedad safrinha, con captura de imágenes que cubren la región visible y del infrarrojo cercano, utilizando dos cámaras digitales Fujifilm IS PRO conectadas a un dron.

Se recolectaron hojas para determinar la concentración de K en los tejidos. Con respecto a los tratamientos evaluados, los resultados mostraron que el K foliar fue estadísticamente diferente y los IV fueron eficientes solo para diferenciar los tratamientos SPD y ASP en todas las etapas de desarrollo.

El manejo adecuado de la fertilización con N tiene una función importante en la optimización del crecimiento y el rendimiento agrícola. Las preocupaciones sobre el riesgo ambiental requieren una determinación rápida, precisa y no destructiva del estado de N en los cultivos y eso lo permite la teledetección hiperespectral durante el ciclo del cultivo.

Li et al. (2021) reportan que, aunque se han propuesto muchos índices espectrales para evaluar el estado de N de los cultivos, aún es necesario optimizar más las bandas centrales, ya que a menudo varían con los cultivares y especies de plantas. Para mejorar esto, identificaron índices espectrales de tres bandas optimizados para estimar la absorción de N del dosel de maíz y trigo en China.

Tanto el trigo como el maíz se evaluaron individualmente, así como en combinación donde comparten bandas de onda similares reflejadas por los índices espectrales de tres bandas optimizados específicos de especies e interespecies, p. las longitudes de onda 740, 736 y 732 nm fueron identificadas como óptimas para maíz, trigo y su combinación.

Los resultados de la validación sugieren que las predicciones que utilizan el índice de dominio planar N de tres bandas optimizado generaron el coeficiente de determinación más alto ( $R^2 = 0.86$ ) y el error cuadrático más bajo ( $RMSE, 20.1 \text{ kg N ha}^{-1}$ ). Por lo tanto, el algoritmo de tres bandas optimizado es una herramienta atractiva para mejorar e identificar bandas centrales. Además, ese algoritmo puede permitir el diseño de sistemas mejorados de diagnóstico de N y optimizar la aplicación de detección terrestre y satelital.

# DRONES PARA ESTIMAR Y APlicAR EL AGUA DE RIEGO

La escasez de agua se ha convertido en uno de los mayores desafíos a los que se enfrenta la humanidad en la actualidad. Su escasez se ve agravada por el cambio climático y la creciente demanda de una población en crecimiento. Existe una necesidad urgente de promover tecnologías de riego sostenibles que optimicen la producción de alimentos sin aumentar el agua aplicada y con efectos secundarios ambientales positivos.

En el artículo publicado por Nhamo et al. (2023) se menciona que, en Sudáfrica, más del 60% de los recursos de agua dulce disponibles se utilizan en la agricultura, principalmente en la agricultura de riego. Las tecnologías y prácticas de riego sostenibles podrían mejorar la eficiencia en el uso del agua (WUE) y la productividad en la agricultura reduciendo así las cargas ambientales, incluido el uso de energía.

El cambio climático y las condiciones ambientales han causado muchos problemas en el sector agrícola. La población mundial en rápida expansión es un problema que debe abordarse para asegurar el suministro de alimentos y agua mediante el uso de tecnología de la informática en la agricultura de precisión y la agricultura inteligente.

Estos avances técnicos en agricultura de precisión están representados por los drones, los cuales ayudan en la agricultura al contar la cantidad de plantas, el manejo del agua de riego, el análisis de erosión, el conteo de plantas, el análisis de humedad del suelo, la evaluación de la salud de los cultivos, la programación del riego, el análisis de la fisiología de las plantas y el pronóstico del rendimiento (Mandla et al., 2023).

Los drones también se pueden utilizar para facilitar la actividad agrícola al recopilar datos sobre el desarrollo rural en términos de límites de tierras agrícolas, recursos hídricos y su superficie, límites de aldeas, monitoreo de áreas forestales, observación de regiones montañosas y de plantas altas, y condición del suelo en términos de contenido de agua, humedad, conductividad eléctrica, pH y la temperatura del suelo y aire.

La población mundial en constante aumento, la gran demanda de suministro de alimentos y la falta de agricultura de temporal o secano para satisfacer tales demandas, han aumentado la importancia del riego en la producción agrícola. El manejo del agua en el sistema de riego es el mayor problema, especialmente en regiones donde los efectos del cambio climático son notorios. La cantidad y el momento del riego para cada cultivo están en debate. Se necesita información sobre cultivos, clima y suelo para este propósito.

Desafortunadamente, obtener dicha información es difícil, especialmente cuando se trabaja con enormes extensiones de terreno. Samreen et al. (2023) mencionan que los científicos han estado trabajando para encontrar las respuestas a estos problemas durante muchos años. La ventaja de la teledetección con drones es que la recopilación de datos a grandes distancias se vuelve simple y eficiente. Este artículo se centra en las tecnologías de detección remota para el riego de precisión utilizadas para calcular la evapotranspiración, la termografía infrarroja, el estado hídrico de los cultivos y los atributos de los mismos.

Los datos precisos del suelo que se pueden recopilar con sensores agrícolas espaciados en el rango de medio variograma, son información crucial para la agricultura de precisión. Los drones ofrecen una ventaja única sobre otros métodos existentes para monitorear datos de sensores de suelo, eso es debido a la alta cantidad de sensores necesarios para recopilar datos sobre la variabilidad del suelo. Goodrich et al. (2023) reportan que, para determinar la ubicación de los sensores dentro de un campo agrícola, desarrollaron y utilizaron un novedoso algoritmo que minimiza la superposición de sensores para asignar su ubicación para cuatro tipos de campos agrícolas.

El algoritmo genético optimizó las rutas de vuelo de múltiples agentes para escanear sensores en un campo agrícola simulado utilizando un modelo sólido basado en agentes. El algoritmo maximiza la cobertura de cualquier campo agrícola de forma arbitraria con menos sensores que una distribución basada en cuadrícula en la mayoría de los casos.

El mapeo de rutas de vuelo de múltiples agentes propuesto puede generar rutas de vuelo de manera efectiva y eficiente para un número variable de drones para escanear todos los sensores. El marco propuesto aquí se puede utilizar y ampliar para el riego de tasa variable, la aplicación precisa de agentes de control biológico y la agricultura inteligente.

Jalajamony et al. (2023) presentaron un sistema de riego inteligente que permite el riego selectivo de puntos secos localizados en un campo agrícola. El sistema de riego utiliza un dron cuadricóptero equipado con una cámara de infrarrojos térmicos (TIR) y un módulo GPS para generar imágenes térmicas georreferenciadas que indican el área y la ubicación de los puntos secos en un área de estudio. Los drones navegan y adquieren imágenes térmicas, que luego son procesadas por un módulo de inteligencia artificial junto con los datos de vuelo (coordenadas GPS, altitud y dirección del dron).

De esta manera, los aspersores inteligentes desplegados en el campo pueden recibir de forma inalámbrica las coordenadas de los puntos secos para que se puedan regar de forma selectiva. Una unidad terrestre genera un patrón de riego para los aspersores inteligentes usando un modelo de aprendizaje automático previamente entrenado para generar un patrón de riego variando el ángulo de rotación del cabezal y el ángulo de rotación de la válvula de control del flujo de agua del aspersor inteligente.

El cálculo matemático y la medición directa comprenden dos grupos de métodos superpuestos utilizados en estimación del volumen de agua. El trabajo de Ruffell y O'Keefe, (2023) utilizó un enfoque de aproximación dual de Sonar y Water Penetrating Radar (WPR), los cuales se pueden montar en un dron. Los datos luego se analizan más a fondo para patrones espaciales en GIS y luego son digitalizados para calcular el volumen de agua. El radar, aunque más caro tiene las ventajas de obtener imágenes de las profundidades del agua a través de burbujas de gas y malezas y evaluar el espesor y la geometría de los sedimentos. El sonar tiene la ventaja de un despliegue rentable y fácil de los drones.

El agua se está convirtiendo en un recurso natural muy escaso y un factor limitante para la producción de cultivos. Al mismo tiempo, la demanda por producir granos

alimenticios está en continuo aumento debido a la creciente población humana. Ante este desafío, debemos centrarnos en el desarrollo y/o refinamiento de prácticas agrícolas para eficientar el uso del agua de riego.

Asegurar la aplicación de la cantidad óptima de agua a la planta en el momento y de la manera correcta, debe abordar el factor de heterogeneidad de la tierra en términos de estrés hídrico mediante tasas variables de irrigación. Brahmanand y Singh (2022) comentan que, con el advenimiento de los desarrollos modernos en informática, aprendizaje automático, posición geográfica (GPS), sistema de información geográfica (GIS), monitoreo basado en drones y automatización, el riego de precisión se ha fortalecido más ahora.

Cancela et al. (2019) proporcionaron una visión general de los avances recientes en la metodología del uso de técnicas de teledetección para el manejo del agua en los sistemas agrícolas. Este trabajo se centra en tres temas: 1) equipos nuevos para caracterizar cuerpos de agua, 2) desarrollo de tecnologías satelitales para determinar la demanda de agua de los cultivos para mejorar la eficiencia del riego y 3) monitoreo del estado hídrico de los cultivos a través de la detección próxima y remota. En general, estas contribuciones exploran nuevas soluciones para mejorar el manejo del riego y una evaluación eficiente de las necesidades de agua de los cultivos, siendo de gran valor tanto para investigadores como para asesores.

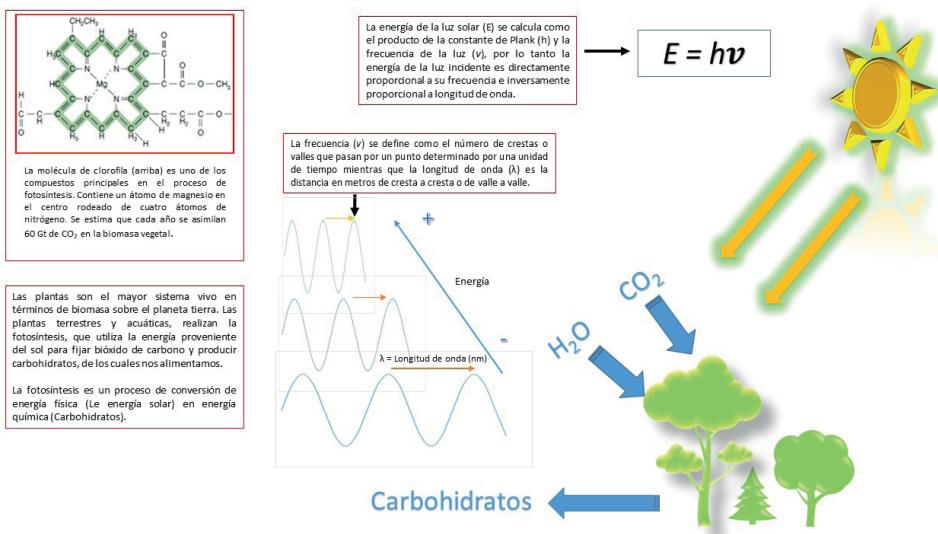
Las necesidades de riego por los cultivos y la determinación de los factores de estrés de las plantas es un desafío, ya que puede ser un resultado combinado del déficit de agua, la deficiencia de nutrientes y la infección por enfermedades. Los síntomas que surgen de estos factores de estrés también pueden ser similares. Por lo tanto, la sola observación visual podría resultar en un diagnóstico erróneo que eventualmente interrumpiría la acción correctiva para la planta o el cultivo afectado.

Por su parte, Mee et al. (2016) señalan que las mediciones de reflectancia espectral pueden ayudar a identificar y seleccionar longitudes de onda sensibles a diferentes tipos de estrés en las plantas. Estudios previos señalan que el estrés fisiológico cambiará el patrón de reflectancia espectral en el rango visible (380-720 nm o F380-F720) y en el rango infrarrojo entre 720-1500 nm o F720-F1500. Concluye que esta información puede reducir el costo operativo de la fertilización y minimizar la pérdida negativa de productividad.

# USO DE IMÁGENES DIGITALES EN EL CÁLCULO DE ÍNDICES VEGETALES

## LAS PLANTAS Y LA LUZ

Las plantas son seres vivos que interactúan con la luz proveniente del sol y la utilizan para fabricar compuestos orgánicos a partir de los cuales pueden completar su ciclo de vida (Figura 14). Dichos compuestos son útiles para los seres humanos debido a que son la fuente de nutrientes, medicamentos, antimicrobianos, colorantes y muchas otras moléculas que utilizamos en la vida cotidiana.



**Figura 14.** El sol proporciona una fuente de energía que las plantas utilizan gracias a la fotosíntesis. En este proceso la energía luminosa se convierte en energía química que sustenta la vida en el planeta tierra. (Elaboración: Francisco Lara-Viveros).

El proceso bioquímico a partir del cual se sintetizan compuestos orgánicos en las plantas se llama fotosíntesis, y el rendimiento de los cultivos está fuertemente relacionado con la tasa fotosintética. Por lo tanto, la cantidad de alimentos que podemos producir para la población en incremento depende en gran medida de este proceso.

La energía luminosa asimilada por las moléculas de clorofila presentes en los cloroplastos de las plantas se utiliza para fijar el carbono que se encuentra en el medio ambiente, al tejido vegetal. Uno de los compuestos más utilizados por las plantas como fuente de carbono es el bióxido de carbono (CO<sub>2</sub>).

Para tener una idea, durante los procesos fotosintéticos se absorben anualmente

cerca de 123 gigatoneladas de CO<sub>2</sub>, de los cuales cerca de la mitad (60 gigatoneladas) es fijado por las hojas (Reyes Santamaría et al, 2023). Lo anterior indica la importancia de la interacción luz-planta en los sistemas vivos del planeta, este fenómeno se ha utilizado desde hace mucho tiempo como un indicador de la salud vegetal, basado en los principios que a continuación se describen brevemente.

La clorofila, tiene la característica de reflejar la luz que tiene una longitud de onda de entre 450 y 550 nm, que nuestros ojos captan como luz de color verde (esta es la razón por la cual vemos a las hojas de este color); además existen otras longitudes de onda que son absorbidas por el tejido vegetal rico en clorofila, típicamente luz entre 400 y 450 nm, que nosotros percibimos como luz azul y entre 550 y 700 nm que nosotros percibimos como luz roja (Katul, 2023). Los rangos de luz azul y roja, son los que se utilizan como fuente de energía en los procesos fotosintéticos.

Adicionalmente las plantas interactúan con la luz infrarroja con una longitud de onda mayor a 700 nm y que, aunque nuestros ojos no son capaces de ver, condicionan las respuestas fisiológicas importantes. Por ejemplo (Badgley et al, 2017) encontraron que la fotosíntesis es proporcional a la cantidad de radiación en el infrarrojo cercano (de 750 a 2500 nm) que las hojas reflejan.

Por otro lado, la reflexión de luz en el espectro comprendido entre el rojo y el infrarrojo cercano (680-760 nm) típicamente llamado borde rojo, muestra la sensibilidad a los cambios en el contenido de clorofila en las hojas (Huang et al, 2022). Estos cambios en la práctica suelen ocurrir como consecuencia de una deficiencia nutrimental en los cultivos (comúnmente N, Mg o Fe) o como un indicador del ataque de algunas plagas que succionan la savia de las hojas disminuyendo la concentración de clorofila.

En realidad, la interacción de las plantas con la luz es un fenómeno que se estudia desde hace mucho tiempo; existen trabajos realizados desde el siglo XVIII que describen los fenómenos de interrelación entre la energía luminosa y las plantas. En años recientes la incorporación de cámaras de alta resolución, con sensores capaces de captar la luz que reflejan las plantas en longitudes de onda fuera del alcance del ojo humano hace posible obtener imágenes de mucha utilidad para la toma de decisiones en la agricultura.

Por otro lado, el incorporar dichas cámaras a drones que cuentan con avanzados algoritmos de control autónomo, permiten fotografiar grandes extensiones de tierra en muy poco tiempo, lo que generó la posibilidad de desarrollar tecnología con el objetivo de estimar parámetros fisiológicos en las plantas a partir de las imágenes digitales, considerando los fenómenos de interacción luz-planta anteriormente descritos.

Una de estas tecnologías son los índices vegetales (IV), que son números provenientes de cálculos simples que se correlacionan con parámetros fisiológicos, generalmente obtenidos a nivel de ampo o parcela, y que son útiles para tomar decisiones relacionadas con el manejo de los cultivos. Los IV se dividen en dos grandes grupos: 1) los calculados a partir de imágenes en el espectro visible y 2) aquellos que se computan a

partir de imágenes combinando el espectro visible e infrarrojo.

Para medir la cantidad de luz reflejada por las plantas, las cámaras a bordo de los drones, suelen usar sensores que transforman la cantidad de luz incidente en una corriente eléctrica que, a su vez, es de nuevo transformada a un número. Típicamente la escala va de 0 a 1 para algunos programas o bien de 1 a 256 para otros, en ambos casos entre menor sea el número, indica una menor cantidad de luz recibida por los sensores (Andrzej Ole et al, 2023). Por lo tanto, a cada uno de los píxeles que en la imagen representa una fracción del tejido vegetal, corresponde un número que indica la cantidad de luz reflejada y capturada por los sensores que se encuentran en las cámaras a bordo de los drones.

Debido a lo anterior en cada imagen se encuentra una gran cantidad de información acerca del complejo planta-luz, que es posible analizar matemáticamente con el fin de obtener información de interés agronómico. Una de las metodologías para poder convertir las imágenes en valores numéricos de utilidad agrícola, es el cálculo de los IV. A continuación, enlistaremos algunos de los más comunes, así como su aplicación en los sistemas agrícolas.

# ÍNDICES CALCULADOS A PARTIR DE IMÁGENES DE DRONES

El espectro visible se compone de la luz con una longitud de onda que va desde los 400 hasta los 700 nm, y se llama así debido a que es la parte del espectro que nuestros ojos pueden ver.

Las cámaras a bordo de drones que captan ese espectro de luz tienen sensores que son capaces de medir la intensidad de luz roja (550 a 700 nm), verde (500 a 550 nm) y azul (400 a 500 nm), por separado y la combinación de estos valores en el procesador de la cámara puede generar cualquier color del espectro visible.

A las imágenes provenientes de estas cámaras se les llama RGB por las siglas en inglés de los colores primarios que los sensores miden (red, green, blue). Las cámaras fotográficas RGB son las más comunes en el mercado y son de fácil acceso a cualquier persona y aunque no ofrecen la misma información que las cámaras multiespectrales, hay estudios que manifiestan muchas aplicaciones en la agricultura.

Estas imágenes son de bajo costo en relación con las multiespectrales ya están disponibles en muchos dispositivos de drones. A partir de estas imágenes se han desarrollado múltiples índices vegetales para estimar algunas variables relacionadas con la fisiología de las plantas. Una de estas imágenes que se calculan con mayor frecuencia es el índice de resistencia atmosféricamente visible (VARI, por sus siglas en inglés).

Para el cálculo de este índice (al igual que muchos otros) es necesario obtener los valores de la intensidad de luz en cada uno de los canales que componen la imagen y aplicar fórmulas sencillas que entregan un valor numérico (índice) que está relacionado con el estado fisiológico de la vegetación (Hassler et al, 2019). En el caso del índice VARI la fórmula que se utiliza es:

$$VARI = \frac{Green - Red}{Green + Red - Blue}$$

En donde:

Green = Intensidad de luz en el canal verde

Red = Intensidad de luz en el canal Rojo

Blue = Intensidad de luz en el canal azul

Originalmente este índice fue propuesto en el 2002 como una nueva metodología para detectar la fracción correspondiente al follaje en una imagen, especialmente en la etapa fenológica de los cultivos en las cuales la luz correspondiente al espectro del infrarrojo cercano tiende a disminuir, lo cual dificulta la detección del follaje utilizando ese tipo de cámaras (Gitelson et al, 2002). Actualmente el índice VARI tiene muchos usos en

la agricultura.

Las técnicas modernas de preprocesamiento y segmentación de imágenes permiten que este indicador se utilice no solo para detectar la fracción vegetal, sino también para detectar cambios en las etapas fenológicas de los cultivos. En este sentido (Ballesteros et al, 2021) encontraron valores del índice VARI diferentes en función de la etapa fenológica de maíz, que fue desde -0.15 en la etapa de desarrollo vegetativo, hasta 0.05 durante el desarrollo del fruto.

Otros autores (Erunova et al, 2021), utilizaron exitosamente el índice VARI como un indicador de la cantidad de malezas presentes en un cultivo de trigo en diferentes etapas fenológicas, además, se encontró una dependencia en el grado de infestación por malezas y el valor puntual del índice VARI, con valores de 0.12 a 0.15 en cultivos altamente infestados, hasta 0.27 con infestaciones bajas.

En este caso el valor del índice VARI fue sensible a la floración de las malezas y cultivos, que mostraron una disminución en el valor del índice debido a la reducción en la concentración de clorofila que se da en las plantas como consecuencia de la desviación de la energía hacia los órganos florales.

En realidad, existen índices que se desarrollaron con el paso del tiempo (Cuadro 2), y todos ellos representan números calculados a partir de fórmulas simples pero que aportan muy valiosa información para apoyar la toma de decisiones por el técnico o el agricultor respecto del cultivo.

Cuadro 2. Índices vegetales comúnmente utilizados en la agricultura.

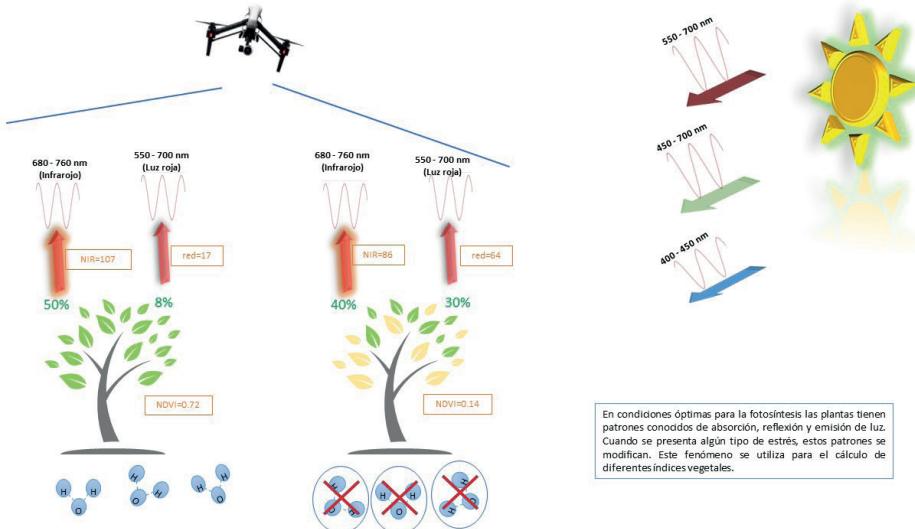
Índice	Formula	Uso	Autores
índice de resistencia atmosféricamente visible (VARI)	$VARI = \frac{Green - Red}{Green + Red - Blue}$	<ul style="list-style-type: none"> <li>Detección de la fracción del follaje</li> </ul>	(Gitelson et al, 2002)
índice de vegetación verde-rojo (GRVI)	$GRVI = \frac{Green - Red}{Green + Red - Blue}$	<ul style="list-style-type: none"> <li>Conteo de arboles</li> <li>Estimación del área foliar</li> <li>Detección de cambios fenológicos y como herramienta para determinar la homogeneidad del riego</li> </ul>	(Khadanga et al, 2020) (Ilniyaz et al, 2023) (Chen et al, 2019)
Red-green-blue vegetation index (RGBVI)	$RGBVI = \frac{Green^2 - Red * Blue}{Red^2 + Red * Blue}$	<ul style="list-style-type: none"> <li>Detección de algas en cuerpos de agua</li> </ul>	(Jiang et al, 2020)
Ratio Vegetation Index (RVI)	$RVI = \frac{NIR}{Red}$	<ul style="list-style-type: none"> <li>Estimación de área foliar</li> <li>Estimación de clorofila en plantas</li> </ul>	(Qiao et al, 2022 a) (Qiao et al, 2022 b)
NDVI	$NDVI = \frac{NIR - Red}{NIR + Red}$	<ul style="list-style-type: none"> <li>Estimación del área foliar</li> <li>Manejo del agua</li> <li>Como indicador de la etapa fenológica en uva.</li> </ul>	(Garcia-Garcia et al, 2021) (Ferro et al, 2023)
OSAVI	$OSAVI = \frac{1.16 NIR - Red}{NIR + Red + 0.16}$	<ul style="list-style-type: none"> <li>Estimación de la humedad en el suelo en conjunto con métodos de aprendizaje automático.</li> </ul>	(Zhang et al, 2023)

Sin embargo, la verdadera utilidad de estos índices es cuando se establece la relación entre ellos y las variables medidas a nivel de parcela, con el objetivo de generar modelos matemáticos que permitan la toma de decisiones agronómicas a partir de la estimación de variables de interés relacionadas con la fisiología de las plantas.

Además de los IV basados en imágenes RGB, hay otros que se calculan a partir de imágenes en el espectro infrarrojo solos o en combinación con imágenes RGB. Este tipo de índices vegetales (Figura 15), requieren de menor preprocesamiento de imagen; sin embargo, los drones equipados con este tipo de cámaras son de un costo significativamente mayor en comparación con un dron equipado únicamente con cámaras RGB.

La iluminación es un factor importante para la vida vegetal porque la luz es la base de la fotosíntesis y la productividad, el regulador de los procesos fisiológicos y una posible causa de daño. La interacción de la luz con los sistemas fotosintéticos de la planta se utiliza para el cálculo de índices vegetales que son muy útiles para detectar estreses o problemas fitosanitarios en cultivos agrícolas.

La fotosíntesis es una expresión directa del estado de crecimiento del cultivo y un indicador importante que predice el rendimiento y la calidad. Por lo tanto, el monitoreo rápido y preciso de la dinámica de la fotosíntesis es clave para el manejo agronómico de los cultivos.



**Figura 15.** La interacción de la luz con los sistemas fotosintéticos de la planta se utiliza para el cálculo de índices vegetales. En el esquema se presentan los principios que hacen posible el cálculo del Índice de Vegetación de Diferencia Normalizada (NDVI) que es uno de los que se utilizan con mayor frecuencia. Las plantas en condiciones de crecimiento óptimas absorben la luz roja, mientras reflejan la luz infrarroja en una proporción mayor que las plantas sometidas a cualquier proceso de estrés. Este fenómeno se utiliza como principio para calcular los índices NDVI. (Elaboración: Francisco Lara-Viveros).

Los IV basados en imágenes RGB e infrarrojas combinadas ofrecen una mayor cantidad de información acerca de los procesos de interacción planta-luz y son de utilidad para su uso en la estimación de parámetros fisiológicos en las plantas en conjunto con sistemas de inteligencia artificial. Uno de los más utilizado para estimar condiciones fisiológicas en los cultivos es el Índice de Vegetación de Diferencia Normalizada (NDVI), por sus siglas en inglés y que se calcula mediante la siguiente fórmula:

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

Donde:

NDVI = Índice de Vegetación de Diferencia Normalizada

NIR = Luz reflejada en la región del infrarrojo cercano

Red = Luz reflejada en el espectro del rojo visible.

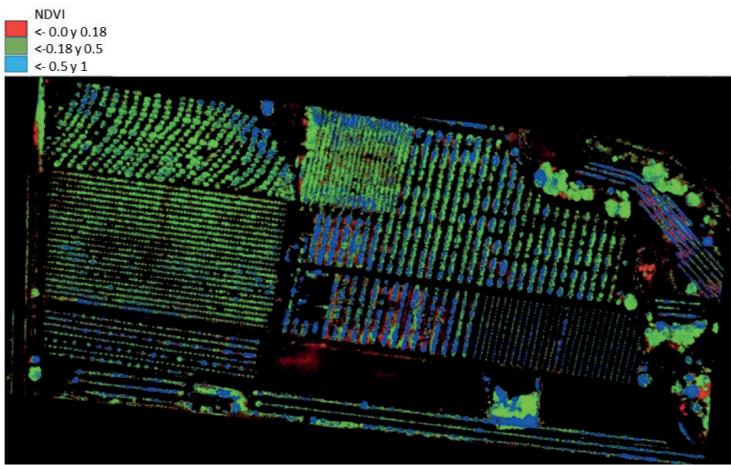
Este índice es una combinación de imágenes RGB y multiespectrales, por que utiliza la información de la banda del rojo visible e infrarrojo cercano. El NDVI es uno de los índices vegetales más utilizados debido a la facilidad de su cálculo y a que los sistemas de imágenes satelitales incluyen la banda infrarroja lo que facilita su uso e implementación para estimar variables fisiológicas en los cultivos.

El índice NDVI ha sido ampliamente utilizado para detectar los cambios en la vegetación y el uso eficiente del nitrógeno, un nutriente importante que determina en una gran medida el rendimiento de los cultivos (Jiang et al, 2021). Otros estudios muestran su utilidad como herramienta para mapear la presencia de plantas enfermas (Vélez et al, 2023).

Por la forma en que se calcula puede tomar un valor desde -1 a 1. En condiciones normales las plantas asimilan luz roja y azul, en contraste reflejan la luz verde y hay picos de reflexión en el espectro infrarrojo. Considerando lo anterior el valor teórico para una planta en condiciones óptimas debe ser de 1.0. Entre más nos alejemos de este valor, indicaría un proceso de estrés que deriva en una alteración en los procesos de asimilación y reflexión de luz por las plantas.

Aunque la mejor forma de interpretar y validar cualquier índice de salud vegetal, es su relación con variables medidas en campo, hay ciertas características que permiten elegir el más adecuado de acuerdo a necesidades específicas, por ejemplo, el RVI, es usado para la estimación de biomasa en zonas con amplia cobertura vegetal, así como en la estimación de concentración de clorofila en cultivos en altas densidades, sin embargo cuando la vegetación es escasa ofrece una señal pobre de la vegetación presente (Xue et al, 2017).

Estos índices NDVI (Figura 16) ofrecen además la ventaja de que pueden ser calculados por sistemas de imágenes satelitales, lo que hace posible su uso a escalas de terreno mucho mayores en comparación con los drones. En general, como fue señalado, los valores de NDVI varían de -1.0 a 1.0, con valores negativos que indican nubes y agua, valores positivos cercanos a cero que indican suelo desnudo y valores positivos más altos de NDVI que van desde vegetación escasa (0.1 - 0.5) hasta vegetación verde densa (0.6 y arriba).



**Figura 16.** Calculo de NDVI en un cultivo de manzana en la región de Arteaga, Coahuila, México. La imagen fue procesada para generar una máscara, en la cual se asigna un color a cada intervalo de NDVI. Lo anterior permite detectar espacialmente los sitios en donde se presentan plantas sometidas a algún estrés (colores rojos), plantas en condiciones normales (verdes) o bien plantas con mejores condiciones que el promedio (azules). La imagen fue tomada por medio de un dron DJI P4, con una cámara multiespectral y procesada por medio del software R (Fotografía y procesamiento: Francisco Lara-Viveros).

# CONSIDERACIONES ACERCA DEL USO DE ÍNDICES VEGETALES

En realidad, existen un gran número de índices vegetales a partir de la correlación de datos obtenidos en tierra e información proveniente de las imágenes; sin embargo, para que estos tengan una verdadera utilidad para los sistemas agrícolas deben de ser una herramienta de fácil acceso para la toma de decisiones.

Con la disminución en los costos de los vehículos aéreos no tripulados aunado al montaje de cámaras cada vez más avanzadas y mejores programas para el control, planificación y seguimiento de los vuelos, es cada vez más accesible a los usuarios finales disponer de esta moderna tecnología.

Adicionalmente, es muy común que los programas utilizados para el procesamiento de las imágenes provenientes de drones construyan de forma automática los ortomapas y estimen pixel a pixel algunos de los IV más utilizados; sin embargo, el solo cálculo de los índices vegetales no son por si mismos una herramienta útil si estos no pueden ser comparados y contrastados contra condiciones reales del campo, lo que hace necesario el considerar algunos criterios agronómicos con la finalidad de seleccionar e interpretar adecuadamente cualquiera de los IV.

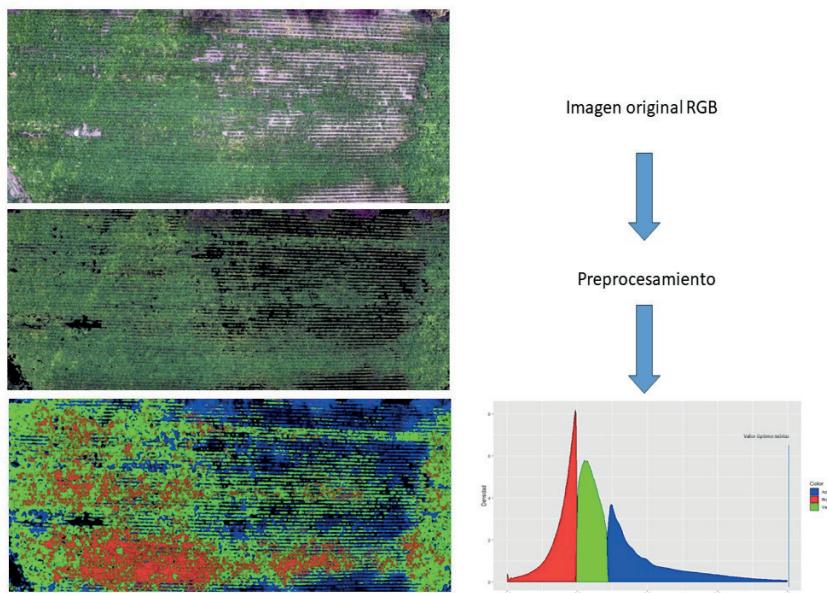
Uno de los aspectos más importante a considerar es que los valores de los índices de salud vegetal son dinámicos y sufren cambios en función de factores relacionados con las condiciones de vuelo (altura, resolución de la cámara, hora del día) y con la condición del cultivo (etapa fenológica, cobertura vegetal, nivel de estrés), por lo tanto, la interpretación adecuada de un índice vegetal implica contextualizar el valor obtenido con algunas de las variables antes descritas.

Además, hay que considerar que el valor obtenido de los índices vegetales, es puntual por lo que refleja las condiciones del momento exacto en el que se tomó la imagen. Debido a lo anterior, en la práctica es muy útil poner los índices vegetales en series de tiempo, lo cual requiere de varios vuelos (Figura 17). En la agricultura, el más común es el índice vegetativo relativo normalizado NDVI (Normalized Difference Vegetation Index), que caracteriza la densidad de la vegetación, permitiendo a los técnicos y agricultores evaluar la germinación, el crecimiento, la presencia de malezas o enfermedades, así como predecir el rendimiento.

Otro factor importante a considerar es que el valor del índice también puede verse afectado por características propias de la parcela, por ejemplo, la presencia o ausencia de malezas, tuberías, basura o acolchados plásticos, lo que hace necesario que la imagen utilizada para el cálculo de cualquier índice sea preprocesada para eliminar este tipo de sesgos que puede llevar a una inadecuada interpretación y contextualización de los valores numéricos.

Un índice es solamente un número que proviene de la aplicación de una determinada fórmula matemática y su interpretación sin considerar aspectos agronómicos, puede derivar en que se pierda su utilidad como herramienta para la toma de decisiones. La correcta interpretación de cualquier índice vegetal obtenido con drones debe hacerse con un preprocesamiento de las imágenes a estudiar y su adecuado contexto agronómico.

Los indicadores de índices vegetales se forman a través de imágenes satelitales de masa verde, que absorbe ondas electromagnéticas en el rango rojo visible y las refleja en el infrarrojo cercano. Cuanto más grande es la superficie de las hojas y más clorofila hay en las hojas, las plantas absorben más la luz roja que les llega de la radiación solar y la reflejan menos. Como resultado, es posible obtener un análisis espectral completo e identificar áreas que necesitan resiembra, aplicación de fitosanitarios o fertilizantes.



**Figura 17.** Imagen de un cultivo de frijol en el Estado de Hidalgo, México, tomada mediante un dron DJI Inspire I, equipado con una cámara RGB de 12 megapixeles. La imagen fue procesada para descartar los píxeles correspondientes al suelo y posteriormente se calculó el índice VARI. En la imagen se muestra la distribución espacial de los diferentes valores del índice por medio de la creación de máscaras de color. En el grafico se observa la distribución del número de píxeles correspondientes a cada categoría (Fotografía y procesamiento: Francisco Marcelo Lara-Viveros).

# USO DE IMÁGENES DIGITALES Y SU ANÁLISIS MEDIANTE SISTEMAS DE INTELIGENCIA ARTIFICIAL

Como hemos detallado en el texto anterior, los índices vegetales se utilizan ampliamente en los sistemas agrícolas y son una herramienta muy importante para estimar distintas variables de mucha utilidad en la toma de decisiones, sin embargo, cuando se calcula un índice la información en la imagen se reduce de forma considerable.

Para ejemplificar lo anterior tomemos una imagen multiespectral obtenida por medio de una cámara de 10 megapíxeles. Dicha imagen contendrá entonces cinco canales con dos megapíxeles cada uno. Matemáticamente dicha imagen se representa como una matriz numérica de varias dimensiones, cada una de las cuales representa un canal. Dicha matriz contendrá entonces 10 millones de datos.

Si usáramos esa imagen para calcular el índice normalizado de vegetación (NDVI) solo utilizaríamos dos canales (NIR y R), por lo tanto, solo usamos cuatro millones de datos de los diez disponibles originalmente en la imagen y una vez calculado el índice se obtiene un solo valor para cada pixel generando una matriz de dos millones de datos.

El cálculo de cualquier índice de vegetación representa una técnica de reducción de datos muy útil en el caso de tener poca capacidad de procesamiento de cómputo y además facilita la interpretación de la imagen al no tener que lidiar con los cinco canales disponibles en la imagen original.

Los avances actuales en capacidad de procesamiento de datos por las computadoras y el desarrollo de sistemas que permiten el análisis de grandes volúmenes de información, hacen posible usar toda la información disponible en cada uno de los canales de las imágenes que provee la cámara a bordo del dron.

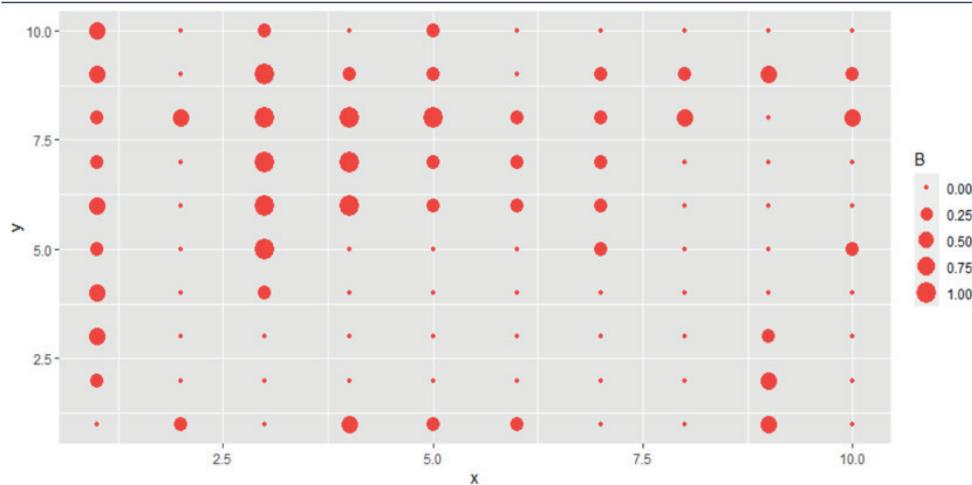
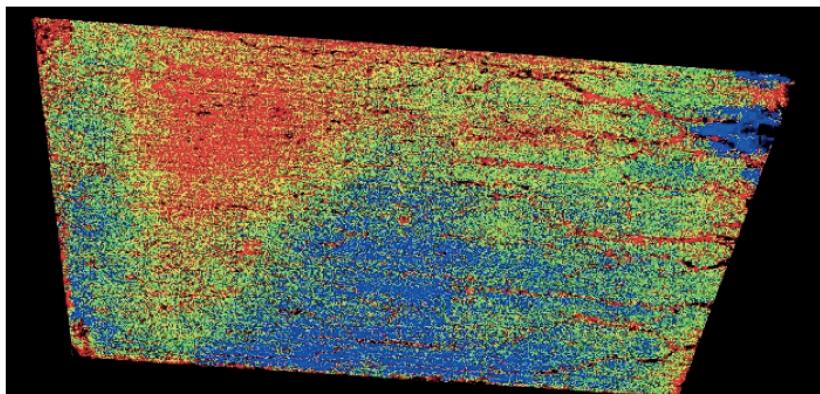
Aunado a esto, en los últimos años se están logrando grandes avances en el desarrollo de algoritmos de aprendizaje automático capaces de encontrar relaciones entre variables que de otra manera serían muy difíciles de deducir, al conjunto de estos algoritmos se les suele clasificar como inteligencia artificial.

Los sistemas de inteligencia artificial han logrado reemplazar a los humanos en muchas tareas que implican el análisis y reconocimiento de imágenes (Kakani et al, 2020). Los sistemas de inteligencia artificial utilizan algoritmos de aprendizaje automático, que, en realidad, es un enfoque multidisciplinario para el análisis de datos que se inspira y toma prestado en gran medida, la teoría de la probabilidad, la estadística, la teoría de la decisión, la visualización y la optimización (Singh et al., 2016).

Los sistemas de aprendizaje automático se dividen en varios grupos entre los que destacan los sistemas de aprendizaje supervisado y no supervisado. Cuando hablamos de imágenes en las cuales se va a usar un sistema de aprendizaje supervisado, es necesario etiquetar en dicha imagen la región u objeto de interés como los síntomas de plagas por

pulgones (Figura 18), enfermedades o deficiencias y plantas sometidas a algún tipo de estrés.

Estas imágenes y sus respectivas etiquetas, son utilizadas como datos de entrada y el algoritmo deberá encontrar los valores comunes que tienen los objetos etiquetados, que permita hacer una clasificación relativamente precisa de la región de interés (Tu et al, 2019). Este tipo de algoritmos funcionan a partir de una gran cantidad de datos, que son necesarios para encontrar los patrones que separen una clasificación de otra, por ejemplo, una planta enferma y otra de una planta sana.



**Figura 18.** Cultivo de alfalfa atacada por pulgones. La imagen muestra en color rojo las zonas en donde las plantas mostraron una disminución en la concentración de clorofila en las hojas derivado de este ataque. Por medio de técnicas de inteligencia artificial y utilizando técnicas de muestreo en campo

para estimar la población de insectos. Se desarrolló un sistema de inteligencia artificial basada en máquinas de soporte vectorial y redes neuronales que estima la población de pulgones en las distintas áreas de la parcela (grafico inferior) en la que el tamaño de los círculos corresponde con la población relativa de insectos que el modelo de inteligencia artificial estima usando como dato de entrada una imagen RGB preprocesada (Fotografía y procesamiento: Francisco Marcelo Lara-Viveros).

Para verificar que el sistema esté identificando correctamente las zonas u objetos de interés en la imagen, el conjunto de datos de entrada se divide en dos partes, un conjunto de entrenamiento y otro de validación. El conjunto de datos de entrenamiento se utiliza para que el algoritmo encuentre la relación entre los datos y las etiquetas. Una vez construido el modelo, se usa con los datos de validación en los se tienen dos etiquetas, las que fueron asignados por el investigador y las que el sistema asignó (datos predichos y observados).

La diferencia en la asignación de etiquetas entre la computadora y el usuario se utilizan para construir métricas con las cuales el sistema perfecciona su capacidad de predecir correctamente una zona de interés en la imagen. Por otro lado, los sistemas no supervisados son capaces de separar conjuntos de datos en grupos grandes a partir de características específicas, sin necesidad de que exista alguna información previa por parte del investigador. Los sistemas de aprendizaje automático se pueden usar para estimar clases, o bien valores puntuales.

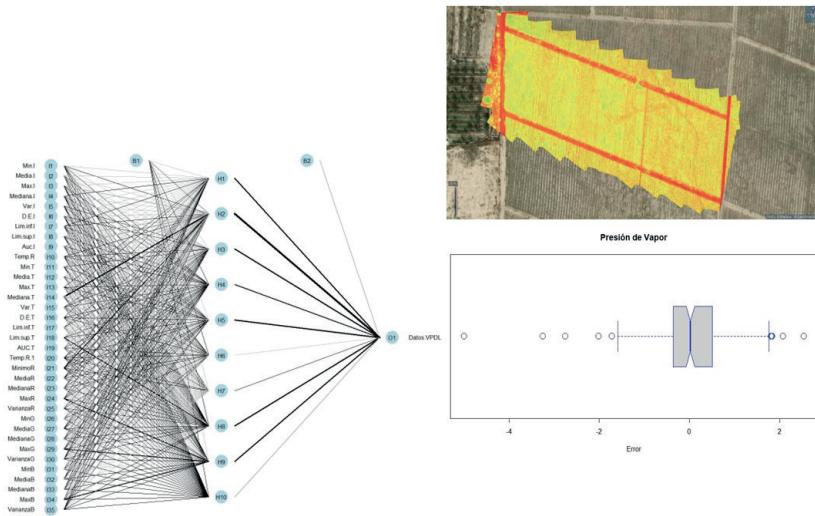
Las técnicas de análisis de imágenes asistidas por medio de algoritmos de inteligencia artificial, sean sistemas supervisados o no, tienen un enorme potencial en los sistemas agrícolas. Por ejemplo (Saad El Imani et al, 2023) utilizaron imágenes provenientes de drones en combinación con máquinas de soporte vectorial y redes neuronales, las cuales son dos técnicas de aprendizaje automático utilizadas frecuentemente para detectar malezas en plantaciones de cítricos con una precisión superior al 96%.

Respecto a la detección remota del estatus nutricional de las plantas (Yu et al., 2022), encontraron un modelo que utilizando imágenes hiperespectrales y métodos de aprendizaje automático, estimaba el nivel de nitrógeno en el cultivo de arroz con una precisión superior al 80%.

Para el control de plagas (Bhusal et al, 2022), desarrollaron un sistema de visión artificial que se montó a bordo de un dron con la finalidad de detectar aves con la cámara a bordo y volar en su dirección para evitar que estos animales ocasionaran daños en los cultivos, los drones se desplegaron de forma automática cuando detectaron movimientos parecidos a los que típicamente realizan las aves.

La detección de enfermedades también está siendo abordada por el análisis de imágenes asistida mediante sistemas de IA. Por ejemplo, Marin et al. (2021), utilizaron índices de vegetación que fueron procesados mediante técnicas de aprendizaje automático, con la finalidad de detectar los síntomas de la roya del café, una de las enfermedades más devastadoras en ese cultivo. Los resultados mostraron que el sistema logró detectar los síntomas cuando la enfermedad apenas iniciaba en las plantas (2 a 5% de infestación), lo cual permite tomar decisiones agronómicas oportunas de control.

En la actualidad los análisis de imagen asistida mediante técnicas de inteligencia artificial en los cultivos agrícolas (Figura 19), apoyan y fortalecen la agricultura de precisión al obtener la mayor cantidad de información sobre las áreas cultivadas, lo cual puede optimizar los procesos de siembra, control de malez y la cosecha.



**Figura 19.** Análisis de imagen asistida mediante técnicas de inteligencia artificial en el cultivo de uva. El modelo estima el déficit de presión de vapor en el cultivo por medio de una red neuronal que usa como datos de entrada una imagen multiespectral a 50 metros de altura. La gráfica muestra las diferentes capas de la red y el diagrama de caja muestra el error en la salida del sistema. Con esta técnica se generan herramientas que mejoran el uso del agua al conectar la información generada por el análisis de la imagen, con el control del sistema de riego (Fotografía y procesamiento: Francisco Marcelo Lara-Viveros).

Los ejemplos citados son apenas una muestra pequeña del potencial de esta tecnología en la agricultura. Las soluciones que la combinación de los sistemas actuales de análisis y procesamiento de imágenes ofrecen, llegan en un momento en el cual los sistemas agrícolas enfrentan retos sin precedentes en la historia de la humanidad, derivados del incremento de la población mundial, el uso inadecuado de los recursos naturales (agua, suelo) y los fenómenos relacionados con el cambio climático.

Ante esta situación es necesario que los profesionales de la agronomía utilicen de forma habitual estas herramientas y que al mismo tiempo se implementen políticas públicas que favorezcan la incorporación de estos conocimientos en todos los ámbitos del sector, desde la inclusión de programas de capacitación en instituciones de educación superior, hasta la estructuración, organización y protección de los datos derivados de este tipo de sistemas. La incorporación de estas tecnologías a los sistemas agrícolas mexicanos, es un reto que debemos de asumir en el corto plazo todos los profesionales de la agronomía.

## CONCLUSIONES

Debemos señalar que el uso de los drones en la agricultura de precisión y la agricultura inteligente tienen grandes beneficios con el Internet de las cosas (IOT), ya que los investigadores, productores y técnicos, permiten obtener y procesar datos para cualquier cultivo y su entorno.

Los dispositivos IOT como los drones son útiles para numerosas aplicaciones de manejo agronómico de los cultivos, ya que pueden grabar imágenes de alta calidad con una resolución fina y durante un cierto período de tiempo deseado. Se predice que la agricultura se transformará como resultado de estas tecnologías en evolución, lo que permitirá tomar decisiones en días en lugar de semanas, así como reducciones considerables de costos, mano de obra y con incrementos en el rendimiento.

Cuando se toman tales decisiones, se hacen posible la aplicación exitosa de insumos agrícolas en apoyo de la agricultura de precisión mediante el uso de técnicas adecuadas en los momentos y lugares apropiados, y aplicarlos en las cantidades correctas. El uso de drones en la agricultura inteligente aún no se ha generalizado como se esperaba, debido en parte a las dificultades asociadas a la elección e implementación de metodologías apropiadas, que incluyen enfoques de recopilación de datos y procesamiento de imágenes.

Se considera que el problema principal de la falta de adopción es que, debido a que este tema es relativamente nuevo, actualmente no existe un protocolo estandarizado para el empleo de drones agrícolas en tales aplicaciones. Sin embargo, desde el punto de vista de los investigadores, los drones abren un gran abanico de posibilidades para mejorar la producción agrícola sustentable y ecológica en todo el mundo.

## REFERENCIAS

- Abdulridha, J., Min, A., Rouse, M.N., Kianian, S., Isler, V. y Yang, C. (2023). Evaluation of stem rust disease in wheat fields by drone hyperspectral imaging. *Sensors*, 23(8), 4154.
- Acharya, B.S., Bhandari, M., Bandini, F., Pizarro, A., Perks, M., Joshi, D.R. y Sharma, S. (2021). Unmanned aerial vehicles in hydrology and water management: Applications, challenges, and perspectives. *Water Resources Research*, 57(11), e2021WR029925.
- Abberli, A., Phinn, S., Johansen, K., Robson, A. y Lamb, D.W. (2023). Characterisation of banana plant growth using high-spatiotemporal-resolution multispectral UAV imagery. *Remote Sensing*, 15(3), 679.
- Ajakaiye, O.B. (2023). Drone agricultural technology: implications for sustainable food production in Africa. *African Journal of Agricultural Science and Food Research*, 9(1), 36–44.
- Ali, Z.A., Yang, C., Israr, A. y Zhu, Q. (2023). A Comprehensive review of scab disease detection on rosaceae family fruits via UAV Imagery. *Drones*, 7(2), 97.
- Alvino, A. y Marino, S. (2017) Remote sensing for irrigation of horticultural crops. *Horticulturae* 3(2):40.
- Anderson C. (2014). Agricultural drones. *MIT Technology Review*, vol. 117/3, 58-60.
- Andrzej, A., Pau, G., Smith, M., Sklyar, O., Huber, W. (2023). Contributions from Joseph Barry, w., & Marais Maintainer Andrzej Ole, P. (2023). Package ‘EBImage’ Title Image processing and analysis toolbox for R Encoding UTF-8. Obtenido de <https://bioconductor.org/packages/release/bioc/html/EBImage.html>
- Arza-García, M. y Burgess, A. J. (2022). Drones in the Sky: Towards a more sustainable agriculture. *Agriculture*, 13(1), 84.
- Aslan, M.F., Durdu, A., Sabancı, K., Ropelewska, E. y Gültekin, S.S. (2022). A comprehensive survey of the recent studies with UAV for precision agriculture in open fields and greenhouses. *Applied Sciences*, 12(3), 1047.
- Awais, M., Li, W., Cheema, M. J. M., Zaman, Q. U., Shaheen, A., Aslam, B. y Liu, C. (2022). UAV-based remote sensing in plant stress imagine using high-resolution thermal sensor for digital agriculture practices: a meta-review. *International Journal of Environmental Science and Technology*, 1-18.
- Azfar, S., Nadeem, A., Ahsan, K., Mehmood, A., Almoamari, H. y Alqahtany, S.S. (2023). IoT-Based cotton plant pest detection and smart-response system. *Applied Sciences*, 13(3), 1851.
- Badgley, G., Field, C. y Berry, J. (2017). Canopy near-infrared reflectance and terrestrial photosynthesis. *Sci. Adv.* 3. Obtenido de <http://advances.sciencemag.org/cgi/>
- Ballesteros, R., Moreno, M., Barroso, F., González-gómez, L. y Ortega, J. (2021). Assessment of maize growth and development with high- and medium-resolution remote sensing products. *Agronomy*, 11(5).
- Banu, T.P., Borlea, G.F. y Banu, C. (2016). The use of drones in forestry. *Journal of Environmental Science and Engineering B*, 5(11), 557-562.

Barela, A., Thakur, S., Pachori, S., Rahangdale, S., Goyal, V.K., Kakade, S. y Shrivastava, M.K. (2023). Applications of proximal remote sensing in agriculture: A review. *The Pharma Innovation Journal*, 12(2), 1124-30.

Bascon, M.V., Nakata, T., Shibata, S., Takata, I., Kobayashi, N., Kato, Y. y Nishiuchi, S. (2022). Estimating yield-related traits using UAV-derived multispectral images to improve rice grain yield prediction. *Agriculture*, 12(8), 1141.

Bazzo, C.O.G., Kamali, B., Hütt, C., Bareth, G. y Gaiser, T. (2023). A review of estimation methods for aboveground biomass in grasslands using UAV. *Remote Sensing*, 15(3), 639.

Bengtsson, J., Bullock, J.M., Egoh, B., Everson, C., Everson, T., O'Connor, T., O'Farrell, P.J., Smith, H.G. y Lindborg, R. (2019). Grasslands—more important for ecosystem services than you might think. *Ecosphere* 2019, 10, e02582.

Berger, K., Verrelst, J., Féret, J.B., Wang, Z., Woehler, M., Strathmann, M., Danner, M., Mauser, W. y Hank, T. (2020). Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions. *Remote Sens. Environ.*, 242, 111758.

Bhusal, S., Karkee, M., Bhattacharai, U., Majeed, Y. y Zhang, Q. (2022). Automated execution of a pest bird deterrence system using a programmable unmanned aerial vehicle (UAV). *Computers and Electronics in Agriculture*, 198.

Bikov, T., Mihaylov, G., Iliev, T. y Stoyanov, I. (2022, June). Drone surveillance in the modern agriculture. In 2022 8th International Conference on Energy Efficiency and Agricultural Engineering (EE&AE) (pp. 1-4). IEEE.

Bouguettaya, A., Zarzour, H., Kechida, A. y Taberkit, A.M. (2023). A survey on deep learning-based identification of plant and crop diseases from UAV-based aerial images. *Cluster Computing*, 26(2), 1297-1317.

Brahmanand, P.S. y Singh, A.K. (2022). Precision irrigation water management-current status, scope and challenges. *Indian Journal of Fertilisers*, 18(4), 372-380.

Budiharto, W., Chowanda, A., Gunawan, A.A.S., Irwansyah, E. y Suroso, J.S. (2019, December). A review and progress of research on autonomous drone in agriculture, delivering items and geographical information systems (GIS). In 2019 2nd world symposium on communication engineering (WSCE) (pp. 205-209). IEEE.

Burns, B.W., Green, V.S., Hashem, A.A., Massey, J.H., Shew, A.M., Adviento-Borbe, M.A.A. y Milad, M. (2022). Determining nitrogen deficiencies for maize using various remote sensing indices. *Precis. Agric.*, 23, 791–811.

Buthelezi, S., Mutanga, O., Sibanda, M., Odindi, J., Clulow, A.D., Chimonyo, V.G. y Mabhaudhi, T. (2023). Assessing the prospects of remote sensing maize leaf area index using UAV-derived multi-spectral data in smallholder farms across the growing season. *Remote Sensing*, 15(6), 1597.

Cancela, J.J., González, X.P., Vilanova, M. y Mirás-Avalos, J.M. (2019). Water management using drones and satellites in agriculture. *Water*, 11(5), 874.

Chancia, R., Bates, T., Heuvel, J.V. y van Aardt, J. (2021). Assessing grapevine nutrient status from unmanned aerial system (UAS) hyperspectral imagery. *Remote Sens.* 2021, 13, 4489.

Chen, A., Orlov-Levin, V. y Meron, M. (5 de 2019). Applying high-resolution visible-channel aerial imaging of crop canopy to precision irrigation management. *Agricultural Water Management*, 216, 196-205.

Chen, J., Chen, Z., Huang, R., You, H., Han, X., Yue, T. y Zhou, G. (2023). The effects of spatial resolution and resampling on the classification accuracy of wetland vegetation species and ground objects: A study based on high spatial resolution UAV images. *Drones*, 7(1), 61.

Chen, P., Ouyang, F., Zhang, Y. y Lan, Y. (2022). Preliminary evaluation of spraying quality of multi-unmanned aerial vehicle (UAV) close formation spraying. *Agriculture*, 12(8), 1149.

Chen, S., Hu, T., Luo, L., He, Q., Zhang, S. y Lu, J. (2022). Prediction of nitrogen, phosphorus, and potassium contents in apple tree leaves based on in-situ canopy hyperspectral reflectance using stacked ensemble extreme learning machine model. *J. Soil Sci. Plant Nutr.*, 22, 10–24.

Chin, R., Catal, C. y Kassahun, A. (2023). Plant disease detection using drones in precision agriculture. *Precision Agric* (2023). <https://doi.org/10.1007/s11119-023-10014-y>

Chiranjeeb, K., Shandilya, R. y Rath, K.C. (2023). Application of drones and sensors in advanced farming: The future smart farming technology. In *Artificial Intelligence and Smart Agriculture Applications* (pp. 1-30). Auerbach Publications.

Choubey, A. y Reddy, B.C. (2023). Drones in Agriculture: Multispectral Analysis. In *Computational Intelligence in Robotics and Automation* (pp. 217-241). CRC Press.

Daponte, P., De Vito, L., Glielmo, L., Iannelli, L., Liuzza, D., Picariello, F. y Silano, G. (2019, May). A review on the use of drones for precision agriculture. In *IOP conference series: earth and environmental science* (Vol. 275, No. 1, p. 012022).

Dileep, M.R., Navaneeth, A.V., Ullagaddi, S. y Danti, A. (2020, November). A study and analysis on various types of agricultural drones and its applications. In *2020 Fifth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)* (pp. 181-185). IEEE.

Er-Raki, S. y Chehbouni, A. (2023). Remote Sensing in Irrigated Crop Water Stress Assessment. *Remote Sensing*, 15(4), 911.

Erunova, M., Pisman, T. y Shevyrnogov, A. (2021). The technology for detecting weeds in agricultural crops based on vegetation index VARI (PlanetScope). *Journal of Siberian Federal University. Engineering & Technologies*, 3(14), 347-353.

Feng, H., Tao, H., Fan, Y., Liu, Y., Li, Z., Yang, G. y Zhao, C. (2022). Comparison of winter wheat yield estimation based on near-surface hyperspectral and UAV hyperspectral remote sensing data. *Remote Sensing*, 14(17), 4158.

Ferro, M., Catania, P., Miccich, D., Pisciotta, A., Vallone, M. y Orlando, S. (2023). Assessment of vineyard vigour and yield spatio-temporal variability based on UAV high resolution multispectral images. 231, 36-56. Obtenido de <https://doi.org/10.1016/j.biosystemseng.2023.06.001>

Fikri, M.R., Candra, T., Saptaji, K., Noviarini, A.N. y Wardani, D.A. (2023). A review of Implementation and Challenges of Unmanned Aerial Vehicles for Spraying Applications and Crop Monitoring in Indonesia. arXiv preprint arXiv:2301.00379.

Fu, Y., Yang, G., Pu, R., Li, Z., Li, H., Xu, X., Song, X., Yang, X. y Zhao, C. (2021). An overview of crop nitrogen status assessment using hyperspectral remote sensing: Current status and perspectives. *Eur. J. Agron.*, 124, 126241.

Furlanetto, R.H., Nanni, M.R., Cruciol, L.G.T., Silva, G.F.C., Junior, A.D.O. y Sibaldelli, R.N.R. (2021). Identification and quantification of potassium (K<sup>+</sup>) deficiency in maize plants using an unmanned aerial vehicle and visible/near-infrared semi-professional digital camera. *Int. J. Remote Sens.*, 42, 8783–8804.

Furukawa, T., Hasegawa, T. y Shirai, Y. (2020). Crop detection and discrimination using convolutional neural networks for autonomous farming. *Computers and Electronics in Agriculture*, 173, 105395. doi: 10.1016/j.compag.2020.105395.

Gago, J., Douthet, C., Coopman, R.E., Gallego, P.P., Ribas-Carbo, M., Flexas, J. y Medrano, H. (2015). UAVs challenge to assess water stress for sustainable agriculture. *Agricultural Water Management*, 153, 9-19.

García, L., Parra, L., Jimenez, J.M., Lloret, J., Mauri, P.V. y Lorenz, P. (2020). DronAway: A proposal on the use of remote sensing drones as mobile gateway for WSN in precision agriculture. *Applied Sciences*, 10(19), 6668.

Garcia-Garcia, D., Reynafarje la Rosa, X., Grados Bedoya, D. y Schrevens, E. (2021). Linear mixed model analysis of NDVI-based canopy coverage, extracted from sequential UAV multispectral imagery of an open field tomato irrigation experiment. *Computers and Electronics in Agriculture*, 189.

Ghazali, M.H.M., Azmin, A. y Rahiman, W. (2022). Drone Implementation in Precision Agriculture—A Survey. *Int. J. Emerg. Technol. Adv. Eng.*, 12, 67-77.

Gitelson, A., Kaufman, Y., Stark, R. y Rundquist, D. (2002). Novel Algorithms for Remote Estimation of Vegetation Fraction Novel Algorithms for Remote Estimation of Vegetation Fraction Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80, 76-87.

Go, S.H., Lee, D.H., Na, S.I. y Park, J.H. (2022). Analysis of growth characteristics of kimchi cabbage using drone-based cabbage surface model image. *Agriculture*, 12(2), 216.

Gokool, S., Mahomed, M., Kunz, R., Clulow, A., Sibanda, M., Naiken, V. y Mabhaudhi, T. (2023). Crop monitoring in smallholder farms using unmanned aerial vehicles to facilitate precision agriculture practices: a scoping review and bibliometric analysis. *Sustainability*, 15(4), 3557.

Goodrich, P., Betancourt, O., Arias, A.C. y Zohdi, T. (2023). Placement and drone flight path mapping of agricultural soil sensors using machine learning. *Computers and Electronics in Agriculture*, 205, 107591.

Gupta, R., Kataria, D. y Tripathi, B.S. (2023). Drone Harvester: Detect and collect ripe fruit and vegetables. In *Applying Drone Technologies and Robotics for Agricultural Sustainability* (pp. 108-123). IGI Global.

Hafeez, A., Husain, M.A., Singh, S.P., Chauhan, A., Khan, M.T., Kumar, N. y Soni, S.K. (2022). Implementation of drone technology for farm monitoring & pesticide spraying: A review. *Information processing in Agriculture*.

Haque, A. y Chowdhury, M.N. (2023). Exploring the benefits of reinforcement learning for autonomous drone navigation and control.

Hassanalian, M. y Abdelkefi, A. (2017). Classifications, applications, and design challenges of drones: A review. *Progress in Aerospace Sciences*, 91, 99-131.

Hassler, S. y Baysal-Gurel, F. (10 de 2019). Unmanned aircraft system (UAS) technology and applications in agriculture. *Agronomy*, 9(10).

He, J., Chen, K., Pan, X., Zhai, J. y Lin, X. (2023). Advanced biosensing technologies for monitoring of agriculture pests and diseases: A review. *Journal of Semiconductors*, 44(2), 023104.

Huang, S., Wu, Y., Wang, Q., Liu, J., Han, Q. y Wang, J. (2022). Estimation of chlorophyll content in pepper leaves using spectral transmittance red-edge parameters. *International Journal of Agricultural and Biological Engineering*, 15(5), 85-90.

Hutagalung, C.A., Priandana, K. y Seminar, K.B. (2023, February). The development of autonomous drone for document delivery in IPB University. In *AIP Conference Proceedings* (Vol. 2482, No. 1, p. 040001). AIP Publishing LLC.

Huuskonen, J. y Oksanen, T. (2018). Soil sampling with drones and augmented reality in precision agriculture. *Computers and electronics in agriculture*, 154, 25-35.

Ilniyaz, O., Du, Q., Shen, H., He, W., Feng, L., Azadi, H. y Chen, X. (2023). Leaf area index estimation of pergola-trained vineyards in arid regions using classical and deep learning methods based on UAV-based RGB images. *Computers and Electronics in Agriculture*, 207. doi:<https://doi.org/10.1016/j.compag.2023.107723>

Ilost Filho, F.H., Heldens, W.B., Kong, Z. y de Lange, E.S. (2020). Drones: innovative technology for use in precision pest management. *Journal of economic entomology*, 113(1), 1-25.

Islam, N., Rashid, M. M., Pasandideh, F., Ray, B., Moore, S. y Kadel, R. (2021). A review of applications and communication technologies for internet of things (iot) and unmanned aerial vehicle (uav) based sustainable smart farming. *Sustainability*, 13(4), 1821.

Jalajamony, H.M., Nair, M., Mead, P.F. y Fernandez, R.E. (2023). Drone aided thermal mapping for selective irrigation of localized dry spots. *IEEE Access*.

Jasim, A., Zaeen, A., Sharma, L., Bali, S., Wang, C., Buzzia, A. y Alyokhin, A. (2020). Predicting phosphorus and potato yield using active and passive sensors. *Agriculture*, 10, 564.

Javaid, M., Haleem, A., Khan, I.H. y Suman, R. (2023). Understanding the potential applications of artificial intelligence in agriculture sector. *Advanced Agrochem*, 2(1), 15-30.

Jiang, R., Sanchez-Azofeifa, A., Laakso, K., Wang, P., Xu, Y., Zhou, Z. y Chen, X. (2021). UAV-based partially sampling system for rapid NDVI mapping in the evaluation of rice nitrogen use efficiency. *Journal of Cleaner Production*, 289.

Jiang, X., Gao, M. y Gao, Z. (2020). A novel index to detect green-tide using UAV-based RGB imagery. *Estuarine, Coastal and Shelf Science*, 245.

Kabilash, S.K., Mohanapriya, D., Suseendhar, P., Indra, J., Gunasekar, T. y Senthilvel, N. (2023). Research on artificial intelligence based fruit disease identification system (AI-FDIS) with the internet of things (IoT). *Journal of Intelligent & Fuzzy Systems*, (Preprint), 1-16.

Kaivosoja, J., Hautsalo, J., Heikkinen, J., Hiltunen, L., Ruuttunen, P., Näsi, R. y Salonen, J. (2021). Reference measurements in developing UAV Systems for detecting pests, weeds, and diseases. *Remote Sensing*, 13(7), 1238.

Kakani, V., Nguyen, V., Kumar, B., Kim, H. y Pasupuleti, V. (2020). A critical review on computer vision and artificial intelligence in food industry. *Journal of Agriculture and Food Research*, 2. doi:<https://doi.org/10.1016/j.jafr.2020.100033>

Kapoor, D. S., Singh, K. J., Bansal, R., Thakur, K. y Sharma, A. (2023, March). Future commercial prospects of unmanned aerial vehicles (UAVs). In *Third Congress on Intelligent Systems: Proceedings of CIS 2022*, Volume 1 (pp. 79-89). Singapore.

Katul, G. (2023). Agrivoltaics in color: Going from light spectra to biomass. *Earth's Future*, 11(5).

Khadanga, G. y Jain, K. (2020). Tree census using circular hough transform and GRVI. *Procedia Computer Science*, 171, 389-394.

Koech, R. y Langat, P. (2018). Improving irrigation water use efficiency: A review of advances, challenges and opportunities in the Australian context. *Water*, 10(12), 1771.

Kumar, S., Yadav, A., Tiwari, A., Singh, V. y Sachan, R. (2022). Robotic Agriculture. *Environment and Sustainability Volume I*, 74.

Kumar, S.P., Subeesh, A., Jyoti, B. y Mehta, C.R. (2023). Applications of drones in smart agriculture. In *smart agriculture for developing nations: status, perspectives and challenges* (pp. 33-48). Singapore: Springer Nature Singapore.

Li, F., Li, D., Elsayed, S., Hu, Y. y Schmidhalter, U. (2021). Using optimized three-band spectral indices to assess canopy N uptake in corn and wheat. *Eur. J. Agron.*, 127, 126286.

Li, M., Shamshiri, R.R., Weltzien, C. y Schirrmann, M. (2022). Crop monitoring using Sentinel-2 and UAV multispectral imagery: A Comparison case study in northeastern germany. *Remote Sensing*, 14(17), 4426.

Li, X., Ata-Ul-Karim, S.T., Li, Y., Yuan, F., Miao, Y., Yoichiro, K., Cheng, T., Tang, L., Tian, X. y Liu, X. (2022). Advances in the estimations and applications of critical nitrogen dilution curve and nitrogen nutrition index of major cereal crops. A review. *Comput. Electron. Agric.*, 197, 106998.

Li, Y., Yan, W., An, S., Gao, W., Jia, J., Tao, S. y Wang, W. (2023). A spatio-temporal fusion framework of UAV and satellite imagery for winter wheat growth monitoring. *Drones*, 7(1), 23.

Li, Z.L., Wu, H., Duan, S.B., Zhao, W., Ren, H., Liu, X. y Zhou, C. (2023b). Satellite remote sensing of global land surface temperature: definition, methods, products, and applications. *Reviews of Geophysics*, 61(1), e2022RG000777.

Ma, B., Cao, G., Hu, C. y Chen, C. (2023). Monitoring the rice panicle blast control period based on UAV multispectral remote sensing and machine learning. *Land*, 12(2), 469.

Maes, W.H. y Steppe, K. (2019). Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in plant science*, 24(2), 152-164.

Mandla, V.R., Chokkavarapu, N. y Peddinti, V.S.S. (2023). Role of drone technology in sustainable rural development: opportunities and challenges. Proceedings of UASG 2021: Wings 4 Sustainability: Unmanned Aerial System in Geomatics, 301-318.

Manobharathi, K., Sankarganesh, E. y Gowthaman, T. (2022). Drones: New generation technology for crop protection.

Marin, D., Ferraz, G., Santana, L., Barbosa, B., Barata, R., Osco, L. y Guimarães, P. (2021). Detecting coffee leaf rust with UAV-based vegetation indices and decision tree machine learning models. Computers and Electronics in Agriculture, 190.

Marinello, F., Pezzuolo, A., Chiumenti, A. y Sartori, L. (2016). Technical analysis of unmanned aerial vehicles (drones) for agricultural applications. Engineering for rural development, 15(2), 870-875.

Martínez-Heredia, J.M., Gálvez, A.I., Colodro, F., Mora-Jiménez, J.L. y Sassi, O.E. (2023). Feasibility study of detection of ochre spot on almonds aimed at very low-cost cameras onboard a drone. Drones, 7(3), 186.

Martins, R.N., de Carvalho Pinto, F.D.A., de Queiroz, D.M., Valente, D.S.M., Rosas, J.T.F., Portes, M.F. y Cerqueira, E.S.A. (2023). Digital mapping of coffee ripeness using UAV-based multispectral imagery. Computers and Electronics in Agriculture, 204, 107499.

Maslekar, N.V., Kulkarni, K.P. y Chakravarthy, A.K. (2020). Application of unmanned aerial vehicles (UAVs) for pest surveillance, monitoring and management. Innovative Pest Management Approaches for the 21st Century: Harnessing Automated Unmanned Technologies, 27-45.

Mazur, P., Gozdowski, D., Stępień, W. y Wójcik-Gront, E. (2023). Does drone data allow the assessment of phosphorus and potassium in soil based on field experiments with winter rye?. Agronomy, 13(2), 446.

McDonald, W. (2019). Drones in urban stormwater management: a review and future perspectives. Urban Water Journal, 16(7), 505-518.

Medeiros, T.P.D., Morellato, L.P.C. y Silva, T.S.F. (2023). Spatial distribution and temporal variation of tropical mountaintop vegetation through images obtained by drones. Frontiers in Environmental Science, 11, 150.

Mee, C.Y., Bala, S.K. y Mohd, A.H. (2016). Detecting and monitoring plant nutrient stress using remote sensing approaches: A Review. Asian J. Plant Sci. 2016, 16, 1–8.

Metiva, M.A. (2021) Applications of drone-based remote sensing in carrot and tomato cropping systems. M.Sc. Thesis Michigan State University.

Michels, M., von Hobe, C.F., Weller von Ahlefeld, P.J. y Musshoff, O. (2021). The adoption of drones in German agriculture: a structural equation model. Precision Agriculture, 22(6), 1728-1748.

Mirzaliev, S.M., Horomidov, H.H., Sharipov, K.A. y Kholikova, N.A. (2022, June). Perspectives of use of agricultural drones in Uzbekistan. In IOP Conference Series: Earth and Environmental Science (Vol. 1045, No. 1, p. 012147). IOP Publishing.

Misbah, K.; Laamrani, A.; Khechba, K.; Dhiba, D.; Chehbouni, A. (2021). Multi-Sensors remote sensing applications for assessing, monitoring, and mapping NPK content in soil and crops in african agricultural land. Remote Sens. 2021, 14, 81.

Mithra, S. y Nagamalleswari, T.Y. (2023). Cucurbitaceous family flower inferencing using deep transfer learning approaches: CuCuFlower UAV imagery data. *Soft Computing*, 1-12.

Mukhamediev, R.I., Yakunin, K., Aubakirov, M., Assanov, I., Kuchin, Y., Symagulov, A. y Amirgaliyev, Y. (2023). Coverage path planning optimization of heterogeneous UAVs group for precision agriculture. *IEEE Access*.

Nambi, E., Walsh, O.S., Ansah, E.O. y Lamichhane, R. (2022). Drones for fruit producers. *Crops & Soils*, 55(4), 16-23.

Nduku, L., Munghemezulu, C., Mashaba-Munghemezulu, Z., Kalumba, A.M., Chirima, G.J., Masiza, W. y De Villiers, C. (2023). Global research trends for unmanned aerial vehicle remote sensing application in wheat crop monitoring. *Geomatics*, 3(1), 115-136.

Nguyen, H.D., Pan, V., Pham, C., Valdez, R.; Doan, K. y Nansen, C. (2020). Night-based hyperspectral imaging to study association of horticultural crop leaf reflectance and nutrient status. *Comput. Electron. Agric.*, 173, 105458.

Nhamo, L., Mpandeli, S., Liphadzi, S., Hlophe-Ginindza, S., Kapari, M., Molwantwa, J. y Mabhaudhi, T. (2023). Advances in water research: Enhancing sustainable water use in irrigated agriculture in South Africa. In *Progress in Sustainable Development* (pp. 233-248). Elsevier.

Padilla, F.M., Gallardo, M., Peña-Fleitas, M.T., De Souza, R. y Thompson, R.B. (2018). Proximal optical sensors for nitrogen management of vegetable crops: A review. *Sensors*, 18(7), 2083.

Pallottino, F., Figorilli, S., Cecchini, C. y Costa, C. (2021). Light drones for basic in-field phenotyping and precision farming applications: RGB tools based on image analysis. *Crop Breeding: Genetic Improvement Methods*, 269-278.

Pandiyar, P., Thangaraj, R., Subramanian, M., Vivekanandan, S., Arivazhagan, S. y Geetha, S.K.A. (2023). Comprehensive review on internet of agro drones for precision agriculture. *Internet of Drones*, 99-123.

Pathak, H., Kumar, G.A.K., Mohapatra, S.D., Gaikwad, B.B. y Rane, J. (2020). Use of drones in agriculture: Potentials, problems and policy needs. ICAR-National Institute of Abiotic Stress Management, 4-5.

Peng, X., Chen, D., Zhou, Z., Zhang, Z., Xu, C., Zha, Q., Wang, F. y Hu, X. (2022). Prediction of the nitrogen, phosphorus and potassium contents in grape leaves at different growth stages based on UAV multispectral remote sensing. *Remote Sens.*, 14, 2659.

Pewira Redi, A.A., Kusuma, M.R.C., Sopha, B.M., Asih, A.M.S. y Liperda, R.I. (2023). Two-echelon vehicle routing problem for agricultural area mapping operation with drone. In *Smart and sustainable supply chain and logistics—challenges, methods and best practices: Volume 2* (pp. 173-181). Cham: Springer International Publishing.

Puri, V., Nayyar, A. y Raja, L. (2017). Agriculture drones: A modern breakthrough in precision agriculture. *Journal of Statistics and Management Systems*, 20(4), 507-518.

Qiao, L., Tang, W., Gao, D., Zhao, R., An, L., Li, M. y Song, D. (2022). UAV-based chlorophyll content estimation by evaluating vegetation index responses under different crop coverages. *Computers and Electronics in Agriculture*, 196.

Qiao, L., Zhao, R., Tang, W., An, L., Sun, H., Li, M. y Liu, G. (2022). Estimating maize LAI by exploring deep features of vegetation index map from UAV multispectral images. *Field Crops Research*, 289.

Raj, E.F.I., Appadurai, M. y Athiappan, K. (2022). Precision farming in modern agriculture. In Smart agriculture automation using advanced technologies: Data analytics and machine learning, cloud architecture, automation and IoT (pp. 61-87). Singapore: Springer Singapore.

Rani, A.L., Chaudhary, A. M., Sinha, N., Mohanty, M. y Chaudhary, R. (2019). Drone: The green technology for future agriculture. *Harit Dhara*, 2(1), 3-6.

Rehman, A., Ma, H., Ozturk, I. y Ulucak, R. (2022). Sustainable development and pollution: The effects of CO<sub>2</sub> emission on population growth, food production, economic development, and energy consumption in Pakistan. *Environmental Science and Pollution Research*, 1-12.

Rejeb, A., Abdollahi, A., Rejeb, K. y Treiblmaier, H. (2022). Drones in agriculture: A review and bibliometric analysis. *Computers and Electronics in Agriculture*, 198, 107017.

Reyes Santamaría, M., Toledo Cabrera, D., López Santiago, A., Pacheco Trejo, J., Saucedo García, M. y Madariaga-Navarrete, A. (2023). Impacto del cambio climático sobre la fotosíntesis, fotorrespiración y respiración de plantas C3. *Boletín de Ciencias Agropecuarias del ICAP*, 9 (Especial), 6-11.

Rifat, A., Patel, P. y Babu, B.S. (2022). The internet of things (IOT) in smart agriculture monitoring. *European Journal of Information Technologies and Computer Science*, 2(1), 14-18.

Rodriguez III, R. (2023). Measuring the Adoption of Drones: A Case Study of the United States Agricultural Aircraft Sector. *Eng*, 4(1), 977-983.

Ruffell, A. y O'Keefe, A. (2023). Conjunctive use of drone-mounted sonar and water penetrating radar for reservoir water resource and vulnerability. DOI: <https://doi.org/10.21203/rs.3.rs-2409642/v1>

Rustioni, L., Grossi, D., Brancadoro, L. y Failla, O. (2018). Iron, magnesium, nitrogen and potassium deficiency symptom discrimination by reflectance spectroscopy in grapevine leaves. *Sci. Hortic.*, 241, 152–159.

Saad El Imanni, H., El Harti, A., Bachaoui, E., Mouncif, H., Eddassouqui, F., Hasnai, M. y Zinelabidine, M. (2023). Multispectral UAV data for detection of weeds in a citrus farm using machine learning and Google Earth Engine: Case study of Morocco. *Remote Sensing Applications: Society and Environment*, 30, 100941.

Sahoo, R.N., Viswanathan, C., Kumar, M., Bhugra, S., Karwa, S., Misra, T. y Kumar, S. (2023). High-throughput phenomics of crops for water and nitrogen stress. In: *Translating Physiological Tools to Augment Crop Breeding* (pp. 291-310). Singapore: Springer Nature Singapore.

Samreen, T., Ahmad, M., Baig, M.T., Kanwal, S. y Nazir, M.Z. (2023). Remote sensing in precision agriculture for irrigation management. *Environmental Sciences Proceedings*, 23(1), 31.

Sangjan, W., McGee, R.J. y Sankaran, S. (2022). Optimization of UAV-based imaging and image processing orthomosaic and point cloud approaches for estimating biomass in a forage crop. *Remote Sensing*, 14(10), 2396.

Saranya, T., Deisy, C., Sridevi, S. y Anbananthen, K.S.M. (2023). A comparative study of deep learning and Internet of Things for precision agriculture. *Engineering Applications of Artificial Intelligence*, 122, 106034.

Sarma, A.S. y Nidamanuri, R.R. (2023, January). Transfer Learning for Plant-level Crop Classification using Drone-based Hyperspectral Imagery. In 2023 International Conference on Machine Intelligence for GeoAnalytics and Remote Sensing (MIGARS) (Vol. 1, pp. 1-4). IEEE.

Shankar, R.H., Veeraraghavan, A.K., Sivaraman, K. y Ramachandran, S.S. (2018, December). Application of UAV for pest, weeds and disease detection using open computer vision. In 2018 International Conference on Smart Systems and Inventive Technology (ICSSIT) (pp. 287-292). IEEE.

Shavanov, M.V., Shigapov, I.I. y Niaz, A. (2022, February). Biological methods for pests and diseases control in agricultural plants. In AIP Conference Proceedings (Vol. 2390, No. 1, p. 030081). AIP Publishing LLC.

Siedliska, A., Baranowski, P., Pastuszka-Woźniak, J., Zubik, M. y Krzyszczak, J. (2021). Identification of plant leaf phosphorus content at different growth stages based on hyperspectral reflectance. *BMC Plant Biol.*, 21, 28.

Singh, A., Ganapathysubramanian, B., Singh, A. y Sarkar, S. (2016). Machine learning for high-throughput stress phenotyping in plants. *Trends in Plant Science*, 21(2), 110-124. doi:<http://dx.doi.org/10.1016/j.tplants.2015.10.015>

Singh, C., Mishra, R., Gupta, H.P. y Kumari, P. (2022). The Internet of Drones in Precision Agriculture: Challenges, Solutions, and Research Opportunities. *IEEE Internet of Things Magazine*, 5(1), 180-184.

Sorbelli, F.B. Corò, F., Sajal, K., Di Bella, E., Lara, M., Palazzetti, L. y Pinottie, C.M. (2022). A drone-based application for scouting Halyomorpha halys bugs in orchards with multifunctional nets. *IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)*, Pisa, Italy, pp. 127-129, doi: 10.1109/PerComWorkshops53856.2022.9767309.

Stehr, N.J. (2015). Drones: The newest technology for precision agriculture. *Natural Sciences Education*, 44(1), 89-91.

Sundar, C. y Asokhan, M. (2023). Pivotal Role of Drones in Agriculture—a Review. *Asian Journal of Agricultural Extension, Economics & Sociology*, 41(4), 131-140.

Tallou, A., Haouas, A., Erraji, H., Driouich, A., Salcedo, F.P., Vivaldi, G.A. y Aziz, F. (2023). Can remote sensing be a useful tool to increase water reuse in agriculture?. In *Water in Circular Economy* (pp. 131-139). Springer, Cham.

Tejasri, N., Pachamuthu, R., Naik, B. y Desai, U.B. (2023). Intelligent drought stress monitoring on spatio-spectral-temporal drone based crop imagery using deep networks. In *2nd AAAI Workshop on AI for Agriculture and Food Systems*.

Tu, Y., Johansen, K., Phinn, S. y Robson, A. (2019). Measuring canopy structure and condition using multi-spectral UAS imagery in a horticultural environment. *Remote Sensing*, 11(3).

Turner, D., Lucieer, A. y Watson, C. (2011, April). Development of an unmanned aerial vehicle (UAV) for hyper resolution vineyard mapping based on visible, multispectral, and thermal imagery. In *Proceedings of 34th International symposium on remote sensing of environment* (p. 4).

ur Rehman, U., Iqbal, T., Hussain, S., Cheema, M. J. M., Iqbal, F. y Basit, A. (2023). Drone and robotics roadmap for agriculture crops in Pakistan: A Review. *Environmental Sciences Proceedings*, 23(1), 39.

Valluvan, A.B., Raj, R., Pingale, R. y Jagarlapudi, A. (2023). Canopy height estimation using drone-based RGB images. *Smart Agricultural Technology*, 4, 100145.

van der Merwe, D., Burchfield, D.R., Witt, T.D., Price, K.P. y Sharda, A. (2020). Drones in agriculture. *Advances in agronomy*, 162, 1-30.

Vélez, S., Ariza-Sentís, M. y Valente, J. (2023). Mapping the spatial variability of Botrytis bunch rot risk in vineyards using UAV multispectral imagery. *European Journal of Agronomy*, 142. doi:<https://doi.org/10.1016/j.eja.2022.126691>

Vishal, R. y Mahanta, G.B. (2022, December). A preliminary study on autonomous drone systems for agriculture pesticide spraying. In *AIP Conference Proceedings* (Vol. 2670, No. 1, p. 030007). AIP Publishing LLC.

Vishwakarma, K., Tripathi, A. y Ghare, M. (2023). Harvesting Future: The transformative role of AI and machine learning in agriculture. *Vigyan Varta* 4(3): 148-153.

Wang, L., Huang, X., Li, W., Yan, K., Han, Y., Zhang, Y. y Lan, Y. (2022). Progress in agricultural unmanned aerial vehicles (UAVs) applied in China and prospects for Poland. *Agriculture*, 12(3), 397.

Xiao, J., Suab, S.A., Chen, X., Singh, C.K., Singh, D., Aggarwal, A.K. y Avtar, R. (2023). Enhancing assessment of corn growth performance using unmanned aerial vehicles (UAVs) and deep learning. *Measurement*, 214, 112764.

Xu, L., Zhou, L., Meng, R., Zhao, F., Lv, Z., Xu, B. y Peng, S. (2022). An improved approach to estimate ratoon rice aboveground biomass by integrating UAV-based spectral, textural and structural features. *Precision Agriculture*, 23(4), 1276-1301.

Xue, J. y Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017.

Yang, T., Lu, J., Liao, F., Qi, H., Yao, X., Cheng, T., Zhu, Y., Cao, W. y Tian, Y. (2021). Retrieving potassium levels in wheat blades using normalised spectra. *Int. J. Appl. Earth Obs. Geoinf.*, 102, 102412

Yu, F.H., Bai, J.C., Jin, Z.Y., Guo, Z.H., Yang, J.X. y Chen, C. (2022). Combining the critical nitrogen concentration and machine learning algorithms to estimate nitrogen deficiency in rice from UAV hyperspectral data. *Journal of Integrative Agriculture*. doi:[10.1016/j.jia.2022.12.007](https://doi.org/10.1016/j.jia.2022.12.007)

Yu, X., Chang, C., Song, J., Zhuge, Y. y Wang, A. (2022). Precise monitoring of soil salinity in China's yellow river delta using UAV-borne multispectral imagery and a soil salinity retrieval index. *Sensors* 2022, 22, 546.

Yuan, W., Hua, W., Heinemann, P.H. y He, L. (2023). UAV Photogrammetry-Based Apple Orchard Blossom Density Estimation and Mapping. *Horticulturae*, 9(2), 266.

Yue, J., Feng, H., Li, Z., Zhou, C. y Xu, K. (2021). Mapping winter-wheat biomass and grain yield based on a crop model and UAV remote sensing. *International Journal of Remote Sensing*, 42(5), 1577-1601.

Zha, H., Miao, Y., Wang, T., Li, Y., Zhang, J., Sun, W., Feng, Z. y Kusnerek, K. (2020). Improving unmanned aerial vehicle remote sensing-based rice nitrogen nutrition index prediction with machine learning. *Remote Sens.*, 12, 215.

Zhang, Y., Han, W., Zhang, H., Niu, X. y Shao, G. (2023). Evaluating soil moisture content under maize coverage using UAV multimodal data by machine learning algorithms. *Journal of Hydrology*, 617.

Zhao, W., Wang, M. y Pham, V.T. (2023). Unmanned aerial vehicle and geospatial analysis in smart irrigation and crop monitoring on IoT platform. *Mobile Information Systems*, 2023.

Zheng, H.; Cheng, T.; Li, D.; Yao, X.; Tian, Y.; Cao, W. y Zhu, Y. (2018). Combining unmanned aerial vehicle (UAV)-based multispectral imagery and ground-based hyperspectral data for plant nitrogen concentration estimation in rice. *Front. Plant Sci.* 2018, 9, 936.

Zuo, A., Wheeler, S.A. y Sun, H. (2021). Flying over the farm: understanding drone adoption by Australian irrigators. *Precision Agriculture*, 22(6), 1973-1991.

## SOBRE LOS AUTORES



### **RICARDO HUGO LIRA-SALDIVAR:**

Doctor (Ph.D) en Ecología por la Universidad de California, Davis, USA. Diplomado en la Universidad Ben-Gurion de Israel. Con una Maestría (M.C.) en Uso y Conservación del Agua, del Instituto Tecnológico y de Estudios Superiores de Monterrey (ITESM), México. Ingeniero Agrónomo por la Universidad Autónoma Agraria Antonio Narro (UAAAAN) de Saltillo, México.

México. Labora en el Departamento de Biociencias y Agrotecnología del Centro de Investigación en Química Aplicada (CIQA), en Saltillo, México.



### **FRANCISCO MARCELO LARA**

**VIVEROS:** Doctor en Ciencias en Fisiología Vegetal por el Colegio de Postgraduados (CP) Texcoco, México. Maestría en Ciencias en Producción Agroalimentaria en el Trópico e Ingeniero en Sistemas de Producción Agropecuaria por la Universidad Veracruzana, Veracruz, México. Actualmente adscrito al Departamento de Biociencias y Agrotecnología del Centro de Investigación en Química Aplicada en Saltillo, México.

# Uso de Drones

---

## en la Agricultura de Precisión

---

- 🌐 [www.atenaeditora.com.br](http://www.atenaeditora.com.br)
- ✉️ [contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)
- 📷 [@atenaeditora](#)
- ⬇️ [www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)

# Uso de Drones

---

## en la Agricultura de Precisión

---

- 🌐 [www.atenaeditora.com.br](http://www.atenaeditora.com.br)
- ✉️ [contato@atenaeditora.com.br](mailto:contato@atenaeditora.com.br)
- 📷 [@atenaeditora](https://www.instagram.com/atenaeditora)
- ⬇️ [www.facebook.com/atenaeditora.com.br](https://www.facebook.com/atenaeditora.com.br)