



Procesamiento de imágenes con UAV en la agricultura de precisión: panorama actual, tendencias tecnológicas, una revisión sistemática

Image processing with UAVs in precision agriculture: current landscape, technological trends, and a systematic review

Giovanni Mora Castro

Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México

gmora.doc@sin.conalep.edu.mx

ORCID: 0009-0004-6108-9122

Karla Vanessa Ayala Cruz

Universidad Autónoma de Sinaloa, Los Mochis, Sinaloa, México

ayalacruz05@gmail.com

ORCID: 0009-0009-6312-758X

José de Jesús Valenzuela Hernández

Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México

jvh93@uaim.edu.mx

ORCID: 0009-0009-6152-4186

José de Humberto Romero Fitch

Universidad Autónoma de Sinaloa, Los Mochis, Sinaloa, México

joseromero@uas.edu.mx

ORCID: 0009-0002-7279-1123



<https://doi.org/10.36825/RITI.13.32.002>

Recibido: Junio 15, 2025

Aceptado: Octubre 08, 2025

Resumen: Esta revisión sistemática analiza las principales tendencias tecnológicas y metodológicas en el uso de vehículos aéreos no tripulados (VANT) y técnicas de procesamiento de imágenes aplicadas a la agricultura de precisión entre 2018 y 2024. Se consultaron bases indexadas (Scopus, IEEE Xplore, ScienceDirect, etc.) y, tras criterios rigurosos de inclusión y exclusión —eliminación de duplicados, ausencia de validez metodológica y falta de enfoque agrícola— se seleccionaron 111 artículos. Los hallazgos muestran crecimiento sostenido de la producción científica y la prevalencia de sensores RGB por costo y accesibilidad; además, se observa adopción creciente de sensores multiespectrales y térmicos para aplicaciones avanzadas. En procesamiento de imágenes destacan modelos de aprendizaje profundo como CNN, U-Net y YOLO, aplicados a segmentación de cultivos, detección de enfermedades, monitoreo de germinación y clasificación de especies. Se identificaron configuraciones metodológicas recurrentes entre tipos de sensores, técnicas y cultivos, aunque persisten vacíos: escasa validación en campo, falta de métricas estandarizadas y

subrepresentación de regiones emergentes. El estudio ofrece una base para proyectos futuros y refuerza el potencial de los VANT para una agricultura más eficiente, precisa y sostenible. Sus conclusiones orientan decisiones de investigación, inversión y adopción tecnológica con énfasis en prácticas abiertas, replicables y contextualmente pertinentes locales.

Palabras clave: *Vehículos Aéreos No Tripulados, Agricultura de Precisión, Procesamiento de Imágenes, Segmentación de Cultivos, Redes Neuronales Profundas, Detección de Enfermedades y Análisis de Germinación.*

Abstract: This systematic review aims to analyze the main technological and methodological trends in the use of unmanned aerial vehicles (UAVs) and image processing techniques applied to precision agriculture between 2018 and 2024. The research was based on a structured query of indexed databases such as Scopus, IEEE Xplore, and ScienceDirect, from which 111 peer-reviewed articles were selected following rigorous inclusion criteria. Duplicates, non-agricultural studies, and publications lacking methodological clarity were excluded. The findings indicate sustained growth in scientific production related to UAV applications in agriculture, with a predominance of RGB sensors due to their affordability and accessibility. There is also an increasing adoption of multispectral and thermal sensors for more advanced use cases. In terms of image processing techniques, significant advances were found in the application of deep learning models, particularly CNN, U-Net, and YOLO, used for tasks such as crop segmentation, disease detection, germination monitoring, and species classification. Frequent technological combinations were identified between sensors, processing methods, and agricultural applications, establishing increasingly standardized methodological frameworks. However, several challenges persist, including limited validation under field conditions, lack of metric standardization, and underrepresentation of studies in emerging agricultural regions. This review provides a strong foundation for future research and technological implementation, highlighting the potential of UAVs as strategic tools in achieving more efficient, precise, and sustainable agriculture.

Keywords: *Unmanned Aerial Vehicles, Precision Agriculture, Image Processing, Crop Segmentation, Deep Neural Networks, Disease Detection y Germination Analysis.*

1. Introducción

En las últimas décadas, la agricultura ha experimentado una transformación profunda impulsada por la integración de tecnologías digitales. Ante desafíos como el cambio climático, la escasez de recursos hídricos y la necesidad de garantizar la seguridad alimentaria, surgen soluciones innovadoras que permiten monitorear los cultivos con mayor precisión y eficiencia. En este escenario, los vehículos aéreos no tripulados (VANT's) y el procesamiento inteligente de imágenes se presentan como herramientas clave para modernizar las prácticas agrícolas, optimizar los recursos y tomar decisiones agronómicas con base en datos.

La agricultura de precisión se ha posicionado como una estrategia clave para mejorar la eficiencia, sostenibilidad y competitividad del sector agrícola. En este contexto, los vehículos aéreos no tripulados (UAV, por sus siglas en inglés) han cobrado relevancia como herramientas versátiles para la adquisición de imágenes aéreas de alta resolución, permitiendo el monitoreo dinámico de cultivos y el diagnóstico de condiciones fisiológicas, fenológicas y ambientales de forma oportuna y localizada [1], [2].

El avance en tecnologías ópticas ha permitido la incorporación de sensores RGB, multiespectrales, hiperespectrales y térmicos en VANT's, posibilitando la generación de índices vegetativos como el NDVI y el LAI, esenciales para evaluar la salud de los cultivos [3], [4]. En particular, el uso de imágenes RGB se ha consolidado como una alternativa económica y eficiente, siendo aplicada exitosamente en tareas como estimación de biomasa, análisis de estrés hídrico y clasificación de etapas de crecimiento en cultivos como arroz, maíz, algodón y trigo [5], [6], [7].

En paralelo, el desarrollo de técnicas de procesamiento de imágenes, como la segmentación y la detección de contornos, ha ampliado la capacidad de análisis morfológico a nivel de planta y semilla. Estas metodologías permiten, por ejemplo, cuantificar parámetros como la longitud de radículas y el área de emergencia en semillas germinadas, lo que resulta clave para la evaluación automatizada del vigor de germinación [8], [9]. Modelos de

aprendizaje profundo como YOLOv8, U-Net o *Swin Transformer* han demostrado gran eficacia en la identificación de estructuras vegetales complejas, incluso en condiciones visuales adversas [10], [11].

Asimismo, el aprendizaje profundo ha sido ampliamente adoptado para potenciar la visión computacional en agricultura. Las redes neuronales convolucionales (CNN) permiten automatizar tareas como la detección de enfermedades, la clasificación de especies y la identificación de malezas con altos niveles de precisión [12], [13], [14]. La integración de VANT's, inteligencia artificial y sensores ha dado paso a sistemas inteligentes capaces de operar en tiempo real, conectados incluso a plataformas IoT y arquitecturas de cómputo en el borde [15], [16].

No obstante, el desarrollo y adopción de estas tecnologías enfrentan desafíos técnicos, metodológicos y operativos. La estandarización de protocolos, la validación en campo y la transferencia entre contextos agronómicos siguen siendo retos pendientes. Además, el volumen de datos generado por VANT's requiere infraestructura robusta para su procesamiento, lo que limita su acceso para pequeños productores [17], [18].

Frente a este panorama, resulta necesario consolidar el conocimiento existente y analizar de forma crítica las tendencias actuales en el uso de procesamiento de imágenes con VANT's en agricultura de precisión. Por ello, el presente artículo tiene como objetivo realizar una revisión sistemática de la literatura científica reciente sobre técnicas de adquisición y análisis de imágenes aplicadas al monitoreo agrícola, con especial énfasis en el uso de VANT's, visión artificial, segmentación, detección de contornos y aprendizaje profundo. Esta revisión busca identificar avances, vacíos y oportunidades futuras para fortalecer la investigación y las aplicaciones prácticas en este campo estratégico para el desarrollo agroalimentario.

Dada la creciente incorporación de VANT's en el monitoreo agrícola, así como el desarrollo acelerado de técnicas de procesamiento de imágenes, resulta necesario consolidar el conocimiento técnico y científico que sustenta estas aplicaciones. Por tal motivo, en este artículo se presenta una revisión sistemática que explora los principales enfoques utilizados en la literatura reciente para el análisis de imágenes capturadas por VANT's en agricultura de precisión. A continuación, se presenta el marco teórico que fundamenta los ejes conceptuales clave del estudio.

2. Marco Teórico

VANT's y teledetección en agricultura de precisión

Los vehículos aéreos no tripulados (VANT's), también conocidos como drones, se han consolidado como una herramienta fundamental en la teledetección aplicada a la agricultura de precisión. Su capacidad para capturar imágenes georreferenciadas de alta resolución, con frecuencia temporal flexible y costos operativos reducidos, los posiciona como una alternativa eficiente frente a los sistemas satelitales tradicionales [2]. Gracias a su maniobrabilidad, los VANT's pueden operar en condiciones específicas de cultivo, adaptándose a distintos tipos de terreno y etapas fenológicas [1].

En el contexto agrícola, los VANT's permiten la adquisición de datos clave para el diagnóstico del estado fisiológico de los cultivos, la detección temprana de estrés hídrico o fitosanitario, y la estimación de parámetros como la cobertura vegetal, el índice de área foliar (LAI) o el vigor de las plantas [3], [4]. La calidad de estos datos depende en gran medida de los sensores embarcados, como cámaras RGB, multispectrales, hiperspectrales, térmicas o LiDAR [7], [15]. Además, su implementación ha favorecido el uso de modelos agronómicos basados en datos de alta precisión, lo que permite una toma de decisiones más informada en fertilización, riego o control fitosanitario [12], promoviendo una gestión más sustentable [17].

Procesamiento de imágenes: técnicas, herramientas y aplicaciones

El procesamiento digital de imágenes es un componente esencial en el análisis de datos capturados por VANT's en agricultura de precisión. Este proceso incluye preprocesamiento, segmentación, clasificación y extracción de características [3], [18]. Las imágenes obtenidas mediante sensores RGB o multispectrales son procesadas para generar patrones que permitan identificar estrés vegetal, anomalías o zonas de bajo rendimiento [5], [19]. A través del uso de índices como el NDVI o ExG, es posible estimar el vigor de los cultivos [20], [21].

Herramientas como OpenCV, TensorFlow o PyTorch han sido fundamentales en la automatización del análisis visual [14], [22]. Su integración con plataformas GIS permite una interpretación espacial más detallada y útil para la gestión localizada [23].

Segmentación, detección de contornos y aprendizaje profundo en entornos agrícolas

La segmentación de imágenes permite separar regiones de interés, y su aplicación en agricultura ha sido clave para cuantificar estructuras vegetales y su morfología [10], [24]. En particular, la detección de contornos ha mostrado gran eficacia en el análisis de germinación, permitiendo medir parámetros como la longitud de radículas a partir de imágenes RGB [8], [9].

El aprendizaje profundo ha elevado el nivel de precisión de estas técnicas. Modelos como YOLOv8, U-Net o *Swin Transformer* se han aplicado exitosamente en tareas de clasificación, detección y segmentación en contextos agrícolas [25], [26]. Además, las redes con mecanismos de atención espacial y espectral han mejorado la adaptabilidad de estos sistemas para operar bajo condiciones variables [14], [27].

3. Materiales y métodos

La revisión del estado del arte ha permitido observar una diversidad de enfoques, sensores y técnicas aplicadas en el uso de VANT's dentro de la agricultura de precisión. No obstante, gran parte de estos estudios se presentan de forma aislada o fragmentada, lo que dificulta una visión integral sobre las tendencias y aplicaciones más significativas en el procesamiento de imágenes. Por esta razón, se consideró necesario estructurar un proceso metodológico riguroso que permitiera organizar, comparar y analizar la producción científica reciente sobre el tema. A continuación, se describe la metodología empleada para llevar a cabo esta revisión sistemática.

El presente artículo se desarrolla bajo un enfoque de revisión sistemática de literatura, con base en las directrices propuestas por Kitchenham [28], adaptadas al contexto de la ingeniería aplicada a la agricultura de precisión. El objetivo de este tipo de revisión es identificar, analizar y sintetizar las principales contribuciones científicas relacionadas con el uso de VANT's y el procesamiento de imágenes en la agricultura, en particular aquellas que emplean técnicas de segmentación, detección de contornos y aprendizaje profundo.

La revisión sistemática se justifica por la creciente producción científica en esta área, lo cual requiere una organización estructurada del conocimiento que permita visualizar tendencias, aplicaciones recurrentes y oportunidades de mejora en los enfoques técnicos utilizados.

Adaptación metodológica:

La revisión sistemática aquí desarrollada se fundamenta en las directrices de Kitchenham [28], originalmente concebidas para estudios en ingeniería de software. Esta metodología fue adaptada para responder a las particularidades del campo de la ingeniería aplicada a la agricultura de precisión. En específico, se conservaron elementos clave como la formulación de la pregunta de investigación, el diseño del protocolo de búsqueda, la definición de criterios de inclusión/exclusión y el procedimiento de extracción de datos. Las adaptaciones consistieron en: (1) la incorporación de bases de datos especializadas tanto en tecnología como en agricultura; (2) la inclusión de literatura en español y estudios provenientes de América Latina para captar aportes regionales relevantes; y (3) la categorización temática orientada a sensores, técnicas de procesamiento, tipos de cultivo y software utilizado, aspectos centrales en el contexto agrícola. Esta adecuación metodológica permitió mantener la rigurosidad estructural del modelo original, garantizando su pertinencia en un dominio tecnológico distinto. La pregunta de investigación que orientó esta revisión fue la siguiente: *¿Qué técnicas de procesamiento de imágenes han sido utilizadas en la literatura científica reciente para el análisis agrícola mediante VANT's, y cuáles son las principales tendencias tecnológicas asociadas a su aplicación en la agricultura de precisión?*

3.1. Estrategia de búsqueda

Para la identificación de artículos relevantes, se realizó una estrategia de búsqueda sistemática en diversas fuentes académicas digitales reconocidas por su rigor científico y amplia cobertura temática. Las bases de datos consultadas fueron:

- Scopus.
- IEEE Xplore.
- ScienceDirect.
- SpringerLink.
- Redalyc y SciELO (para literatura científica en español y contexto latinoamericano).

Las búsquedas se llevaron a cabo entre los meses de marzo y abril de 2025, considerando como periodo de revisión los años 2018 a 2024, a fin de recopilar estudios representativos y actualizados. Se aplicaron operadores booleanos

y combinaciones de palabras clave en inglés y español para garantizar una cobertura más completa. Algunas expresiones utilizadas se resumen en la Tabla 1. Los filtros aplicados durante la búsqueda incluyeron el idioma (inglés y español), que la publicación fuera artículo científico, que hubiera acceso al texto completo y que los estudios estuvieran centrados en UAV, agricultura de precisión y procesamiento de imágenes.

Tabla 1. Expresiones de búsqueda utilizados.

Idioma	Expresiones
Inglés	• "UAV" AND "<i>image processing</i>" AND "<i>precision agriculture</i>" • "RGB images" AND "<i>crop monitoring</i>" • "<i>contour detection</i>" AND "<i>plant germination</i>" • "<i>deep learning</i>" AND "UAV imagery"
Español	• "procesamiento de imágenes" AND "agricultura de precisión" • "análisis de germinación" AND "VANT" • "visión computacional" AND "monitoreo de cultivos" • "drones en agricultura"

3.2. Criterios de inclusión y exclusión

Para garantizar la relevancia, pertinencia y calidad de los estudios considerados en esta revisión, se definieron los siguientes criterios de inclusión:

- Artículos publicados entre los años 2018 y 2024.
- Documentos en idioma español o inglés.
- Estudios con acceso al texto completo.
- Publicaciones exclusivamente en journals revisados por pares, seleccionadas a partir del filtro “tipo de documento: artículo” en los motores de búsqueda académicos.
- Investigaciones centradas en el uso de VANT’s aplicados a la agricultura de precisión.
- Estudios que incorporen técnicas de procesamiento de imágenes, especialmente segmentación, detección de contornos o aprendizaje automático.
- Aplicaciones orientadas al monitoreo agrícola, como germinación, estrés hídrico, estado fisiológico y detección de enfermedades en cultivos.

Los criterios de exclusión fueron:

- Artículos de opinión, boletines, capítulos de libro, tesis o ponencias de congreso sin revisión editorial formal.
- Estudios duplicados o con contenido redundante entre bases de datos.
- Investigaciones que utilicen VANT’s en contextos no agrícolas (como seguridad, infraestructura o transporte).
- Publicaciones sin aplicación concreta de procesamiento de imágenes.
- Trabajos con una metodología ambigua o resultados no explicados de forma suficiente para su análisis crítico.

Estos criterios se aplicaron desde la etapa inicial de búsqueda, utilizando filtros automáticos de tipo de documento en las bases de datos consultadas. Posteriormente, se realizó una revisión manual de títulos, resúmenes y textos completos, a fin de asegurar la coherencia temática y metodológica con los objetivos de la revisión.




Figura 1. Flujo de selección de artículos incluidos en la revisión sistemática, conforme al modelo PRISMA.

3.3. Proceso de selección de estudios

A diferencia de una revisión sistemática tradicional basada en grandes volúmenes iniciales de literatura, el enfoque adoptado en esta revisión fue específico y dirigido, utilizando expresiones clave cuidadosamente diseñadas para localizar estudios directamente relacionados con el tema. A partir de las combinaciones definidas en la estrategia de búsqueda, se identificaron y analizaron resúmenes de artículos que cumplieran con los criterios de inclusión previamente establecidos.

Este procedimiento permitió construir una biblioteca inicial curada, compuesta exclusivamente por estudios de revistas científicas relevantes, tanto en inglés como en español. La evaluación de estos documentos se realizó desde la lectura del resumen, seguida de la consulta del texto completo, confirmando que cada uno de los trabajos incluía elementos esenciales como el uso de VANT's, aplicaciones agrícolas y técnicas de procesamiento de imágenes (especialmente segmentación, detección de contornos o modelos de aprendizaje automático).

Como resultado, se integró un corpus de 111 artículos seleccionados de manera justificada, que sirven como base para el análisis teórico y comparativo presentado en este trabajo. Este enfoque permitió optimizar el proceso de revisión al focalizar la atención en trabajos pertinentes desde la etapa inicial, asegurando profundidad sin sacrificar claridad metodológica.

3.4. Extracción y síntesis de datos

Una vez definidos los artículos que conforman el corpus de análisis, se procedió a realizar la extracción sistemática de información clave de cada uno de ellos. Para ello, se diseñó una matriz de recopilación de datos que permitió organizar y comparar los estudios seleccionados en función de sus principales características metodológicas y temáticas. Los elementos extraídos de cada artículo fueron los siguientes:

- Autor y año de publicación.
- País o región de afiliación del primer autor.
- Tipo de sensor utilizado (RGB, multiespectral, térmico, hiperespectral, etc.).
- Técnica de procesamiento aplicada (segmentación, detección de contornos, CNN, U-Net, YOLOv8, entre otras).
- Aplicación agrícola (monitoreo de germinación, análisis de estrés hídrico, clasificación de cultivos, detección de enfermedades, etc.).
- Tipo de cultivo abordado (arroz, maíz, trigo, hortalizas, etc.).
- Plataforma de análisis o software empleado (OpenCV, TensorFlow, QGIS, MATLAB, etc.).

Esta sistematización permitió identificar tendencias tecnológicas, como el uso creciente de modelos de aprendizaje profundo para la segmentación precisa de estructuras vegetales, así como áreas de aplicación frecuentes, entre las que destacan la detección temprana de enfermedades, el análisis de vigor en etapas iniciales de cultivo y el monitoreo de estrés. Asimismo, el análisis de los países de procedencia evidenció una concentración de investigaciones en regiones como Asia (principalmente China e India), Europa (Alemania, España) y América del Norte, aunque también se documentaron aportes relevantes desde América Latina, especialmente en Brasil y México. En cuanto a la distribución temporal, se observó un incremento sostenido en las publicaciones entre 2019 y 2023, con un pico de producción científica en el año 2023, lo cual refleja el crecimiento del interés y la madurez tecnológica del campo.

4. Resultados y análisis

A partir de los 111 artículos seleccionados, se procedió al análisis descriptivo de sus principales características, agrupándolas en función de aspectos técnicos, metodológicos y temáticos. El objetivo de esta sección es identificar patrones relevantes en la literatura reciente, tanto en lo que respecta a la distribución temporal y geográfica de los estudios, como a las técnicas, sensores y aplicaciones más utilizadas en el contexto de la agricultura de precisión. Los resultados se presentan organizados por categorías, permitiendo una visión estructurada de las tendencias actuales en el uso de procesamiento de imágenes con VANT's.

4.1. Distribución temporal de publicaciones

La revisión abarcó artículos publicados en el periodo comprendido entre los años 2018 y 2024, con un total de 111 estudios seleccionados. Si bien se identificaron contribuciones durante todo el rango temporal establecido, se observó una tendencia ascendente en la cantidad de publicaciones conforme avanzan los años, ver Tabla 2.

El crecimiento más significativo se evidenció a partir de 2020, cuando el número de artículos comenzó a incrementarse de manera sostenida, alcanzando su pico máximo en el año 2023. Este comportamiento coincide con el auge de tecnologías emergentes como el aprendizaje profundo aplicado a imágenes VANT's, así como con una mayor disponibilidad de plataformas de bajo costo para captación y procesamiento de datos agrícolas.

Este aumento progresivo refleja no solo el interés creciente de la comunidad científica en la integración de VANT's y visión computacional para el sector agrícola, sino también el avance en la madurez técnica de las herramientas disponibles, permitiendo abordajes más sofisticados en la recolección, análisis e interpretación de imágenes aéreas.

Tabla 2. Distribución de publicaciones por año.

Año	Número de artículos
2018	5
2019	8
2020	12
2021	16
2022	22
2023	35
2024	13

4.2. Distribución geográfica

En cuanto a la procedencia geográfica de los estudios analizados, se identificó una amplia representación internacional, lo que refleja el interés global en la integración de VANT's y técnicas de procesamiento de imágenes en la agricultura. Los países con mayor número de publicaciones fueron China, India, Estados Unidos, España y Brasil, destacando como núcleos activos de investigación en esta temática, ver Tabla 3.

El predominio de estudios provenientes de Asia y América del Norte se vincula tanto con el avance tecnológico en estos países como con el apoyo institucional y la inversión en innovación agroindustrial. En Europa, destacan contribuciones relevantes desde Alemania, Francia, Italia y los Países Bajos, centradas especialmente en agricultura de precisión aplicada a cultivos de alto valor comercial.

Por su parte, América Latina muestra una participación creciente, principalmente desde Brasil y México, con estudios enfocados en cultivos regionales y adaptación tecnológica en entornos agrícolas de mediana escala. Aunque en menor medida, también se registraron investigaciones provenientes de países africanos y de Medio Oriente, lo que evidencia una expansión progresiva de estas tecnologías hacia regiones emergentes.

Tabla 3. Principales países de origen de los estudios

País	Número de artículos
China	24
India	15
EE.UU.	14

España	10
Brasil	9
México	6
Otros	33

4.3. Tipos de sensores utilizados

Uno de los aspectos clave analizados en los estudios revisados fue el tipo de sensor empleado en los VANT's para la adquisición de imágenes (Tabla 4). La mayoría de los artículos incluyeron el uso de sensores RGB, debido a su bajo costo, facilidad de implementación y amplia disponibilidad comercial. Estos sensores fueron especialmente utilizados en tareas de clasificación de cultivos, detección de cobertura vegetal y análisis morfológico básico.

En segundo lugar, se identificó una importante presencia de sensores multiespectrales, que permitieron el cálculo de índices vegetativos como el NDVI, EVI o VARI. También se reportaron estudios que utilizaron sensores térmicos, principalmente para evaluar estrés hídrico, y sensores hiperespectrales, en investigaciones más especializadas. El uso de LiDAR, aunque menos frecuente, fue relevante en estudios de reconstrucción tridimensional o estimación de biomasa. Esta variedad de sensores evidencia que la elección del dispositivo óptico depende directamente de los objetivos específicos del análisis agronómico.

Tabla 4. Tipos de sensores utilizados.

Tipo de sensor	Número de estudios
RGB	58
Multiespectral	27
Térmico	10
Hiperespectral	9
LiDAR	7

4.4. Técnicas de procesamiento aplicadas

En los estudios revisados se identificó una diversidad de enfoques técnicos utilizados para el procesamiento y análisis de las imágenes capturadas por VANT's. La técnica más común fue la segmentación de imágenes, empleada para delimitar áreas de cultivo, identificar plantas individuales y separar elementos relevantes del entorno (Tabla 5).

La **detección de contornos** fue aplicada principalmente en estudios centrados en análisis de germinación o morfología vegetal. Además, se observó una adopción creciente de modelos de aprendizaje profundo, especialmente YOLO, U-Net y Swin Transformer, los cuales permiten tareas de detección, segmentación y clasificación de cultivos con altos niveles de precisión. También se documentó el uso de técnicas híbridas, que combinan métodos tradicionales con modelos de *deep learning*, así como la aplicación de estrategias como *transfer learning* y *data augmentation*.

Tabla 5. Técnicas de procesamiento de imágenes utilizadas.

Técnica	Número de estudios
Segmentación	42
Detección de contornos	18
CNN	28
YOLO (v4-v8)	16
U-Net	10
Swin Transformer	5
Técnicas híbridas	7

4.5. Ámbitos de aplicación agrícola

Entre las aplicaciones más comunes encontradas en los estudios revisados destacan: el análisis de germinación, el monitoreo de estrés hídrico, la detección de enfermedades, la clasificación de cultivos y el seguimiento del estado fisiológico de las plantas.

También se registraron estudios orientados a estimar biomasa y rendimiento, así como trabajos dedicados a la evaluación de tratamientos agronómicos, por ejemplo, la eficacia de fertilizaciones o riegos localizados. En general, los artículos muestran una tendencia a utilizar estas tecnologías como herramientas complementarias para la toma de decisiones agronómicas informadas.

Tabla 6. Aplicaciones agrícolas abordadas.

Aplicación	Número de estudios
Germinación	20
Estrés hídrico	14
Salud vegetal	18
Clasificación de cultivos	26
Detección de enfermedades	22
Biomasa / rendimiento	8
Evaluación de tratamientos	7

4.6. Tipos de cultivo abordados

Los cultivos más analizados fueron maíz, trigo y arroz, debido a su relevancia económica y disponibilidad de áreas de cultivo extensivo. También se identificaron estudios centrados en hortalizas como tomate y lechuga, así como en frutales (cítricos, uva, manzana), y cultivos industriales como soja, caña de azúcar y algodón, ver Tabla 7. Algunos trabajos exploraron aplicaciones en sistemas más complejos como agroecosistemas diversificados, policultivos o cultivos de cobertura, donde las imágenes VANT's permiten generar mapas de variabilidad y monitoreo detallado.

Tabla 7. Tipos de cultivo analizados en los estudios.

Cultivo	Número de estudios
Maíz	18
Trigo	14
Arroz	12
Tomate	9
Hortalizas variadas	10
Frutales	11
Caña de azúcar / algodón / soja	8
Otros	7

5. Discusión

El análisis de los 111 estudios seleccionados permitió identificar tendencias claras en el uso de vehículos aéreos no tripulados (VANT's) aplicados al procesamiento de imágenes en la agricultura de precisión. En primer lugar, se evidenció un crecimiento sostenido en la producción científica sobre esta temática entre 2018 y 2023, reflejando el creciente interés por soluciones tecnológicas que mejoren el monitoreo y la gestión de cultivos.

Los sensores RGB fueron los más utilizados debido a su disponibilidad y bajo costo, mientras que los multispectrales cobraron relevancia en aplicaciones más avanzadas que requerían el cálculo de índices vegetativos. El uso de sensores térmicos e hiperespectrales, aunque menos frecuente, mostró aplicaciones especializadas con alto valor diagnóstico.

En cuanto a las técnicas de procesamiento, la segmentación fue la más común, seguida de enfoques de aprendizaje profundo como CNN, U-Net y YOLO, que han ganado popularidad en los últimos años debido a su capacidad de automatizar tareas con alta precisión. Las aplicaciones agrícolas más recurrentes fueron la detección

de enfermedades, la clasificación de cultivos y el análisis de germinación, lo cual pone en evidencia la búsqueda de soluciones automatizadas para problemas agrícolas críticos.

La construcción de una matriz de coocurrencia entre sensores, técnicas y aplicaciones reveló combinaciones predominantes —por ejemplo, el uso de sensores RGB junto a redes YOLOv5 en tareas de clasificación temprana de plantas, o el uso de multispectrales con segmentación en el monitoreo del estrés hídrico— lo que demuestra que ciertas configuraciones están consolidándose como prácticas estándar en la literatura reciente.

5.1. Relación con otros estudios

Los hallazgos obtenidos en esta revisión sistemática son consistentes con lo reportado en estudios previos que abordan el uso de VANT's e inteligencia artificial en entornos agrícolas. Investigaciones como las de Tsouros et al. (2019) y Fu et al. (2020) ya habían señalado la prevalencia de sensores RGB por su facilidad de integración en plataformas VANT's comerciales, así como la transición paulatina hacia sensores multispectrales en contextos donde se requiere mayor precisión espectral.

Asimismo, la popularidad creciente de técnicas basadas en deep learning ha sido documentada en revisiones como las de Ramachandran et al. (2024) y Bellis et al. (2022), quienes destacan el valor de arquitecturas como U-Net y YOLO para tareas de segmentación y clasificación en imágenes agrícolas. La coincidencia en la adopción de estas herramientas tecnológicas sugiere un proceso de estandarización metodológica en la comunidad científica especializada en agricultura de precisión.

Por otra parte, los resultados de esta revisión también refuerzan observaciones realizadas en estudios regionales como los de Navarro et al. (2024) en México y Hasan et al. (2022) en Asia, donde el uso de VANT's ha sido adaptado a cultivos locales, demostrando la flexibilidad de estas plataformas para operar en condiciones agroecológicas variadas.

Sin embargo, también se identifican diferencias notables: mientras que en otras regiones los estudios privilegian el monitoreo de grandes extensiones, en América Latina se ha reportado un interés particular en el análisis detallado a pequeña escala, especialmente en hortalizas y frutales. Estas variaciones indican que, si bien existen tendencias globales, el uso de VANT's y procesamiento de imágenes también responde a necesidades específicas de cada contexto agrícola.

5.2. Implicaciones técnicas y prácticas

Los resultados de esta revisión sistemática no solo evidencian el avance en la investigación sobre VANT's y procesamiento de imágenes, sino que también ofrecen elementos valiosos para la transferencia tecnológica hacia el campo agrícola. La amplia adopción de sensores accesibles como los RGB, combinados con algoritmos de segmentación o redes neuronales livianas, sugiere que es posible desarrollar soluciones de bajo costo con un alto potencial de implementación, incluso en unidades productivas de pequeña y mediana escala.

Esta afirmación se sustenta en el hecho de que una parte importante de los estudios analizados emplea tecnologías de bajo costo, como sensores RGB y plataformas de código abierto, lo que facilita su replicabilidad en entornos reales. Además, se identificaron investigaciones que desarrollan algoritmos livianos y metodologías adaptadas a condiciones productivas de pequeña y mediana escala. La documentación detallada de configuraciones técnicas aplicables, junto con validaciones preliminares en campo, demuestra que existe un interés creciente por trasladar estas soluciones del laboratorio a la práctica agrícola. En este sentido, los hallazgos recopilados constituyen un insumo técnico y operativo útil para orientar procesos de adopción tecnológica en diversos contextos agropecuarios.

Además, el uso de técnicas de aprendizaje profundo para detectar enfermedades, estimar cobertura vegetal o clasificar cultivos, representa una oportunidad para automatizar tareas que tradicionalmente dependen de la experiencia visual humana, reduciendo el margen de error y mejorando la eficiencia en la toma de decisiones. La sistematización de combinaciones de sensores, técnicas y aplicaciones también ofrece un marco de referencia útil para desarrolladores de software agrícola, diseñadores de sistemas VANT's, agrónomos y tomadores de decisiones, permitiéndoles identificar configuraciones tecnológicas adecuadas para contextos específicos. Desde una perspectiva más estratégica, los resultados obtenidos reafirman el papel de los VANT's como una herramienta clave en el avance de la agricultura digital. Su capacidad de generar datos visuales de alta resolución,

analizables mediante técnicas inteligentes, constituye una ventaja crucial frente a otras tecnologías más costosas o de menor resolución espacial y temporal.

5.3. Vacíos y desafíos encontrados

Pese al avance significativo en el desarrollo y aplicación de tecnologías VANT's para la agricultura de precisión, la revisión permitió identificar una serie de vacíos y desafíos metodológicos que persisten en la literatura científica.

Uno de los principales vacíos es la falta de estandarización en los procedimientos de evaluación. Muchos estudios utilizan métricas propias para validar sus algoritmos, lo que dificulta la comparación objetiva entre enfoques. Además, la ausencia de conjuntos de datos abiertos, compartidos o referenciables limita la posibilidad de reproducir o escalar los resultados.

Otro aspecto relevante es la escasa inclusión de validación en campo. Si bien muchas investigaciones muestran resultados prometedores en ambientes controlados o con datos previamente procesados, pocos trabajos documentan la eficacia real de los sistemas desarrollados bajo condiciones agrícolas complejas, donde factores como el clima, la topografía o la variabilidad del cultivo pueden afectar significativamente el desempeño.

También se identificó un desequilibrio en la cobertura temática, con predominancia de estudios enfocados en ciertos cultivos (cereales y hortalizas) y aplicaciones específicas (clasificación, detección de enfermedades), mientras que otros temas, como la estimación de rendimiento, el análisis de suelo o el monitoreo postcosecha, han sido abordados en menor medida.

Desde el punto de vista técnico, persisten retos vinculados al volumen de datos generado, la capacidad de procesamiento en tiempo real, y la necesidad de infraestructura tecnológica robusta para ejecutar modelos de aprendizaje profundo en entornos rurales con conectividad limitada.

5.4. Proyecciones y líneas futuras

Una primera línea de desarrollo apunta a la integración de sensores múltiples en una sola plataforma VANT's. El uso combinado de cámaras RGB, multiespectrales, térmicas e incluso hiperspectrales puede potenciar la calidad del diagnóstico agronómico, permitiendo una caracterización más completa del estado fisiológico del cultivo en tiempo real.

Paralelamente, se espera una mayor adopción de técnicas de inteligencia artificial más avanzadas, como transformers visuales, redes neuronales híbridas y modelos auto-supervisados, capaces de aprender con menos datos etiquetados y adaptarse a condiciones de campo más variables.

Otro camino crucial es el desarrollo de modelos ligeros y entrenables en el borde (*edge computing*), que permitan ejecutar algoritmos de análisis directamente en el dron o en dispositivos móviles sin necesidad de conectividad constante, facilitando así su uso en regiones rurales con infraestructura limitada.

También se identifica una necesidad creciente de protocolos estandarizados de validación, así como de la creación y disponibilidad de repositorios abiertos de imágenes VANT's etiquetadas, que fomenten la colaboración interdisciplinaria y la replicabilidad de los resultados.

Desde el punto de vista práctico, se vislumbra un mayor énfasis en el diseño de herramientas de bajo costo, adaptadas a pequeños y medianos productores, con interfaces amigables, interpretaciones visuales accesibles y posibilidad de vinculación con sistemas de toma de decisiones o plataformas de agricultura digital.

6. Conclusiones

Esta revisión sistemática permitió identificar y analizar las principales tendencias tecnológicas en el uso de vehículos aéreos no tripulados (VANT's) y técnicas de procesamiento de imágenes en la agricultura de precisión durante el periodo 2018–2024. Los 111 estudios revisados revelan una evolución significativa en las metodologías aplicadas, así como un creciente interés de la comunidad científica en el desarrollo de soluciones inteligentes para el monitoreo y análisis agrícola.

Entre los hallazgos más relevantes destaca el predominio de sensores RGB por su accesibilidad, así como el uso creciente de sensores multiespectrales y modelos de aprendizaje profundo como U-Net, CNN y YOLO. Las aplicaciones más frecuentes se enfocaron en la detección de enfermedades, clasificación de cultivos y análisis de germinación, consolidándose como líneas prioritarias de investigación aplicada.

El análisis cruzado entre sensores, técnicas y aplicaciones permitió visualizar combinaciones tecnológicas recurrentes, lo cual representa un aporte metodológico útil para futuros desarrollos en el campo. Asimismo, se evidenciaron vacíos relevantes como la escasa validación en condiciones reales, la falta de estandarización de métricas y la limitada representación de ciertos cultivos o regiones agrícolas.

En conjunto, los resultados obtenidos refuerzan el valor de los VANT's como herramienta clave en la transformación digital del sector agropecuario, pero también subrayan la necesidad de continuar explorando líneas emergentes como la integración sensorial, el *edge computing*, y la democratización tecnológica para pequeños productores.

Finalmente, esta revisión establece una base sólida para orientar futuros proyectos de investigación, desarrollo e implementación de tecnologías VANT's en contextos agrícolas, promoviendo una agricultura más eficiente, sostenible y tecnológicamente avanzada.

7. Referencias

- [1] Pino-Vargas, E. (2019). Los Drones Una Herramienta Para Una Agricultura Eficiente: Un Futuro De Alta Tecnología. *Idesia*, 37 (1), 75-84. <http://dx.doi.org/10.4067/S0718-34292019005000402>
- [2] Tsouros, D. C., Bibi, S., Sarigiannidis, P. (2019). A review on UAV-based applications for precision agriculture. *Information*, 10 (11), 1-26. <http://dx.doi.org/10.3390/info10110349>
- [3] Zhu, W., Sun, Z., Huang, Y., Lai, J., Li, J., Zhang, J., Yang, B., Li, B., Li, S., Zhu, K., Li, Y., Liao, X. (2019). Improving field-scale wheat LAI retrieval based on UAV remote-sensing observations and optimized VI-LUTs. *Remote Sensing*, 11 (20), 1-22. <http://dx.doi.org/10.3390/rs11202456>
- [4] Fu, Z., Jiang, J., Gao, Y., Krienke, B., Wang, M., Zhong, K., Cao, Q., Tian, Y., Zhu, Y., Cao, W., Liu, X. (2020). Wheat growth monitoring and yield estimation based on multi-rotor unmanned aerial vehicle. *Remote Sensing* 12 (3), 1-19. <http://dx.doi.org/10.3390/rs12030508>
- [5] Gerardo, R., de Lima, I. P. (2023). Applying RGB-based vegetation indices obtained from UAS imagery for monitoring the rice crop at the field scale: A case study in Portugal. *Agriculture*, 13 (10), 1-18. <http://dx.doi.org/10.3390/agriculture13101916>
- [6] Ma, Y., Ma, L., Zhang, Q., Huang, C., Yi, X., Chen, X., Hou, T., Lv, X., Zhang, Z. (2022). Cotton yield estimation based on vegetation indices and texture features derived from RGB image. *Frontiers in Plant Science*, 13, 1-17. <http://dx.doi.org/10.3389/fpls.2022.925986>
- [7] Yamaguchi, T., Tanaka, Y., Imachi, Y., Yamashita, M., Katsura, K. (2020). Feasibility of combining deep learning and RGB images obtained by unmanned aerial vehicle for leaf area index estimation in rice. *Remote Sensing*, 13 (1), 1-19. <http://dx.doi.org/10.3390/rs13010084>
- [8] Fang, Z., Fan, Q., Jiang, H., Wang, C., Fu, X., Li, X., Li, M., Zhang, S., Zhang, Y., Li, Y. (2024). Evaluation of cucumber seed germination vigor under salt stress environment based on improved YOLOv8. *Frontiers in Plant Science*, 15, 1-16. <http://dx.doi.org/10.3389/fpls.2024.1447346>
- [9] Wu, Y., Li, Z., Jiang, H., Li, Q., Qiao, J., Pan, F., Fu, X., Guo, B. (2024). YOLOv8-segANDcal: Segmentation, extraction, and calculation of soybean radicle features. *Frontiers in Plant Science*, 15, 1-20. <http://dx.doi.org/10.3389/fpls.2024.1425100>
- [10] Xu, X., Zou, J., Cai, J., Zou, D. (2024). Multi-scale contextual Swin transformer for crop image segmentation. *Journal of Physics: Conference Series*, 2759, 1-6. <http://dx.doi.org/10.1088/1742-6596/2759/1/012012>
- [11] Zhu, Z., Jiang, M., Dong, J., Wu, S., Ma, F. (2023). PD-SegNet: Semantic segmentation of small agricultural targets in complex environments. *IEEE Access*, 11, 90214-90226. <http://dx.doi.org/10.1109/access.2023.3284036>
- [12] Bellis, E. S., Hashem, A. A., Causey, J. L., Runkle, B. R. K., Moreno-García, B., Burns, B. W., Green, V. S., Burcham, T. N., Reba, M. L., Huang, X. (2022). Detecting intra-field variation in rice yield with unmanned aerial vehicle imagery and deep learning. *Frontiers in Plant Science*, 13, 1-13. <http://dx.doi.org/10.3389/fpls.2022.716506>
- [13] Bouguettaya, A., Zarzour, H., Kechida, A., Taberkit, A. M. (2022). A survey on deep learning-based identification of plant and crop diseases from UAV-based aerial images. *Cluster Computing*, 26 (2), 1297-1317. <http://dx.doi.org/10.1007/s10586-022-03627-x>

- [14]Ramachandran, A., Kumar, K. S. S. (2024). An efficient deep learning model for paddy growth stage classification using neural network pruning on UAV images. *Engineering Research Express*, 6 (4), 1-15. <http://dx.doi.org/10.1088/2631-8695/ad9afe>
- [15]McEnroe, P., Wang, S., Liyanage, M. (2022). A survey on the convergence of edge computing and AI for UAVs: Opportunities and challenges. *IEEE Internet of Things Journal*, 9 (12), 15435-15459. <http://dx.doi.org/10.1109/jiot.2022.3176400>
- [16]Arafat, M. Y., Alam, M. M., Moh, S. (2023). Vision-based navigation techniques for unmanned aerial vehicles: Review and challenges. *Drones*, 7 (2), 1-41. <http://dx.doi.org/10.3390/drones7020089>
- [17]Zimmer-Dauphinee, J., Wernke, S. A. (2024). Semantic segmentation and classification of active and abandoned agricultural fields through deep learning in the southern Peruvian Andes. *Remote Sensing*, 16 (19), 1-16. <http://dx.doi.org/10.3390/rs16193546>
- [18]Wang, W., Kang, Y. (2025). A review of computer vision technologies in precision agriculture: From crop disease detection to farm management. *Theoretical and Natural Science*, 5 (2), 35-40. <http://dx.doi.org/10.54254/2753-8818/2025.ch22224>
- [19]Hasan, U., Sawut, M., Chen, S. (2019). Estimating the leaf area index of winter wheat based on unmanned aerial vehicle RGB-image parameters. *Sustainability*, 11 (23), 1-11. <http://dx.doi.org/10.3390/su11236829>
- [20]Vigabriel Navarro, L. M., Osorio Leyton, J. M., Quezada Lambertín, C. E., Benavides Lopez, J. P. (2024). Estimación de la biomasa del cultivo de cebada (*Hordeum vulgare* L.) mediante teledetección de imágenes multiespectrales. *Revista de Investigación e Innovación Agropecuaria y de Recursos Naturales*, 11 (2), 18–29. <http://dx.doi.org/10.53287/iguo9951ru99j>
- [21]Lu, W., Okayama, T., Komatsuzaki, M. (2021). Rice height monitoring between different estimation models using UAV photogrammetry and multispectral technology. *Remote Sensing*, 14 (1), 1-24. <http://dx.doi.org/10.3390/rs14010078>
- [22]Luo, B., Wang, X., Zhang, Z. (2021). Application of computer vision technology in UAV. *Journal of Physics: Conference Series*, 1881, 1-4. <http://dx.doi.org/10.1088/1742-6596/1881/4/042052>
- [23]Fraccaro, P., Butt, J., Edwards, B., Freckleton, R. P., Childs, D. Z., Reusch, K. (2022). A deep learning application to map weed spatial extent from unmanned aerial vehicles imagery. *Remote Sensing*, 14 (17), 1-15. <http://dx.doi.org/10.3390/rs14174197>
- [24]Mustafa, S., Waseem Iqbal, M., Rana, T. A., Jaffar, A., Shiraz, M., Arif, M., Chelloug, S. A. (2022). Entropy and Gaussian filter-based adaptive active contour for segmentation of skin lesions. *Computational Intelligence and Neuroscience*, 2022, 1-10. <http://dx.doi.org/10.1155/2022/4348235>
- [25]Cheng, S., Li, B., Sun, L., Chen, Y. (2023). HRRNet: Hierarchical refinement residual network for semantic segmentation of remote sensing images. *Remote Sensing*, 15 (5), 1-19. <http://dx.doi.org/10.3390/rs15051244>
- [26]Sonawane, S., Patil, N. N. (2024). Crop-weed segmentation and classification using YOLOv8 approach for smart farming. *Journal of Studies in Science and Engineering*, 4 (2), 136-158. <http://dx.doi.org/10.53898/josse2024428>
- [27]Kerner, H., Chaudhari, S., Ghosh, A., Robinson, C., Ahmad, A., Choi, E., Jacobs, N., Holmes, C., Mohr, M., Dodhia, R., Lavista Ferres, J. M., Marcus, J. (2025). Fields of The World: A Machine Learning Benchmark Dataset for Global Agricultural Field Boundary Segmentation. *Proceedings of the AAAI Conference on Artificial Intelligence*, 39 (27), 28151-28159. <https://doi.org/10.1609/aaai.v39i27.35034>
- [28]Kitchenham, B., Brereton, O. P. (2013). A systematic review of systematic review process research in software engineering. *Information and Software Technology*, 55 (12), 2049–2075. <http://dx.doi.org/10.1016/j.infsof.2013.07.010>