



ARTÍCULO DE REVISIÓN

Monitoreo de cultivos y suelos en agricultura de precisión con UAV e inteligencia artificial: una revisión

Crop and Soil Monitoring in Precision Agriculture with UAVs and Artificial Intelligence: A Review

Elías Buitrago Bolívar  ¹, John Alexander Rico Franco  ² y Sócrates Rojas Amador  ³

Fecha de Recepción: 14 de junio de 2024

Fecha de Aceptación: 15 de diciembre de 2024

Cómo citar: Buitrago Bolívar, E., Rico Franco., J. A., y Rojas Amador., S. (2024). Monitoreo de cultivos y suelos en agricultura de precisión con UAV e inteligencia artificial: una revisión. *Tecnura*, 28(82), 75-103. <https://doi.org/10.14483/22487638.22360>

Resumen

Contexto: la creciente demanda global de alimentos, junto con los retos ambientales y sociales asociados a la intensificación agrícola, ha impulsado el desarrollo de soluciones tecnológicas que mejoren la eficiencia y sostenibilidad de la producción. En este escenario, la agricultura de precisión, apoyada en vehículos aéreos no tripulados (*unmanned aerial vehicle* [UAV]) y en inteligencia artificial (IA), se posiciona como una herramienta clave para el monitoreo detallado de cultivos y suelos.

Objetivo: este artículo presenta una revisión estructurada de la literatura científica sobre técnicas de detección remota basadas en UAV, con énfasis en aplicaciones orientadas a la estimación de niveles de fertilización, biomasa aérea, predicción de rendimiento y detección de plagas y malezas en sistemas agrícolas.

Metodología: se efectuó una búsqueda sistemática en bases de datos académicas (Scopus y Web of Science), mediante combinaciones de términos clave relacionados con agricultura de precisión, UAV, teledetección, IA y monitoreo agronómico. Se recurrió a criterios de selección rigurosos que resultaron en la inclusión de 62 artículos para análisis. La información se sintetizó mediante un enfoque comparativo de técnicas, sensores, algoritmos y métricas de desempeño.

Resultados: la revisión evidenció una tendencia creciente hacia el uso de UAV equipados con sensores RGB, multiespectrales, hiperespectrales y LiDAR, junto con técnicas de aprendizaje automático y profundo, para estimar parámetros clave del cultivo como el índice de área foliar (*leaf area index* [LAI]), contenido de nitrógeno y rendimiento. Se identificaron enfoques prometedores basados en fusión multimodal de datos y modelos híbridos (CNN + GRU, ensambles), capaces de superar limitaciones de métodos clásicos como la saturación espectral. Sin embargo,

¹Profesor Facultad de Sistemas, Escuela Tecnológica Instituto Técnico Central, Grupo de Investigación K-Demy 
Correo electrónico: ebuitragob@itc.edu.co

²Profesor Facultad de Sistemas, Escuela Tecnológica Instituto Técnico Central, Grupo de Investigación K-Demy 
Correo electrónico: jfrancor@itc.edu.co

³Profesor Facultad de Sistemas, Escuela Tecnológica Instituto Técnico Central, Grupo de Investigación K-Demy 
Correo electrónico: rsocrates@itc.edu.co

se detectó escasa disponibilidad de bases de datos abiertas y poca estandarización en los protocolos de adquisición, lo que dificulta la replicabilidad y generalización de los modelos.

Conclusiones: el uso integrado de UAV e IA representa una herramienta transformadora para la gestión agrícola inteligente. No obstante, su implementación efectiva requiere superar barreras técnicas, económicas y estructurales; además, debe promover el acceso abierto a datos y el desarrollo de soluciones contextualizadas. Esta revisión destaca la importancia de avanzar hacia sistemas más explicables, ligeros y adaptables, así como de fomentar una transformación digital agrícola inclusiva y responsable.

Palabras clave: agricultura de precisión, UAV, detección remota, inteligencia artificial, aprendizaje automático, fertilización, biomasa, predicción de rendimiento, apropiación tecnológica.

Abstract

Background: The growing global demand for food, along with the environmental and social challenges associated with agricultural intensification, has driven the development of technological solutions aimed at improving the efficiency and sustainability of food production. In this context, precision agriculture, supported by unmanned aerial vehicles (UAVs) and artificial intelligence (AI), emerges as a key tool for the detailed monitoring of crops and soils.

Objective: This article presents a structured review of the scientific literature on UAV-based remote sensing techniques, with an emphasis on applications aimed at estimating fertilization levels, aboveground biomass, yield prediction, and the detection of pests and weeds in agricultural systems.

Methodology: A systematic search was conducted in academic databases (Scopus and Web of Science), using combinations of key terms related to precision agriculture, UAV, remote sensing, AI, and agronomic monitoring. Rigorous inclusion criteria were applied, resulting in the selection of 62 articles for analysis. The information was synthesized through a comparative approach of techniques, sensors, algorithms, and performance metrics.

Results: The review highlights a growing trend in the use of UAVs equipped with RGB, multispectral, hyperspectral, and LiDAR sensors, combined with machine learning and deep learning techniques, to estimate key crop parameters such as leaf area index (LAI), nitrogen content, and yield. Promising approaches were identified based on multimodal data fusion and hybrid models (CNN + GRU, ensemble methods), capable of overcoming limitations of classical methods such as spectral saturation. However, a lack of open-access datasets and limited standardization in data acquisition protocols were observed, which hinders the replicability and generalization of models.

Conclusions: The integrated use of UAVs and AI represents a transformative tool for smart agricultural management. Nevertheless, effective implementation requires overcoming technical, economic, and structural barriers, as well as promoting open data access and the development of context-aware solutions. This review underscores the importance of advancing toward more explainable, lightweight, and adaptable systems, and fostering an inclusive and responsible digital transformation of agriculture.

Keywords: Precision agriculture, UAV, remote sensing, artificial intelligence, machine learning, fertilization, biomass, yield prediction, technological adoption.

Introducción

A partir del estudio pionero de (1), a lo largo de la década de 1990 se llevaron a cabo una serie de investigaciones centradas en el desarrollo de métodos de muestreo del suelo, para medir eficazmente la calidad de la fertilización. Estos estudios incorporaron herramientas tecnológi-

cas avanzadas a las prácticas agrícolas rutinarias; además, demostraron cómo las variaciones en los niveles de fertilizantes del suelo podían atribuirse a la variabilidad introducida por los métodos de muestreo del análisis del suelo. Este conjunto de conocimientos ha dado lugar a propuestas innovadoras para optimizar las estrategias de fertilización y garantizar una gestión sostenible de los recursos agrícolas. De ahí han surgido conceptos clave en la agricultura de precisión, como el *muestreo estratégico de nutrientes, las evaluaciones de la toxicidad del suelo agrícola y la fertilización de precisión con dosificación variable para cultivos productivos* (2).

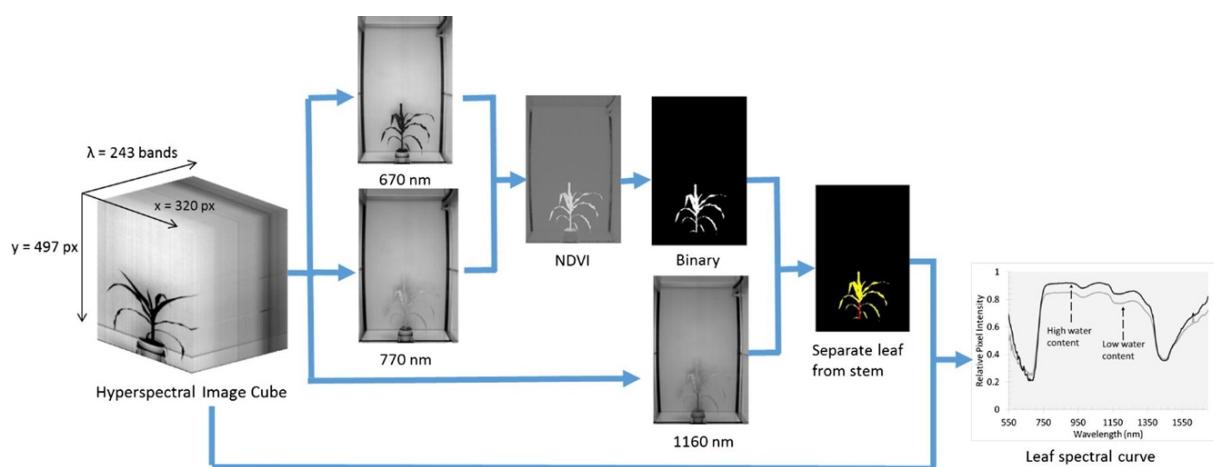


Figura 1. Análisis de imágenes hiperespectrales para predecir el contenido de agua de la hoja de la planta. Tomado de (4).

La evolución en estos métodos de estudio agrícola ha facilitado la incorporación de variables más específicas y detalladas, y ha enriquecido significativamente el análisis de suelos. Por ejemplo, pueden medirse los efectos de la inclinación del terreno en los índices de fertilización o los impactos negativos de la sobredosificación de fertilizantes en otros seres vivos del ecosistema. Este progreso ha resultado en innovaciones significativas, como la integración de mapas de contornos tridimensionales, modelos geoestadísticos y técnicas cartográficas, sistemas de información geográfica (SIG), los sistemas de posicionamiento global (SPG) y las técnicas de monitoreo remoto (3).

Los drones comerciales (*unmanned aerial vehicles* [UAV]) pueden equiparse con diversos sensores y cámaras para captar imágenes y facilitar los procesos de telemetría (5) (véase figura 1). Esta capacidad ha impulsado el desarrollo de aplicaciones de supervisión y control remotos para la gestión de cultivos, por medio de la integración activa de los UAV como herramientas versátiles en la producción agrícola de nueva generación (6). Las investigaciones en esta área demuestran cómo las imágenes panorámicas captadas por UAV sirven para calcular índices de vegetación, los cuales pueden correlacionarse con varios aspectos de la salud y vitalidad de

las plantas: crecimiento, altura, densidad y medidas geométricas de referencia específicas. Este enfoque acentúa la utilidad de las imágenes basadas en UAV para proporcionar información detallada y procesable sobre el estado y el desarrollo de los cultivos (7). Entonces, la literatura especializada resalta la decidida integración de UAV para detección remota por medio de distintas cámaras, con sensores remotos, sistemas de información en tiempo real e inteligencia artificial (IA), según requerimientos concretos y definidos. De hecho, la utilización de UAV como apoyo a procesos agrícolas representa un campo de investigación y desarrollo en expansión, con miras a lograr su integración a los flujos de trabajo y a operaciones agroindustriales de precisión (8,9).

En la literatura hay una gran diversidad de índices de vegetación (IV) y sus aplicaciones en casos de uso bien definidos. Una primera aproximación a índices primarios de vegetación para aplicaciones de detección remota, basadas en UAV la plantean (5). Los autores proponen una clasificación de los IV en dos grupos: térmicos y espectrales, y ponen de manifiesto un caso de uso que era el foco en ese momento, la utilización de distintos IV para la detección de estrés hídrico. Posteriormente, otros estudios han registrado la evolución y aplicaciones de los IV basados en imágenes obtenidas por UAV, como se observa en los trabajos de (10–12) y (13).

La reciente disponibilidad de distintos sensores y cámaras especializados para UAV ha impulsado el desarrollo de nuevos usos para la teledetección de cultivos, lo cual amplía las capacidades de la agricultura de precisión a los siguientes campos: estrés hídrico, estado nutricional de los cultivos (particularmente niveles de nitrógeno), y monitoreo de plagas y enfermedades (14,15).

El objetivo de este artículo es presentar una revisión estructurada de la literatura científica sobre el uso UAV e IA, en aplicaciones de agricultura de precisión, con énfasis en la estimación de niveles de fertilización, biomasa aérea, detección de plagas y predicción de rendimiento. Esta revisión se fundamenta en el análisis de 62 estudios primarios recientes que integran imágenes captadas por UAV con técnicas de visión por computador y modelos de aprendizaje automático. El artículo se organiza como sigue: la introducción contextualiza los avances históricos y tecnológicos en agricultura de precisión con UAV; la metodología detalla el proceso de búsqueda, selección y análisis de la literatura revisada; luego se sintetizan los resultados más relevantes organizados por área de aplicación; las últimas dos partes plantean una discusión crítica y las conclusiones generales; además, se resaltan los avances, limitaciones y oportunidades futuras identificadas en este campo.

Metodología

La presente revisión de literatura se llevó a cabo siguiendo una metodología estructurada, diseñada para identificar, sintetizar y analizar de manera sistemática los estudios primarios publicados recientemente sobre el uso de UAV y técnicas de IA en agricultura de precisión. Se enfatizó en las aplicaciones sobre monitoreo de cultivos y estimación de parámetros clave, fertilización, estimación de biomasa, detección de plagas y predicción de rendimiento. Este enfoque buscó asegurar la transparencia y reproducibilidad de la selección de la literatura, para así iniciar el análisis crítico de los hallazgos empíricos.

Fuentes de información

La búsqueda de literatura relevante se realizó en las bases de datos Scopus y Web of Science (WoS). Estas fueron elegidas estratégicamente debido a su indexación de literatura *peer-reviewed* de alto impacto, lo cual contribuyó a garantizar la calidad y pertinencia de los estudios identificados.

Estrategia de búsqueda

Para identificar los artículos relevantes, se emplearon las siguientes cadenas de búsqueda en cada base de datos:

- *Scopus*. TITLE-ABS-KEY((UAV OR “unmanned aerial vehicle” OR UAS) AND (“artificial intelligence” OR “machine learning” OR “deep learning”) AND (“precision agriculture” OR “precision farming”)) AND (crop* OR plant* OR vegetation OR field* OR agricul* OR soil* OR land OR fertiliz* OR nitrogen OR phosphorus OR potassium OR biomass OR yield OR pest* OR disease* OR “plant density” OR “vegetation index” OR “spectral analysis”))
- *Web of Science*. ALL=((“UAV” OR “unmanned aerial vehicle” OR UAS) AND (“artificial intelligence” OR “machine learning” OR “deep learning”) AND (“precision agriculture” OR “precision farming”)) AND ((“crop”* OR “plant”* OR “vegetation” OR “field”* OR agricul*) OR (“soil”* OR land) OR fertiliz* OR nitrogen OR phosphorus OR potassium OR biomass OR yield OR pest* OR disease* OR “plant density” OR “vegetation index” OR “spectral analysis”))

La búsqueda abarcó publicaciones entre los años 2020 y 2024. Esta limitación temporal permitió focalizar la revisión en los avances más recientes y relevantes en el campo. La ejecución de esta estrategia de búsqueda en las plataformas seleccionadas resultó en una identificación inicial de un total de 1165 artículos.

Criterios de selección

Los artículos identificados en la fase de búsqueda fueron sometidos a una rigurosa selección, a partir de criterios de inclusión y exclusión predefinidos para determinar el conjunto final de estudios que conformarían el corpus de la revisión. Estos criterios se detallan en la tabla 1.

Tabla 1. Criterios de selección para la revisión

Criterios de inclusión	Criterios de exclusión
Publicaciones correspondientes a artículos de investigación originales (estudios primarios) en revistas científicas con revisión por pares o actas de conferencias relevantes.	Documentos que no corresponden a literatura científica <i>peer-reviewed</i> (por ejemplo: editoriales, noticias, blogs, resúmenes extendidos sin publicación completa asociada).
Estudios que describen la aplicación o el uso de UAV o drones en contextos agrícolas.	Artículos de revisión o metaanálisis.
Trabajos que involucren la utilización de técnicas de inteligencia artificial (IA), aprendizaje automático (<i>machine learning</i> [ML]) o aprendizaje profundo (<i>deep learning</i> [DL]) para el análisis de imágenes o datos obtenidos por UAV.	Estudios que, si bien utilizan UAV o IA/ML/DL, no aplican <i>ambas tecnologías de forma combinada</i> en el análisis de datos para agricultura.
Artículos centrados en aplicaciones de agricultura de precisión, específicamente relacionadas con el monitoreo de cultivos, estimación de parámetros (incluyendo fertilización, biomasa, rendimiento, plagas, enfermedades).	Publicaciones enfocadas en aplicaciones de UAV o IA/ML/DL fuera del ámbito de la agricultura de precisión (por ejemplo: mapeo topográfico general, inspección de infraestructura no agrícola).
Publicados dentro del rango de fechas establecido (2020-2024).	Artículos duplicados que aparecieron en múltiples bases de datos o búsquedas.
Artículos publicados en idioma inglés.	Estudios que, tras la revisión del texto completo, resultaron no cumplir con los criterios de inclusión definidos, a pesar de haber sido inicialmente identificados por título o resumen.

Proceso de selección

La selección de artículos se llevó a cabo en las siguientes fases:

1. *Gestión de duplicados.* Tras consolidar los resultados de las bases de datos en Zotero, se identificaron y eliminaron 768 artículos duplicados.
2. *Cribado por título y resumen.* Los 397 artículos restantes fueron evaluados inicialmente por título y resumen, según los criterios de selección. Esta fase resultó en la exclusión de 268 artículos, principalmente debido a falta de relevancia temática o tipo de documento

inadecuado (se excluyeron artículos de conferencias, libros y capítulos de libros, entre otros).

3. *Revisión de texto completo*. Los 129 artículos que superaron el tamizaje inicial fueron leídos en detalle para confirmar el cumplimiento de todos los criterios de inclusión/exclusión. En esta fase, se excluyeron 67 adicionales.

Este proceso resultó en la identificación de un corpus final de 62 artículos para la revisión, cuyo flujo completo se ilustra en la figura 2.

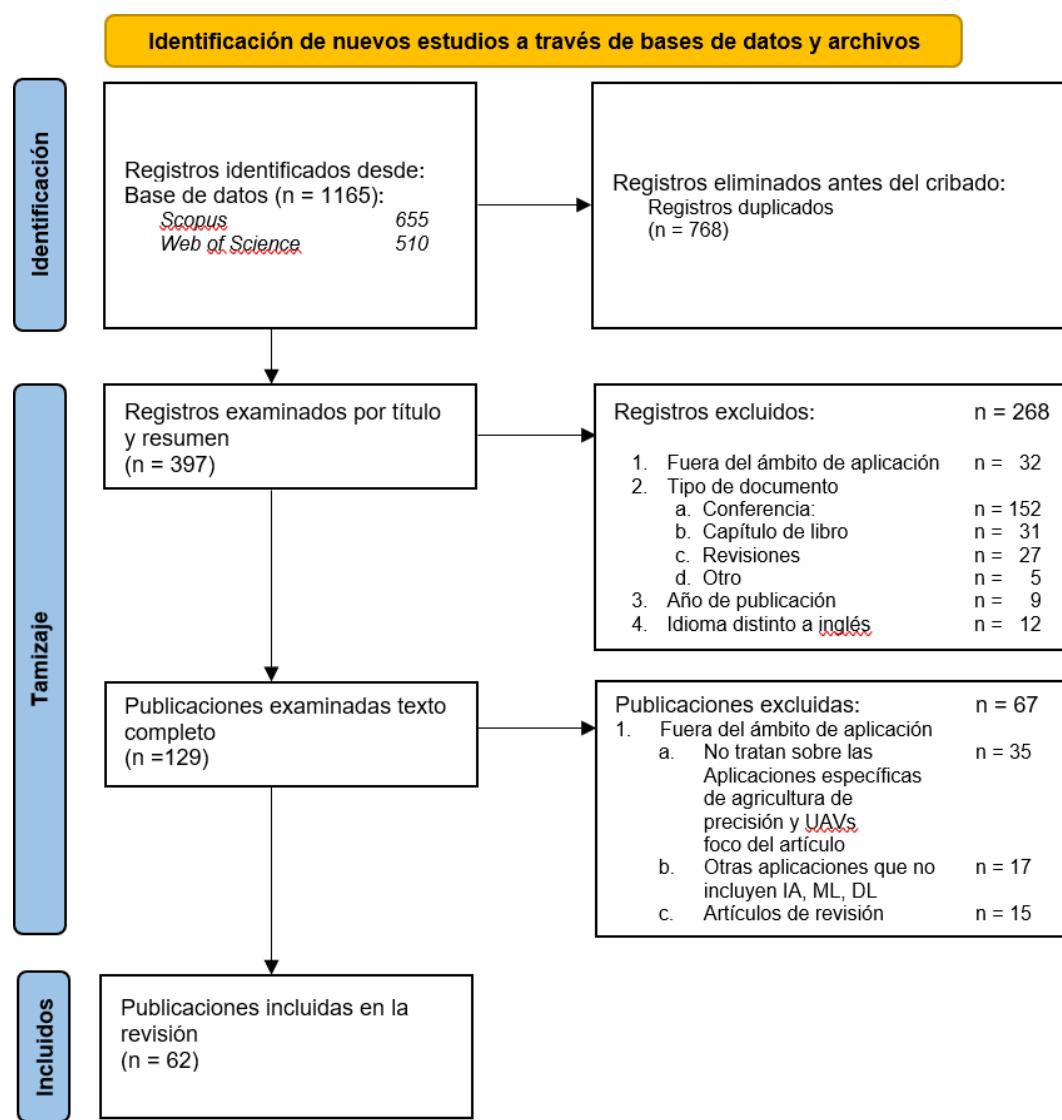


Figura 2. Diagrama de flujo del proceso de selección de artículos

Extracción de datos

A partir del corpus final de 62 artículos seleccionados, se procedió a la extracción sistemática de información clave y relevante para los objetivos de la revisión. Se utilizó una hoja de cálculo estructurada para asegurar la consistencia en la recolección de datos a través de todos los estudios.

Esta extracción de datos estructurada proporcionó la base empírica necesaria para la posterior síntesis y análisis de los hallazgos.

Síntesis y análisis de datos

Los datos extraídos de los estudios incluidos (estudios primarios) fueron objeto de un análisis comprensivo y estructurado. El enfoque principal fue la síntesis de los hallazgos empíricos para reconocer las tendencias predominantes, las metodologías más empleadas y los resultados clave reportados en las diversas aplicaciones de UAV e IA en agricultura de precisión. El análisis se organizó temáticamente; luego se agruparon los estudios según su aplicación principal, lo cual hizo posible comparar y contrastar las tecnologías (sensores, UAV) y las técnicas usadas de inteligencia artificial (IA), aprendizaje automático (*machine learning* [ML]) o aprendizaje profundo (*deep learning* [DL]); después se evaluaron sus fortalezas, debilidades y el desempeño en diferentes contextos y cultivos. Se efectuó un análisis crítico para identificar patrones recurrentes, evaluar la solidez de las metodologías reportadas, y así determinar las limitaciones y desafíos comunes inherentes a la implementación de estas tecnologías en la práctica agrícola, tal como fueron reportados por los autores de los estudios originales. Asimismo, se reconocieron las brechas de conocimiento y las direcciones futuras de investigación sugeridas en la literatura primaria.

Resultados

En esta sección se sintetizan los hallazgos en los estudios primarios incluidos en la revisión, organizados por áreas de aplicación principal. El análisis de estos trabajos proporciona una visión general de las tecnologías (UAV, sensores, técnicas de IA/ML/DL) y metodologías empleadas, el desempeño alcanzado y los contextos en los que se han aplicado en el ámbito de la agricultura de precisión.

Estimación de niveles de nutrientes en cultivos

Autores como (16), al aplicar estas tecnologías en cultivos de trigo, revelaron una fuerte correlación entre descriptores como el índice de área foliar (*leaf area index* [LAI]) y la biomasa

fresca de la masa (*fresh biomass mass* [FBM]). Los autores describen correlaciones significativas entre otros descriptores como la altura de la planta (*plant height* [PHT]) y la biomasa seca de la masa (*dry biomass* [DBM]), que son esenciales para entender las características biofísicas del dosel del trigo. A partir de sus hallazgos, sugieren la utilización de imágenes tomadas por UAV para calcular el índice de nutrición nitrogenada (*nitrogen nutrition index* [NNI]) de los trigales como métrica efectiva para estimar los niveles de nitrógeno del suelo. Esto determinaría si el trigo está pobremente fertilizado o si sufre de sobrefertilización, y ayudaría a evitar los efectos negativos asociados con ambos extremos de gestión del nitrógeno.

Asimismo, se destaca la aplicación de algoritmos de DL para el análisis de imágenes capturadas por UAV, porque ha demostrado su potencial aplicabilidad, al ofrecer información esencial que facilita la toma de decisiones en tiempo real con un margen de error mínimo; de esta manera se superan las metodologías tradicionales más fluctuantes e imprecisas (17).

Las cámaras de última generación se convierten en un actor importante, pues les brindan la posibilidad a los UAV de obtener datos relacionados con el vigor y la tasa de crecimiento de los cultivos. Entonces, la estimación precisa de los niveles de nutrientes en los cultivos es fundamental para optimizar la fertilización y mejorar la productividad agrícola de manera sostenible. La teledetección basada en UAV e IA ha emergido como una herramienta clave para el monitoreo no destructivo y a escala de campo de parámetros nutricionales, principalmente el nitrógeno (N), aunque también se abordan el fósforo (P) y el potasio (K) en ciertos cultivos (18–27).

Los índices de vegetación (*vegetation index* [VI]) derivados de imágenes multiespectrales y, en estudios más avanzados, hiperespectrales, son las características más utilizadas para estimar el estado nutricional. Se ha validado la correlación de VI como el índice de vegetación de diferencia normalizada (*normalized difference vegetation index* [NDVI]), la diferencia normalizada del borde rojo (*normalized difference red edge* [NDRE]) o índices relacionados con la clorofila (por ejemplo: *soil and plant analyzer development* [SPAD]), con el contenido de N en las hojas o en la biomasa total en diversos cultivos como arroz, trigo, maíz, vid y pastizales. Estos IV (y las bandas espectrales) se utilizan como entrada para modelar sus potenciales relaciones (posiblemente no lineales) con los parámetros nutricionales medidos en campo. Entre los más reportados en los estudios revisados se encuentran *random forest* (RF), *support vector regression* (SVM) y redes neuronales (*artificial neural network* [ANN]/ *extreme learning machine* [ELM]) (18–23). Estudios han reportado altas precisiones (valores de R^2 superiores a 0,70) en la predicción de contenido de N, P o K, así como otros indicadores como SPAD o absorción de nitrógeno (19, 21, 22). El algoritmo RF es frecuentemente destacado por su robustez y buen desempeño (18, 22, 23). La tabla 2 sintetiza los estudios más destacados.

Tabla 2. Estudios sobre estimación de niveles de nutrientes en cultivos utilizando UAV e IA

Cultivo	Indicador	Sensor UAV	Métodos IA/ML	Referencia
Arroz	SPAD, contenido de nitrógeno (N)	HS (400-1000 nm)	ANN, ELM, LASSO, SVR, MLR	(18)
Trigo	LNC	HS (400-1000 nm)	PPR, ANN, GPR-mRMR (Selección)	(28)
Trigo	LNC, PNC, LNA, PNA	CIR (NIR-G-B) <i>multi-view</i>	SVR, ELM, RF	(20)
Vid	LNC, LKC, LPC	MS (6 bandas)	PLS, RF, SVM, ELM	(21)
Maíz, soya, alfalfa	VWC, EC (Suelo)	MS (5 bandas) + GPR/EM	RF	(27)
Sorgo	Contenido de nitrógeno (N %)	RGB	MLR, MLP, CNN, IA Híbrida/Ensamble (MLP+CNN)	(29)
Cítricos	LNC	Multiespectral (MS) + Textura (LBP)	Regresión cooperativa semisupervisada (Ridge, SVR, RF), BPNN, PLSR	(20)
Arroz	LNC	Multisensores (RGB + MS), fusión (método GS)	LR, GPR, GPR+mRMR (selección de características.)	(30)
Trigo	LNC, SPAD	Hiperespectral (HS, 400-1000 nm)	ANN, ELM, LASSO, SVR, MLR	(18)

HS: *hiperespectral*; MS: *multiespectral*, RGB: *red, green, blue*; CIR: *color infrared*; SPAD: *soil and plant analyzer development*; LNC: *leaf nitrogen content*; PNC: *plant nitrogen content*; LNA: *leaf nitrogen accumulation*; PNA: *plant nitrogen accumulation*; LKC: *leaf potassium content*; LPC: *leaf phosphorus content*; VWC: *volumetric water content*; EC: *electrical conductivity*; N %: *porcentaje de nitrógeno*; LBP: *local binary pattern*; ANN: *artificial neural network*; ELM: *extreme learning machine*; LASSO: *least absolute shrinkage and selection operator*; SVR: *support vector regression*; MLR: *multiple linear regression*; PPR: *projection pursuit regression*; GPR: *gaussian process regression*; mRMR: *minimum redundancy maximum relevance*; RF: *random forest*; MLP: *multilayer perceptron*; CNN: *convolutional neural network*.

Si bien los VI espectrales son informativos, presentan limitaciones, particularmente la saturación en etapas avanzadas de crecimiento o con alta densidad de cultivo, lo cual reduce su sensibilidad a variaciones en el contenido de nutrientes en esos escenarios (18, 20). Para superar esto, la incorporación de características estructurales del cultivo, como la altura o la cobertura del dosel (derivadas de imágenes *red, green, blue* [RGB] o datos 3D como LiDAR), ha

Tabla 3. Cámaras y sensores utilizados por UAV en la estimación de niveles de fertilización y crecimiento

Tipo de cámara	Cultivo	Fertilizante estudiado	Índice calculado	Referencia
Multiespectral	Trigo	Nitrógeno	Índice de área foliar (LAI) y materia seca foliar (LDM)	(32)
RGB	Sorgo	Nitrógeno	VI (basados en color/verde)	(29)
Hiperespectral	Trigo	Nitrógeno (LNC)	VI (espectrales/hiperespectrales)	(28)
Multiespectral	Cítricos	N, P, K (LNC, LKC, LPC)	LNC + Textura	(20)
Multiespectral	Vid	N, P, K (LNC, LKC, LPC)	VI (espectrales)	(21)

demostrado mejorar la precisión de la estimación, especialmente para la biomasa y parámetros relacionados con N (Nitrógeno) como N % o Nup (N uptake [absorción de nitrógeno]) (23–26). Los enfoques de fusión de datos multimodales, que combinan información espectral con características estructurales, texturales o de otro tipo (térmicas, topográficas), procesados a menudo con técnicas de DL, se perfilan como métodos más robustos y precisos, capaces de capturar relaciones complejas y mitigar los efectos del fondo del suelo o la saturación (22,24–26). La fusión de datos provenientes de diferentes bandas espectrales (por ejemplo: visible, *red-edge*, NIR near InfraRed spectroscopy) o incluso de dominios espectrales distintos (por ejemplo: visible/near infrared spectroscopy [NIR] con *short-wavelength infrared* [SWIR]) también es explorada para mejorar la sensibilidad y superar las limitaciones de las bandas tradicionales para detectar ciertos nutrientes (31).

El análisis de la literatura en estimación de nutrientes mediante UAV e IA demuestra un avance significativo, con precisiones considerables en diversos cultivos y contextos. La tabla 3 presenta una síntesis de los estudios más destacados desde el punto de vista del tipo de cámara utilizado. Sin embargo, persisten desafíos que limitan la implementación práctica y la generalización de los modelos: (i) la saturación de los VI implica explorar características estructurales o el uso de bandas espectrales alternativas; (ii) la complejidad en la adquisición y procesamiento de datos multimodales (por ejemplo: alineación geométrica, calibración radiométrica) y la necesidad de datos de campo extensos y precisos para el entrenamiento y validación de modelos; (iii) la transferibilidad de los modelos a diferentes variedades de cultivo, etapas de crecimiento, condiciones ambientales y tipos de suelo. Aunque se han logrado avances, la estandarización de metodologías, la mejora en la robustez de los modelos ante la variabilidad contextual y la reducción de la necesidad de datos de campo intensivos son áreas clave para futuras investiga-

ciones que faciliten la adopción a gran escala de estas tecnologías para la gestión de nutrientes en agricultura de precisión.

Estimación de biomasa

La estimación precisa de la biomasa aérea (*above-ground biomass* [AGB]) y la predicción del rendimiento (Yield) son aplicaciones cruciales en la agricultura de precisión, donde la teledetección basada en UAV e IA ha mostrado un potencial significativo (22–26,31,33,34). Los estudios primarios revisados en esta categoría exploran diversas combinaciones de plataformas UAV, tipos de sensores y algoritmos de IA.

En este panorama, el LAI ha emergido como una variable clave en la estimación no destructiva de biomasa aérea, al capturar aspectos estructurales del dosel que están asociados a la acumulación de materia vegetal. Estudios recientes en de maíz, papa y cítricos han demostrado que el LAI puede estimarse con alta precisión a partir de imágenes UAV, mediante el uso de modelos como RF, SVR o técnicas de regresión multivariada, alcanzando valores de R^2 superiores a 0,80 (35–37). Estas investigaciones destacan el potencial de combinar información espectral, textural y morfológica con algoritmos de aprendizaje automático para representar la dinámica foliar a lo largo del ciclo del cultivo; así se obtiene una estimación más robusta de la biomasa.

Por otro lado, en sistemas agrícolas diversos como quinua, pasturas y campos salinizados, se ha explorado el uso del LAI como vínculo entre características espectrales complejas y variables productivas o de calidad, como la materia seca o el contenido de nitrógeno (38–40). En estos contextos, la aplicación de sensores multiespectrales e hiperespectrales (incluyendo bandas VNIR y SWIR (subregión del espectro de longitud de onda electromagnética), junto con técnicas de selección de variables y fusión de datos, ha demostrado ser eficaz para capturar la heterogeneidad del dosel vegetal (41). Estos hallazgos refuerzan el papel del LAI como variable puente en los modelos de estimación de biomasa, a partir del cual se generan predicciones más detalladas, adaptables a distintas condiciones de manejo y escalables en parcela o cultivo.

Los VI derivados de imágenes multiespectrales son quizás las variables más utilizadas, como entradas para los modelos de predicción de biomasa y rendimiento (22,32–34). Por ejemplo, (32) demostraron que la combinación de NDVI con RF fue efectiva para predecir el rendimiento en trigo ($R^2 = 0,78$), mientras que (33) lograron una alta precisión ($R^2 = 0,9$) en la predicción de rendimiento en algodón, con el uso de características de dosel e índices de vegetación con un modelo de red neuronal artificial. Sin embargo, varios estudios señalan una limitación clave de los VI: tienden a saturarse en etapas de crecimiento avanzadas o con alta densidad de cultivo, lo que reduce su precisión para estimar alta biomasa (26,31,34).

Para mitigar la limitación de la saturación de los VI, la incorporación de características estructurales del cultivo (como altura o cobertura del dosel) ha demostrado ser crucial. Estudios como el de (34) en centeno y de (23) en pastizales confirmaron que la inclusión de altura y cobertura mejoró significativamente la precisión de la estimación de biomasa, en comparación con el uso exclusivo de VI. Estas características estructurales, a menudo derivadas de modelos 3D generados por fotogrametría de imágenes RGB o, en estudios más avanzados, de datos LiDAR (25, 26), son menos susceptibles a la saturación y proporcionan información complementaria valiosa sobre la arquitectura del dosel.

La fusión multimodal (*multimodal function* [MMF]) que combina datos espectrales, estructurales y, en algunos casos, térmicos, ha demostrado optimizar la precisión y robustez de la estimación de biomasa y la predicción de rendimiento, sobre todo en contextos agrícolas complejos o con terrenos irregulares. Por ejemplo, (24) propusieron un modelo MMF con aprendizaje multitarea (MTL) que fusiona VI con características de imagen RGB para predecir simultáneamente LAI (*leaf area index*), AGB (*above-ground biomass*), PH (*plant height*) y LCC (*leaf chlorophyll content*) en trigo con acolchado, superando las limitaciones del fondo del suelo. Asimismo, (25) mostraron que la fusión de datos multiespectrales, térmicos, estructurales y topográficos mejoró la predicción de AGB en trigo en terrenos ondulados.

El uso de DL, particularmente redes neuronales convolucionales (*convolutional neural network* [CNN]) y modelos de fusión híbrida que integran imágenes 2D con nubes de puntos 3D, ha demostrado un potencial superior para extraer características complejas y capturar relaciones no lineales, con altas precisiones en la predicción de AGB como resultado (22, 26). Aunque el estudio de (42) en acuicultura de *kelp* también explora el uso de UAV, detección espectral e IA para biomasa, resalta desafíos de costos e infraestructura, aplicables también a la agricultura terrestre a gran escala. La exploración de nuevas longitudes de onda, como las del dominio VNIR/SWIR, también señala potencial para superar la saturación y mejorar la estimación de biomasa y nitrógeno (31).

La síntesis de los estudios primarios revisados en esta categoría revela una sólida capacidad de las tecnologías UAV e IA para la estimación de biomasa aérea y la predicción de rendimiento en diversos cultivos. Se observa una clara tendencia hacia el empleo de sensores multiespectrales y RGB, a menudo complementados con datos estructurales obtenidos mediante fotogrametría a partir de imágenes RGB. Los algoritmos de aprendizaje automático tradicionales como RF y SVM registran un buen desempeño, aunque las técnicas de *deep learning* (CNN, fusión multimodal) muestran un potencial superior, sobre todo al integrar múltiples fuentes de datos y trabajar con grandes volúmenes de imágenes. Sin embargo, el análisis crítico de estos hallazgos también pone de manifiesto desafíos persistentes. La saturación de los índices de ve-

getación en etapas de crecimiento avanzadas o con alta densidad de cultivo sigue siendo una limitación significativa para la estimación precisa (26,31,34). La complejidad del procesamiento de datos multimodales y de fuentes como LiDAR o nubes de puntos, aunque mejora la precisión, representa una barrera para la implementación a gran escala (25,26). Adicionalmente, la variabilidad en el desempeño de los modelos entre diferentes cultivos, etapas de crecimiento, condiciones ambientales y contextos geográficos (22,25,34).

Predicción de rendimiento

La predicción precisa del rendimiento de los cultivos es una tarea crucial para la agricultura de precisión; además, les facilita a los agricultores optimizar la gestión de insumos, planificar la cosecha y la logística, y tomar decisiones informadas para maximizar la rentabilidad. Los métodos tradicionales para este propósito, a menudo basados en muestreos destructivos o evaluaciones visuales, son laboriosos, costosos y no siempre evidencian la variabilidad espacial dentro de un campo. La integración de vehículos aéreos no tripulados (UAV) equipados con diversos sensores y técnicas avanzadas de visión por computador e inteligencia artificial (IA) ofrece una alternativa potente para obtener predicciones de rendimiento no destructivas y a alta resolución.

Los estudios recientes han explorado diversas aproximaciones para predecir el rendimiento utilizando datos de UAV e IA en una variedad de cultivos, desde cereales y leguminosas hasta frutales y hortalizas. Estos trabajos varían en los tipos de sensores empleados, las características de imagen y otros datos integrados, los algoritmos de IA/ML aplicados y la escala de la predicción (en planta, parcela o campo). Un objetivo común es aprovechar la capacidad de los UAV para capturar información detallada sobre el estado del cultivo que se correlacione con el rendimiento final.

Estudios recientes señalan el potencial de UAV e IA para la predicción de rendimiento. Se observan diversas estrategias técnicas. Por ejemplo, (43) combinaron VI y fracción vegetada de UAV con ANN para estimar rendimiento en viñedo; así, lograron $RMSE = 0,5 \text{ kg/vid}$ y $RE = 12,1\%$ con ANN al fusionar VI y Fc. Para trigo, (44) fusionaron datos multisensor (RGB, MS, TIR) con un ensamble ML (*stacking ensemble using ridge regression [StRR]*), obteniendo $R^2 = 0,692$ y $RMSE = 0,916 \text{ t/ha}$, con lo cual superaron modelos individuales. En la tabla 4 se presenta una síntesis de estudios sobre predicción de rendimiento de cosechas.

Integrar UAV con modelos de simulación también es viable: (45) asimilaron LAI de UAV en WO-FOST mediante 4DVAR para col; de esta manera, se redujo el RMSE de rendimiento (1314-2532 kg/ha sin asimilación vs. 1314-2498 kg/ha con asimilación). (46) emplearon regresión

Tabla 4. Estudios sobre predicción de rendimiento mediante UAV e IA

Viñedo/rendimiento	Multiespectral	VI, fracción vegetada (Fc)	ANN	1,0 (validación)	0,5 kg/viad/12,1 %	(43)
Trigo/rendimiento	Multisensor (RGB, MS, TIR)	VI (espectrales), textura (TIR), modelos climáticos	ML (Cubist, SVM, DNN, RR, RF), ensamble (<i>stacking</i>)	0,692	0,916 t/ha	(44)
Soja/rendimiento	Multitemporal RGB	Imágenes RGB (multitemporales, 3D), rasgos profundos	DL (3D CNN - VGG, Res-Net, DenseNet)	0,70 (mejor)	NRMS E 10,08 % (mejor)	(?)
Col (<i>cabbage</i>)/rendimiento	RGB, multiespectral	LAI (estimado por modelo de segmentación)	Modelos de simulación (WOFOST) + Asimilación de datos (4DVAR)		RMSE 1314-2532 kg/h a/rR MSE 15,8-30,9 %	(45)
Trigo/rendimiento, rasgos (CMT, TKW, Gnm2)	Hiperespectral	Datos espectrales (curvas de reflectancia funcional)	Regresión funcional	-	MAE 13,42 %/RM SE 869,20 kg/ha	(46)
Algodón/rendimiento	Multiaño UAV (MS, RGB) + Suelo (ECa) + Clima	Datos fusionados (suelo, clima, NDVI de UAV) procesados por CNN	DL (CNN + GRU)	0,72-0,84	MAE 247-384 kg /ha/ Error 8,9-13,7 %	(47)

CM: *cellular membrane thermostability*; CMT: *cellular membrane thermostability*; DL: *deep learning*; ECa: *electrical conductivity apparent*; GRU: *gated recurrent unit*; LAI: *leaf area index*; MAE: *mean absolute error*; ML: *machine learning*; MS: *multispectral*; NRMSE: *normalized root mean square error*; RE: *relative error*; RGB: *red green blue*; RMSE: *root mean square error*; UAV: *unmanned aerial vehicle*; VI: *vegetation index*.

Nota: la métrica R^2 de 1,0 indicada en (43) corresponde a los resultados en la validación, no en el conjunto de prueba final.

funcional (Sigcomp) en datos hiperespectrales de UAV para predecir rendimiento de trigo, lo cual arrojó MAPE 13,42 % y RMSE = 869,20 kg/ha, efectivo con datos reducidos. (47) fusionaron datos multíaño de UAV (MS, RGB), suelo (ECa) y clima con DL (CNN + GRU) para predecir rendimiento de algodón; esto evidenció errores medio (MAE) del 8,9 % al 13,7 % en un año fuera del entrenamiento. La robustez y precisión varían según el cultivo, sensor, características y modelo, pero la fusión de datos y el uso de algoritmos ML/DL avanzados (ANN, ensamble, 3D CNN) son tendencias clave para optimizar la predicción de rendimiento.

Detección y manejo de plagas, enfermedades y malezas

La integración de UAV con cámaras multiespectrales e hiperespectrales en la agricultura inteligente ha revolucionado la detección temprana de plagas; lo cual permite una respuesta rápida y precisa en el manejo de cultivos. Gracias a la combinación de tecnología de visión por computador y soluciones de IA, es posible identificar patógenos como hongos, insectos, bacterias, virus y especies invasoras; así, se proporciona un enfoque proactivo y eficiente en la gestión de la salud del cultivo (48).

A partir de estas generalidades, en el estudio de (49), se destaca la aplicación de UAV para la aspersión precisa de insecticidas y acaricidas, centrada en optimizar el control de plagas. Los autores examinan cómo factores como el tamaño de gota, las condiciones meteorológicas y los métodos de aplicación influyen en la deriva de aspersión, esenciales para calibrar la eficacia de estas intervenciones. Además, se subraya la capacidad de los UAV equipados con cámaras multiespectrales e hiperespectrales para detectar estrés en las plantas, tanto abiótico (sequía, deficiencias de nutrientes) como biótico (patógenos, nematodos, malezas) (50, 53). El trabajo de (54) se centra en la detección de una enfermedad específica en cacahuete: el tizón del sur, a través de imágenes multiespectrales de UAV. Proponen un método que combina VI con índices texturales (*textural indices* [TI]) construidos a partir de rasgos texturales originales. Mediante algoritmos como KNN, PSO-SVM y AdaBoost, encontraron que la combinación de VI y TI, particularmente con el modelo KNN, logra una alta precisión (91,89 %) y puntaje F1 (91,39 %) en el conjunto de prueba. Esto subraya la importancia de integrar tanto la información espectral como la textural para una detección más precisa de enfermedades.

La detección de otra enfermedad del trigo, la sarna, es abordada por (55), a través de imágenes RGB de UAV. Este estudio propone una arquitectura de red neuronal profunda personalizada (ASFFNet, basada en YOLOv5) que incluye mejoras de contraste y fusión adaptativa espacial de rasgos. Según los resultados, este método logra una alta precisión media (AP) del 80,8 %, lo cual supera a otros detectores de objetos DL. La innovación radica en la capacidad de ASFFNet para detectar manchas pequeñas de enfermedad al adaptar la fusión de característi-

cas a diferentes escalas, lo cual es crucial dado el pequeño tamaño de las lesiones de sarna en las imágenes.

La aplicabilidad a una gama más amplia de problemas fitosanitarios es explorada en (56), a través de modelos de ML (SVM, RF, AdaBoost, Naive Bayes) aplicados a la gestión fitosanitaria. No obstante, la información específica sobre el uso de UAV, como fuente de datos primarios para la predicción directa de enfermedades en su estudio, no se detalla en los fragmentos revisados. En la tabla 5 se sintetizan estudios relevantes sobre detección y manejo de plagas mediante UAV e IA.

Estudios más específicos sobre la detección de enfermedades foliares en arroz, como el de (57), demuestran la efectividad de adaptar arquitecturas DL existentes, como Tiny YOLOv4, para la detección de manchas de enfermedad foliar (*bacterial leaf blight, rice blast, brown spot*). Mediante la adición de módulos específicos y el entrenamiento con un *dataset* personalizado, lograron una alta precisión media (AP 86 %), destacando la importancia de la arquitectura de red optimizada para objetos pequeños en imágenes UAV y la calidad del conjunto de datos.

La detección de enfermedades en arándanos silvestres (*Monilinia blight, Botrytis blight*) y la identificación de fenotipos susceptibles es abordada por (60). Con imágenes multiespectrales de UAV y, potencialmente, datos LiDAR, junto con VI y rasgos fenológicos, aplicaron métodos ML y clasificación supervisada (LDA, SVM). Sus hallazgos indican que los VI, en particular en la región NIR, y los rasgos fenológicos son discriminatorios para identificar enfermedades y fenotipos, con lo cual se obtuvo una precisión de clasificación global del 85 %.

Además de la detección directa, la evaluación de la susceptibilidad a enfermedades y la zonificación del viñedo basadas en indicadores de salud son objeto de estudio en (58). En este estudio se recurre a imágenes RGB+NIR (multiespectrales) de UAV y datos de campo de nutrientes (N, P, K foliar y peciolo). Los autores trabajan el algoritmo YOLO para la detección precisa de vides (90 % de precisión), lo cual sirve como base para la zonificación utilizando *K-means*. Al integrar NDVI, contenido de nutrientes y coordenadas de ubicación en el proceso de *clustering*, logran definir zonas de manejo homogéneas que reflejan diferencias en el estado de salud; a su vez, proporcionan una herramienta valiosa para la gestión sitio-específica del viñedo.

Finalmente, (61) proponen un sistema integrado más amplio para el monitoreo general de campos agrícolas que incluye la detección de enfermedades. Combinan datos de UAV (MS, HS, GPS) con sensores *internet of things* (IoT) ambientales en tierra, fusionando esta información para alimentar un modelo de aprendizaje automático híbrido (*hybrid machine learning model*

Tabla 5. Estudios relevantes sobre detección y manejo de plagas/Enfermedades mediante UAV e IA

Objetivo (cultivo/problema)	Sensor(es) UAV	Características utilizadas	Métodos IA/ML	Referencia
Cacahuete/Tizón del sur (enfermedad)	Multiespectral (MS, 5 bandas)	VI (6 seleccionados), texturales (3 TI construidos a partir de TF)	KNN, PSO-SVM, AdaBoost	(54)
Trigo/Sarna del trigo (enfermedad)	RGB	Color, rasgos profundos (ASFFNet, fusión adaptativa espacial)	DL (ASFFNet - basado en YOLOv5)	(55)
Vid/Zonificación basada en salud (relacionado con susceptibilidad/estado)	RGB+NIR (MS, 5 bandas), muestras (N, P, K foliar/peciolo)	NDVI, N, P, K (hoja/peciolo), localización (coordenadas)	YOLO (detección de vides), K-means (pesos variables)	(58)
Remolacha azucarera/ <i>Cercospora leaf spot</i> (CLS) (enfermedad)	Multiespectral (MS, 5 bandas)	VI, sombra, resolución, DSMf, parámetros de área (AF, AH, AD, etc.)	ML (PLS-DA, SVML, SVMR, RF, KNN), pipeline combinando ML	(59)
Arroz/Enfermedades foliares (<i>bacterial leaf blight, rice blast, brown spot</i>)	UAV (implícito RGB/MS)	Rasgos profundos (extraídos por Tiny YOLOv4 modificado + SPP, CBAM, SCFEM, Ghost)	DL (Tiny YOLOv4 modificado)	(57)
Arándano silvestre/Enfermedades (<i>Monilinia blight, Botrytis blight</i>), fenología, fenotipos	MSI, LiDAR (potencial)	VI, Rasgos de crecimiento/fenológicos (LAI, altura)	ML (SMLR, RF, SVM), clasificación supervisada (LDA)	(60)

DSM: *digital surface model*; TF: rasgos texturales; TI: *textural indices*; VI: *vegetation index*; ML: *machine learning*; DL: *deep learning*; UAV: *unmanned aerial vehicle*.

[HMLM]) que combina RF y SVM. Este sistema logra una precisión del 98,74 % en la clasificación general. El trabajo de (59) también contribuye a la detección de enfermedades específicas, como el *Cercospora leaf spot* en remolacha azucarera, a nivel de pixel, por medio de imágenes multiespectrales de UAV y rasgos extraídos de MS y DSM. Su *pipeline*, que combina diferentes modelos ML, logra alta precisión (86,3 % *overall*) y destaca la utilidad de los rasgos basados en DSM y los parámetros de área para diferenciar variedades y evaluar la severidad e incidencia de la enfermedad; esto constituye una alternativa automatizada a la evaluación visual por expertos. La tendencia en detección y manejo de plagas y enfermedades mediante la integración de UAV e IA, se orienta hacia enfoques que combinan múltiples fuentes de datos (imágenes UAV de diversas bandas espectrales y rasgos, datos de sensores IoT, información de ubicación

ción/DSM). Las arquitecturas de aprendizaje profundo, en especial las adaptadas para objetos pequeños o con mecanismos de atención y fusión avanzados (ASFFNet, YOLO modificado, TSLM), así como los enfoques de ensamble (HMLM, combinaciones de ML), muestran un rendimiento superior para tareas de detección y clasificación, con altas métricas de precisión y *F1-score*. Si bien la necesidad de grandes *datasets* etiquetados sigue siendo un desafío, algunos trabajos revisados exploran soluciones como el aumento de datos, los enfoques semisupervisados y el aprovechamiento del *transfer learning*. Aunque se han logrado avances notables en cultivos específicos y problemas concretos, la validación de la transferibilidad de los modelos a nuevos entornos y la optimización continua de la complejidad computacional para la implementación en tiempo real en UAV de recursos limitados siguen siendo áreas críticas para la investigación futura. La colaboración interdisciplinaria y la validación en campo a gran escala serán esenciales para traducir estos hallazgos en herramientas agrícolas prácticas y confiables.

Conteo y fenotipado básico de plantas

El conteo preciso del número de plantas individuales o de partes específicas, como plántulas, espigas o borlas, es una tarea fundamental en la agricultura de precisión y la mejora genética. Esta información es esencial para evaluar la calidad de la siembra, estimar la densidad de la población, predecir el rendimiento y tomar decisiones de manejo adaptadas a las condiciones del cultivo. La flexibilidad y la capacidad de los UAV para capturar imágenes de alta resolución a baja altitud los convierten en herramientas idóneas para obtener datos detallados en planta.

En el caso del maíz, el conteo de plántulas y borlas ha sido objeto de múltiples investigaciones. Por ejemplo, (62) compararon la detección de esquinas (Harris), la regresión lineal y el aprendizaje profundo (*Faster R-CNN*) para contar plántulas de maíz a partir de imágenes RGB de UAV. Demostraron que, aunque los tres métodos logran alta precisión (99 %), los modelos de regresión lineal y DL son más robustos a los cambios en la resolución espacial de la imagen, una consideración importante para la aplicabilidad en diferentes alturas de vuelo. La detección de esquinas, si bien precisa, se ve más afectada por la resolución.

La detección y conteo de borlas (*tassels*) de maíz también se ha beneficiado de las técnicas DL. (63) desarrollaron PConv-YOLOv8, un modelo ligero y robusto, para detectar borlas por medio de imágenes RGB tanto de UAV como cerca del suelo. Su modelo alcanzó alta precisión en la detección de borlas (AP >0,9) y un monitoreo preciso de la etapa de borla ($R^2 = 0,99$, $RMSE = 0,21$ día), además de robustez ante variaciones en resolución, variedad y etapa de crecimiento. Un enfoque diferente es el de (64), quienes propusieron IntegrateNet, una red de aprendizaje profundo multitarea que supervisa simultáneamente el aprendizaje de mapas de

densidad y mapas de conteo local para el maíz. Este modelo logró un error bajo ($MAE = 1,62$, $RMSE = 2,28$) y un alto coeficiente de determinación ($R^2 = 0,9578$) en el conjunto de prueba, superando a enfoques previos basados en mapas de densidad. Aunque también se han propuesto enfoques basados en métodos de ML clásicos como regresión SVM (65).

La aplicación de estas técnicas a otras partes de cultivos importantes se ve en el estudio de (66), quienes compararon modelos DL como Faster R-CNN, YOLOv8 y RT-DETR para la detección de espigas de trigo en imágenes RGB de UAV. Aunque YOLOv8 mostró la mayor precisión, RT-DETR tuvo un mejor equilibrio entre precisión y *recall*; asimismo, se destacan los desafíos en la detección precisa de objetos pequeños y superpuestos como las espigas. Incluso en cultivos de árboles, donde el conteo manual puede ser aún más arduo, los UAV y la IA ofrecen soluciones. Se ha utilizado una combinación de CNN y refinamiento basado en procesamiento de imagen (OBIA) para identificar y contar árboles de olivo individuales a partir de imágenes RGB de UAV. Esta aplicación alcanzó una precisión general (99 %) en la detección y conteo de árboles (67).

En conjunto, estos estudios demuestran el gran potencial de los UAV y las técnicas de visión por computador e IA para automatizar y mejorar la precisión del conteo de plantas y partes de plantas en diversos cultivos. Los avances se centran en el desarrollo de arquitecturas de aprendizaje profundo robustas, la integración de múltiples fuentes de datos y el refinamiento de los algoritmos para manejar desafíos específicos como la superposición, la variabilidad morfológica y las diferentes resoluciones espaciales.

En cuanto a las técnicas de identificación y tipificación de plantas, se destacan los avances en algoritmos de DL especializados, y en particular, las CNN. Por ejemplo, (68) describen los avances recientes en este campo, en particular de la computación e informática modernas, y expone una hoja de ruta detallada para la utilización estas técnicas en la identificación automática de plantas de pino, con una precisión más que interesante, al punto de que este trabajo fue ampliado dos años después, para reforzar el gran potencial de la utilización de CNN en monitoreo remoto con imágenes captadas por drones para actividades propias de la agricultura inteligente, tal y como se especifica en (69).

Discusión

Los resultados recopilados en esta revisión confirman que los UAV se han consolidado como herramientas fundamentales en la agricultura de precisión, y que se destacan por su capacidad de recopilar imágenes de alta resolución y por su integración versátil con sensores multispectrales, hiperespectrales, térmicos y LiDAR. Esta capacidad ha facilitado el monitoreo de

variables agronómicas críticas como el estado nutricional, el crecimiento vegetativo, la biomasa aérea (AGB) y los niveles de fertilización en diversos cultivos. Sin embargo, uno de los aportes clave de esta revisión es evidenciar la transición que han tenido las metodologías tradicionales (basadas en índices espectrales simples) hacia enfoques híbridos que incorporan modelos 3D, fusión de datos y técnicas avanzadas de aprendizaje automático y profundo (ML/DL).

En el contexto de la estimación de biomasa y predicción del rendimiento de cosechas, las técnicas basadas exclusivamente en índices de vegetación como NDVI o índice de vegetación de diferencia normalizada verde (*green normalized difference vegetation index [GNDVI]*), han mostrado limitaciones significativas frente a cultivos en etapas avanzadas o con alta densidad foliar, debido a fenómenos de saturación espectral. En contraste, la combinación de características estructurales (altura de planta, cobertura del dosel), morfológicas (textura, volumen estimado), y datos espectrales multibanda, ha demostrado ser más robusta. Modelos como *random forest* (RF) y *support vector regression* (SVR) han mostrado desempeños sólidos ($R^2 > 0,80$ en varios estudios); aunque son los enfoques basados en redes neuronales convolucionales (CNN), LSTM o arquitecturas híbridas con mecanismos de atención los que actualmente dominan el panorama metodológico, debido a su capacidad para aprender representaciones jerárquicas complejas.

De hecho, mientras algunos estudios recientes han logrado predicciones de rendimiento con RM-SE inferiores a 1 t/ha en trigo mediante el uso de *stacking ensembles* que combinan múltiples modelos (por ejemplo: Cubist, DNN, RF), otros han alcanzado niveles similares de precisión por medio de CNN alimentadas con datos RGB multitemporales y morfología 3D, como en el caso de la soja. Asimismo, modelos multivariados aplicados a datos hiperespectrales han evidenciado ser efectivos para estimar simultáneamente variables como LAI, contenido de nitrógeno y biomasa, lo que favorece una integración agronómica más completa. No obstante, la implementación práctica de estos sistemas enfrenta aún importantes barreras, como son: la necesidad de grandes volúmenes de datos de entrenamiento en campo, la baja transferibilidad de los modelos a diferentes ambientes y cultivos, y la alta demanda computacional asociada a arquitecturas DL complejas.

Adicionalmente, la revisión muestra cómo la fusión multimodal de sensores (combinando UAV con estaciones IoT en tierra o con imágenes satelitales) permite mejorar la generalización de los modelos, sobre todo en escenarios de variabilidad topográfica o climática. Sin embargo, dicha integración introduce retos técnicos como la sincronización temporal, la calibración geométrica cruzada y el tratamiento del desbalance entre datos espectrales y estructurales. En este sentido, los modelos de aprendizaje multitarea y las redes neuronales con mecanismos de atención adaptativa se posicionan como líneas prometedoras para abordar esta complejidad y reducir el costo de adquisición de datos en campo.

Conclusiones

Los avances recientes en el uso de vehículos aéreos no tripulados (*unmanned aerial vehicle* [UAV]) combinados con inteligencia artificial (IA) son una alternativa para transformar prácticas agrícolas tradicionales mediante monitoreo no destructivo, optimización del uso de insumos y una mayor precisión en la toma de decisiones. A través de esta revisión se identificó que, más allá de los índices tradicionales como índice de vegetación de diferencia normalizada (*normalized difference vegetation index* [NDVI]), los enfoques que combinan múltiples tipos de características (espectrales, estructurales y texturales), junto con modelos avanzados de aprendizaje automático, se aporta a la precisión en la estimación de variables críticas como biomasa, contenido de nutrientes y rendimiento de las cosechas. La integración de sensores hiperespectrales, térmicos y LiDAR ha llevado a superar algunas limitaciones clásicas como la saturación espectral en cultivos densos o en etapas avanzadas de desarrollo. Sin embargo, el verdadero impacto de estas tecnologías no se medirá únicamente en función de sus métricas de precisión, sino en su capacidad para ser apropiadas, replicadas y sostenidas en contextos reales y diversos.

En este sentido, la transición hacia una agricultura verdaderamente precisa e inteligente requiere ir más allá del despliegue de tecnologías avanzadas; supone construir sistemas abiertos, inclusivos y orientados al bien común. Será fundamental democratizar el acceso a datos de entrenamiento y validación, fomentar estándares abiertos para la interoperabilidad de plataformas UAV, y diseñar soluciones tecnológicas pensadas desde y para los agricultores, especialmente aquellos que enfrentan limitaciones económicas o geográficas. Solo así se logrará una adopción tecnológica equitativa, capaz de combinar el potencial del aprendizaje automático con los saberes locales y las dinámicas agroecológicas del territorio.

Referencias

- [1] D. W. James, y K. L. Wells, *Soil sample collection and handling: technique based on source and degree of field variability*, Hoboken, NJ: John Wiley & Sons, 1990, pp. 25-44.
- [2] M. B. Stuart, A. J. S. McGonigle, y J. R. Willmott, "Hyperspectral imaging in environmental monitoring: a review of recent developments and technological advances in compact field deployable systems", *Sensors*, vol. 19, n.º 1414, p. 3071, en. 2019.
- [3] S. Khanal, K. C. Kushal, J. P. Fulton, *et al.*, "Remote sensing in agricultura— Accomplishments, limitations, and opportunities", *Remote Sensing*, vol. 12, n.º 22, p. 3783, nov. 2020.

- [4] Y. Ge, G. Bai, V. Stoerger, *et al.*, "Temporal dynamics of maize plant growth, water use, and leaf water content using automated high throughput RGB and hyperspectral imaging", *Computers and Electronics in Agriculture*, vol. 127, pp. 625–632, sep. 2016. Disponible en <https://www.sciencedirect.com/science/article/pii/S0168169916305464>
- [5] E. Salamí, C. Barrado, y E. Pastor, "UAV flight experiments applied to the remote sensing of vegetated areas", *Remote Sensing*, vol. 6, n.º 11, pp. 11051–11081, nov. 2014. Disponible en <https://www.mdpi.com/2072-4292/6/11/11051>
- [6] H. Yao, R. Qin, y X. Chen, "Unmanned aerial vehicle for remote sensing applications—A review", *Remote Sensing*, vol. 11, n.º 1212, p. 1443, en. 2019.
- [7] G. Pajares, "Overview and current status of remote sensing applications based on unmanned aerial vehicles (UAVs)", *Photogrammetric Engineering Remote Sensing*, vol. 81, n.º 4, pp. 281–329, abr. 2015.
- [8] I. Colomina, y P. Molina, "Unmanned aerial systems for photogrammetry and remote sensing: a review", *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 92, pp. 79–97, jun. 2014.
- [9] P. Daponte, L. De Vito, L. Glielmo, *et al.*, "A review on the use of drones for precision agriculture", *IOP Conference Series: Earth and Environmental Science*, vol. 275, n.º 1, p. 012022, my. 2019. Disponible en <https://dx.doi.org/10.1088/1755-1315/275/1/012022>
- [10] J. Xue, y B. Su, "Significant remote sensing vegetation indices: a review of developments and applications", *Journal of Sensors*, vol. 2017, n.º 1, p. 1353691, en. 2017. Disponible en <https://onlinelibrary.wiley.com/doi/abs/10.1155/2017/1353691>
- [11] X. Zhang, F. Zhang, Y. Qi, *et al.*, "New research methods for vegetation information extraction based on visible light remote sensing images from an unmanned aerial vehicle (UAV)", *International Journal of Applied Earth Observation and Geoinformation*, vol. 78, pp. 215–226, jun. 2019. Disponible en <https://linkinghub.elsevier.com/retrieve/pii/S0303243418306305>
- [12] R. Vidican, A. Mălinăs, O. Ranta, *et al.*, "Using remote sensing vegetation indices for the discrimination and monitoring of agricultural crops: a critical review", *Agronomy*, vol. 13, n.º 12, p. 3040, dic. 2023. Disponible en <https://www.mdpi.com/2073-4395/13/12/3040>
- [13] D. Radočaj, A. Šiljeg, R. Marinović, *et al.*, "State of major vegetation indices in precision agriculture studies indexed in Web of Science: a review", *Agriculture*, vol. 13, n.º 3, p. 707, mzo. 2023. Disponible en <https://www.mdpi.com/2077-0472/13/3/707>

- [14] J. G. A. Barbedo, "A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses", *Drones*, vol. 3, n.º 2, p. 40, jun. 2019. Disponible en <https://www.mdpi.com/2504-446X/3/2/404>
- [15] S. Gokool, M. Mahomed, R. Kunz, *et al.*, "Crop monitoring in smallholder farms using unmanned aerial vehicles to facilitate precision agriculture practices: a scoping review and bibliometric analysis", *Sustainability*, vol. 15, n.º 4, p. 3557, en. 2023. Disponible en <https://www.mdpi.com/2071-1050/15/4/3557>
- [16] M. Schirrmann, A. Giebel, F. Gleiniger, *et al.*, "Monitoring agronomic parameters of winter wheat crops with low-cost UAV imagery", *Remote Sensing*, vol. 8, n.º 99, p. 706, sep. 2016. <https://doi.org/10.3390/rs8090706>
- [17] J. Wu, D. Zheng, Z. Wu, *et al.*, "Prediction of buckwheat maturity in UAV-RGB images based on recursive feature elimination cross-validation: a case study in Jinzhong, northern China", *Plants*, vol. 11, n.º 2323, p. 3257, en. 2022. Disponible en <https://doi.org/10.3390/plants11233257>
- [18] S. B. Khose, y D. R. Mailapalli, "UAV-based multispectral image analytics and machine learning for predicting crop nitrogen in rice", *Geocarto International*, vol. 39, n.º 1, en. 2024. Disponible en <https://doi.org/10.1080/10106049.2024.2373867>
- [19] R. N. Sahoo, R. G. Rejith, S. Gakhar, *et al.*, "Drone remote sensing of wheat N using hyperspectral sensor and machine learning", *Precision Agriculture*, vol. 25, n.º 2, pp. 704–728, abr. 2024. Disponible en <https://doi.org/10.1007/s11119-023-10089-7>
- [20] N. Lu, Y. Wu, H. Zheng, *et al.*, "An assessment of multi-view spectral information from UAV-based color-infrared images for improved estimation of nitrogen nutrition status in winter wheat", *Precision Agriculture*, vol. 23, n.º 5, pp. 1653–1674, oct. 2022.
- [21] X. Peng, D. Chen, Z. Zhou, *et al.*, "Prediction of the nitrogen, phosphorus and potassium contents in grape leaves at different growth stages based on UAV multispectral remote sensing", *Remote Sensing*, vol. 14, n.º 11, jun. 2022.
- [22] H. Zha, Y. Miao, T. Wang, *et al.*, "Improving unmanned aerial vehicle remote sensing-based rice nitrogen nutrition index prediction with machine learning", *Remote Sensing*, vol. 12, n.º 2, en. 2020.
- [23] U. Lussem, A. Bolten, I. Kleppert, *et al.*, "Herbage mass, N concentration, and N uptake of temperate grasslands can adequately be estimated from UAV-based image data using machine learning", *Remote Sensing*, vol. 14, n.º 13, jul. 2022.

- [24] Z. Cheng, X. Gu, Y. Du, et al., "Multi-modal fusion and multi-task deep learning for monitoring the growth of film-mulched winter wheat", *Precision Agriculture*, vol. 25, n.º 4, pp. 1933–1957, ag. 2024.
- [25] S.-H. Zhang, L. He, J.-Z. Duan, et al., "Aboveground wheat biomass estimation from a low-altitude UAV platform based on multimodal remote sensing data fusion with the introduction of terrain factors", *Precision Agriculture*, vol. 25, n.º 1, pp. 119–145, feb. 2024.
- [26] S. Zhu, W. Zhang, T. Yang, et al., "Combining 2D image and point cloud deep learning to predict wheat above ground biomass", *Precision Agriculture*, vol. 25, n.º 6, pp. 3139–3166, dic. 2024.
- [27] Y. Guan, K. Grote, J. Schott, et al., "Prediction of soil water content and electrical conductivity using random forest methods with UAV multispectral and ground-coupled geophysical data", *Remote Sensing*, vol. 14, n.º 4, feb. 2022.
- [28] R. N. Sahoo, S. Gakhar, R. Rejith, et al., "Unmanned aerial vehicle (UAV)-based imaging spectroscopy for predicting wheat leaf nitrogen", *Photogrammetric Engineering & Remote Sensing*, vol. 89, n.º 2, pp. 107–116, feb. 2023.
- [29] H. Hammouch, S. Patil, S. Choudhary, et al., "Hybrid-AI and model ensembling to exploit UAV-based RGB imagery: an evaluation of sorghum crop's nitrogen content", *Agriculture-Basel*, vol. 14, n.º 10, oct. 2024.
- [30] S. Xu, X. Xu, Q. Zhu, et al., "Monitoring leaf nitrogen content in rice based on information fusion of multi-sensor imagery from UAV", *Precision Agriculture*, vol. 24, n.º 6, pp. 2327–2349, dic. 2023.
- [31] A. Jenal, H. Hueging, H. E. Ahrends, et al., "Investigating the potential of a newly developed UAV-mounted VNIR/SWIR imaging system for monitoring crop traits-a case study for winter wheat", *Remote Sensing*, vol. 13, n.º 9, my. 2021.
- [32] Z. Fu, J. Jiang, Y. Gao, et al., "Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle", *Remote Sensing*, vol. 12, n.º 3, p. 508, en. 2020. Disponible en <https://www.mdpi.com/2072-4292/12/3/508>
- [33] A. Ashapure, J. Jung, A. Chang, et al., "Developing a machine learning based cotton yield estimation frame-work using multi-temporal UAS data", *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 169, pp. 180–194, nov. 2020.
- [34] K. C. Kushal, M. Romanko, A. Perrault, et al., "On-farm cereal rye biomass estimation using machine learning on images from an unmanned aerial system", *Precision Agriculture*, vol. 25, n.º 5, pp. 2198–2225, oct. 2024.

- [35] M. Bian, Z. Chen, Y. Fan, et al., "Integrating spectral, textural, and morphological data for potato LAI estimation from UAV images", *Agronomy-Basel*, vol. 13, n.º 12, dic. 2023.
- [36] Q. Cheng, F. Ding, H. Xu, et al., "Quantifying corn LAI using machine learning and UAV multispectral imaging", *Precision Agriculture*, vol. 25, n.º 4, pp. 1777–1799, ag. 2024.
- [37] X. Lu, W. Li, J. Xiao, et al., "Inversion of leaf area index in citrus trees based on multi-modal data fusion from UAV platform", *Remote Sensing*, vol. 15, n.º 14, jul. 2023.
- [38] J. Jiang, K. Johansen, C. S. Stanschewski, et al., "Phenotyping a diversity panel of quinoa using UAV-retrieved leaf area index, SPAD-based chlorophyll and a random forest approach", *Precision Agriculture*, vol. 23, n.º 3, pp. 961–983, jun. 2022.
- [39] R. A. Oliveira, R. Naesi, P. Korhonen, et al., "High-precision estimation of grass quality and quantity using UAS-based VNIR and SWIR hyperspectral cameras and machine learning", *Precision Agriculture*, vol. 25, n.º 1, pp. 186–220, febr. 2024.
- [40] R. Mukhamediev, Y. Amirkaliyev, Y. Kuchin, et al., "Operational mapping of salinization areas in agricultural fields using machine learning models based on low-altitude multispectral images", *Drones*, vol. 7, n.º 6, jun. 2023.
- [41] Y. Gan, Q. Wang, T. Matsuzawa, et al., "Multivariate regressions coupling colorimetric and textural features derived from UAV-based RGB images can trace spatiotemporal variations of LAI well in a deciduous forest", *International Journal of Remote Sensing*, vol. 44, n.º 15, pp. 4559–4577, ag. 2023.
- [42] T. W. Bell, N. J. Nidzieko, D. A. Siegel, et al., "The utility of satellites and autonomous remote sensing platforms for monitoring offshore aquaculture farms: a case study for canopy forming kelps", *Frontiers in Marine Science*, vol. 7, dic. 2020. Disponible en <https://www.frontiersin.org/journals/marine-science/articles/10.3389/fmars.2020.520223/full>
- [43] R. Ballesteros, D. S. Intrigliolo, J. F. Ortega, et al., "Vineyard yield estimation by combining remote sensing, computer vision and artificial neural network techniques", *Precision Agriculture*, vol. 21, n.º 6, pp. 1242–1262, dic. 2020.
- [44] S. Fei, M. A. Hassan, Y. Xiao, et al., "UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat", *Precision Agriculture*, vol. 24, n.º 1, pp. 187–212, febr. 2023.
- [45] Y. Yokoyama, A. de Wit, T. Matsui, et al., "Accuracy and robustness of a plant-level cabbage yield prediction system generated by assimilating UAV-based remote sensing data into a crop simulation model", *Precision Agriculture*, vol. 25, n.º 6, pp. 2685–2702, dic. 2024.

- [46] L. Costa, J. McBreen, Y. Ampatzidis, et al., "Using UAV-based hyperspectral imaging and functional regression to assist in predicting grain yield and related traits in wheat under heat-related stress environments for the purpose of stable yielding genotypes", *Precision Agriculture*, vol. 23, n.º 2, pp. 622–642, abr. 2022.
- [47] A. Feng, J. Zhou, E. Vories, et al., "Prediction of cotton yield based on soil texture, weather conditions and UAV imagery using deep learning", *Precision Agriculture*, vol. 25, n.º 1, pp. 303–326, febr. 2024.
- [48] E. C. Tetila, B. B. Machado, G. Astolfi, et al., "Detection and classification of soybean pests using deep learning with UAV images", *Computers and Electronics in Agriculture*, vol. 179, art. 105836, dic. 2020. Disponible en <https://linkinghub.elsevier.com/retrieve/pii/S016816991831055X>
- [49] F. H. Iost Filho, W. B. Heldens, Z. Kong, et al., "Drones: innovative technology for use in precision pest management", *Journal of Economic Entomology*, vol. 113, n.º 1, pp. 1–25, febr. 2020.
- [50] M. Darbyshire, S. Coutts, P. Bosilj, et al., "Review of weed recognition: a global agriculture perspective", *Computers and Electronics in Agriculture*, vol. 227, n.º 1, dic. 2024.
- [51] J. Kaivosoja, J. Hautsalo, J. Heikkinen, et al., "Reference measurements in developing UAV systems for detecting pests, weeds, and diseases", *Remote Sensing*, vol. 13, n.º 7, abr. 2021.
- [52] R. Rosle, N. N. Che'Ya, Y. Ang, et al., "Weed detection in rice fields using remote sensing technique: a review", *Applied Sciences-Basel*, vol. 11, n.º 22, nov. 2021. Disponible en <https://doi.org/10.3390/app112210701>
- [53] M. H. M. Roslim, A. S. Juraimi, et al., "Using remote sensing and an unmanned aerial system for weed management in agricultural crops: a review", *Agronomy-Basel*, vol. 11, n.º 9, sept. 2021.
- [54] W. Guo, Z. Gong, C. Gao, et al., "An accurate monitoring method of peanut southern blight using unmanned aerial vehicle remote sensing", *Precision Agriculture*, vol. 25, n.º 4, pp. 1857–1876, ag. 2024.
- [55] W. Bao, W. Liu, X. Yang, et al., "Adaptively spatial feature fusion network: an improved UAV detection method for wheat scab", *Precision Agriculture*, vol. 24, n.º 3, pp. 1154–1180, jun. 2023.
- [56] B. Das, y C. S. Raghuvanshi, "Advanced UAV-based leaf disease detection: deep radial basis function networks with multidimensional mixed attention", *Multimedia Tools and Applications*, dic. 2024. Disponible en <https://doi.org/10.1007/s11042-024-20462-x>

- [57] A. K. Sangaiah, F.-N. Yu, Y.-B. Lin, et al., "UAV T-YOLO-rice: an enhanced tiny YO-LO networks for rice leaves diseases detection in paddy agronomy", *IEEE Transactions on Network Science and Engineering*, vol. 11, n.º 6, pp. 5201–5216, nov. 2024. Disponible en <https://ieeexplore.ieee.org/document/10387738>
- [58] M. Gavrilovic, D. Jovanovic, P. Bozovic, et al., "Vineyard zoning and vine detection using machine learning in unmanned aerial vehicle imagery", *Remote Sensing*, vol. 16, n.º 3, febr. 2024.
- [59] A. Barreto, F. R. I. Yamati, M. Varrelmann, et al., "Disease incidence and severity of cercospora leaf spot in sugar beet assessed by multispectral unmanned aerial images and machine learning", *Plant Disease*, vol. 107, n.º 1, pp. 188-200, en. 2023.
- [60] D. Percival, K. Anku, y J. Langdon, "Phenotype, phenology, and disease pressure assessments in wild blueberry fields through the use of remote sensing technologies", *Acta Horticulturae*, n.º 1381, pp. 123–130, nov. 2023. Disponible en https://www.actahort.org/books/1381/1381_17.htm
- [61] G. B. C. Narayananappa, S. H. Abbas, L. Annamalai, et al., "Revolutionizing UAV: experimental evaluation of IoT-enabled unmanned aerial vehicle-based agricultural field monitoring using remote sensing strategy", *Remote Sensing in Earth Systems Sciences*, vol. 7, n.º 4, pp. 411–425, dic. 2024. Disponible en <https://doi.org/10.1007/s41976-024-00134-y>
- [62] S. Liu, D. Yin, H. Feng, et al., "Estimating maize seedling number with UAV RGB images and advanced image processing methods", *Precision Agriculture*, vol. 23, n.º 5, pp. 1604–1632, oct. 2022.
- [63] X. Yu, D. Yin, H. Xu, et al., "Maize tassel number and tasseling stage monitoring based on near-ground and UAV RGB images by improved YoloV8", *Precision Agriculture*, vol. 25, n.º 4, pp. 1800–1838, ag. 2024.
- [64] W. Liu, J. Zhou, B. Wang, et al., "IntegrateNet: a deep learning network for maize stand counting from UAV imagery by integrating density and local count maps", *IEEE Geoscience and Remote Sensing Letters*, vol. 19, pp. 1–5, jun. 2022. Disponible en <https://ieeexplore.ieee.org/document/9807329>
- [65] A. Bawa, S. Samanta, S. K. Himanshu, et al., "A support vector machine and image processing based approach for counting open cotton bolls and estimating lint yield from UAV imagery", *Smart Agricultural Technology*, vol. 3, febr. 2023.
- [66] M. Smajlhodžić-Deljo, M. Hundur Hiyari, L. Gurbeta Pokvić, et al., "Using data-driven computer vision techniques to improve wheat yield prediction", *AgriEngineering*, vol. 6, n.º 4, pp. 4704–4719, dic. 2024. Disponible en <https://www.mdpi.com/2624-7402/6/4/26920>

- [67] O. Ameslek, H. Zahir, S. Mitro, *et al.*, “Identification and mapping of individual trees from unmanned aerial vehicle imagery using an object-based convolutional neural network”, *Remote Sensing in Earth Systems Sciences*, vol. 7, n.º 3, pp. 172–182, sept. 2024. Disponible en <https://doi.org/10.1007/s41976-024-00117-z>
- [68] T. Kattenborn, J. Eichel, y F. E. Fassnacht, “Convolutional neural networks enable efficient, accurate and fine-grained segmentation of plant species and communities from high-resolution uav imagery”, *Scientific Reports*, vol. 9, n.º 11, art. 17656, nov, 2019.
- [69] T. Kattenborn, J. Leitloff, F. Schiefer, *et al.*, “Review on convolutional neural networks (CNN) in vegetation remote sensing”, *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 173, pp. 24–49, mzo. 2021.

