

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

<https://doi.org/10.35381/i.p.v7i12.4450>

Agricultura de precisión en la producción de banano. Revisión sistemática

Precision agriculture in banana production. Systematic review

Cristhel Valeria Romero-García

cromero13@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador

<https://orcid.org/0009-0001-7431-2002>

Carmen Marlene Saraguro-Reyes

csaguro3@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador

<https://orcid.org/0009-0008-8850-5818>

Bertha Eugenia Mazon-Olivo

bmazon@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador

<https://orcid.org/0000-0002-2749-8561>

Rodrigo Fernando Morocho-Román

rmorocho@utmachala.edu.ec

Universidad Técnica de Machala, Machala, El Oro
Ecuador

<https://orcid.org/0000-0003-0194-5033>

Recibido: 12 de septiembre de 2024

Revisado: 08 de octubre de 2024

Aprobado: 15 de diciembre de 2024

Publicado: 01 de enero de 2025

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

RESUMEN

Este trabajo consistió en una revisión sistemática la literatura sobre el uso de tecnologías de agricultura de precisión aplicadas en la producción de banano. Se aplicó la metodología PRISMA; sus fases son: identificación, selección e inclusión. Se consideraron criterios de inclusión y exclusión rigurosos para la búsqueda en bases de datos académicas y selección de artículos científicos de los últimos cinco años. El análisis permitió identificar las principales tecnologías empleadas en las distintas fases del cultivo, así como sus beneficios en la optimización del proceso productivo y en la mejora de la toma de decisiones basada en datos. Como resultado, se diseñó una arquitectura organizada en capas: percepción, red y aplicación, que integra herramientas, tecnologías (Internet de las Cosas e Inteligencia Artificial) y aplicaciones para cultivos de banano. En conclusión, esta arquitectura es una guía de referencia para los agricultores que buscan tecnificar sus procesos productivos.

Descriptores: Agricultura de precisión; banano; inteligencia artificial; internet; tecnología de la información. (Thesaurus AGROVOC).

ABSTRACT

This work consisted of a systematic review of the literature on the use of precision agriculture technologies applied to banana production. The PRISMA methodology was applied; its phases are: identification, selection and inclusion. Rigorous inclusion and exclusion criteria were considered for the search in academic databases and selection of scientific articles from the last five years. The analysis made it possible to identify the main technologies used in the different phases of cultivation, as well as their benefits in optimizing the production process and improving data-based decision making. As a result, an architecture organized in layers was designed: perception, network and application, which integrates tools, technologies (Internet of Things and Artificial Intelligence) and applications for banana crops. In conclusion, this architecture is a reference guide for farmers seeking to technify their production processes.

Descriptors: Precision agriculture; banana; artificial intelligence; internet; information technology. (AGROVOC Thesaurus).

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

INTRODUCCIÓN

El banano es uno de los principales cultivos agrícolas producidos, comercializados y consumidos en el mundo, que contribuye a la seguridad alimentaria, en especial en países en desarrollo. En los últimos años se ha registrado un aumento en la producción y el volumen comercial de este fruto, siendo uno de los productos más comercializado con \$13.5 miles de millones durante el año 2022 (FAO, 2024c; OEC, 2024).

La producción de banano se concentra principalmente en países de América Latina y Asia, regiones que en conjunto representan aproximadamente el 95% del comercio mundial de esta fruta (FAO, 2024b). En el año 2023, los principales países exportadores fueron Ecuador, con 6.2 millones de toneladas; Guatemala, con 2.6 millones; Filipinas, con 2.3 millones; Costa Rica, con 1.9 millones; y Colombia, con 1.7 millones de toneladas. Estas exportaciones generaron un valor total superior a 1.120 millones de dólares estadounidenses (FAO, 2024a; OEC, 2024).

Las tecnologías como la agricultura de precisión (AP), demuestra su potencial para transformar la agricultura global. Se presentan como una solución que combina tecnologías avanzadas (drones, internet de las cosas, sistemas de información geográfica, inteligencia artificial y ciencia de datos) para optimizar no solo la producción, sino también reducir los impactos ambientales mediante la aplicación localizada y eficiente de agua e insumos agrícolas como fertilizantes y plaguicidas (Gao et al., 2020; Nowak, 2021; Ramírez-Orellana et al., 2021). La AP en la producción de banano se ha estudiado de diversas maneras, tanto en trabajos de revisión como en casos aplicativos, con un enfoque genérico o centrados en una o más tecnologías y tipos de cultivos. Sin embargo, existen distintas barreras a considerar para su adopción.

En Kenia, Kirimi et al. (2021) evaluaron el impacto de la adopción de tecnologías de producción de banano entre pequeños agricultores, identificando limitaciones significativas como el acceso restringido a recursos tecnológicos y la incertidumbre en los precios, lo que pone de manifiesto la necesidad de estrategias integrales que

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

fomenten una adopción tecnológica efectiva. Por su parte, Patrick et al. (2023) aplicaron modelos avanzados de predicción como SARIMAX, State Space y LSTM para estimar el rendimiento del banano en escenarios de cambio climático, incorporando variables climáticas como precipitación y temperatura. Los resultados evidenciaron una mejora sustancial en la precisión de los pronósticos, lo que contribuye a una toma de decisiones más sostenible en el manejo productivo del cultivo.

Diversas revisiones han documentado sus aplicaciones generales en distintos cultivos; sin embargo, se ha identificado una limitada cantidad de estudios centrados específicamente en el cultivo de banano. Las revisiones sistemáticas disponibles destacan el uso de tecnologías como vehículos aéreos no tripulados (UAV), sensores, Internet de las Cosas (IoT), aprendizaje automático (ML) y aprendizaje profundo (DL), orientadas a la detección temprana de plagas y enfermedades, predicción de rendimientos y evaluación del estado de madurez del fruto (Akkem et al., 2023; Alexopoulos et al., 2023; Nasim et al., 2023; Yang et al., 2024). No obstante, la ausencia de un enfoque integral dificulta la adopción de la agricultura de precisión en este cultivo, lo que limita su contribución al incremento de la sostenibilidad y la eficiencia productiva. Por tanto, esta revisión sistemática resulta fundamental para consolidar el conocimiento existente, identificar vacíos en la literatura actual y proponer una arquitectura integral que permita la incorporación de tecnologías de agricultura de precisión en cada una de las etapas del sistema productivo del banano. El objetivo de este trabajo es realizar una revisión sistemática del estado del arte sobre la agricultura de precisión, que sirva como base para futuras investigaciones en el ámbito del cultivo de banano.

MÉTODO

La presente investigación empleó una metodología de Revisión Sistemática de la Literatura (RSL), propuesto por Molina y Párraga (2024), y basada en las directrices PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*)

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

garantizando un enfoque riguroso, transparente y reproducible de los resultados.

La elección de este tipo de diseño responde a la necesidad de recopilar, sintetizar y analizar de manera estructurada la información existente sobre la agricultura de precisión, su aplicación en la cadena de producción del banano, los beneficios y desafíos asociados con la adopción de estas tecnologías, así como las arquitecturas tecnológicas propuestas para su integración. Adicionalmente, el estudio permitió identificar brechas y limitaciones en los trabajos existentes, lo que respalda la pertinencia e importancia del análisis.

La metodología se desarrolló en tres fases: en la primera fase: identificación, se formularon las preguntas de investigación, definieron las palabras clave y seleccionaron las bases de datos científicas. En la segunda fase: selección, se aplicaron criterios de inclusión y exclusión para filtrar los estudios relevantes al objeto de estudio. Por último, en la fase: inclusión, se llevó a cabo el análisis y evaluación de los artículos seleccionados, extrayendo la información necesaria para responder a las preguntas de investigación planteadas.

Para facilitar el proceso metodológico, se utilizó la herramienta Parsifal para organizar las etapas de búsqueda, selección y análisis de estudios.

Fase 1. Identificación

Preguntas de investigación: Se plantearon las siguientes preguntas de investigación:

- **RQ1:** ¿Cuáles son las tecnologías de agricultura de precisión utilizadas en las diferentes fases del cultivo del banano?
- **RQ2:** ¿Qué beneficios y desafíos enfrentan los productores de banano al incorporar tecnologías de agricultura de precisión en sus procesos de producción?
- **RQ3:** ¿Se puede integrar en un sistema de producción de banano, una arquitectura de tecnologías de agricultura de precisión para maximizar su productividad?

Palabras clave: Entre las palabras clave se encuentran: cultivo de banano/plátano, agricultura de precisión, vehículos aéreos no tripulados (UAV) agrícolas, maquinaria

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

agrícola automatizada, robots agrícolas, sistemas de información geográfica (SIG), Internet de las Cosas (IoT), riego inteligente, sostenibilidad y sensores. También, se incluyeron términos relacionados con ciencia de datos e inteligencia artificial, tales como aprendizaje automático (ML: Machine Learning), aprendizaje profundo (DL: Deep Learning), big data, visión por computadora y procesamiento de lenguaje natural, incluyendo aplicaciones como chatbots.

Selección de base de datos

Se emplearon combinaciones específicas de palabras clave en bases de datos científicas reconocidas (IEEE Xplore, Scopus, Web of Science y Springer) para identificar estudios sobre la adopción de tecnologías de agricultura de precisión en la producción de banano. Las búsquedas, realizadas en inglés y español, utilizaron operadores booleanos ('AND', 'OR') y filtros personalizados por base de datos.

Fase 2. Selección

Criterios de inclusión y exclusión

En la tabla 1 se muestran los criterios seleccionados.

Tabla 1.
Criterios de selección.

Criterios de inclusión	Criterios de exclusión
<ul style="list-style-type: none">• Estudios de caso o investigaciones empíricas realizadas en regiones productoras de banano.• Documentos en cualquier idioma.• Documentos con al menos 25 referencias.• Publicaciones realizadas en los últimos cinco años.• Publicaciones en revistas arbitradas o congresos de renombre.	<ul style="list-style-type: none">• Artículos que no traten sobre el cultivo del banano• Artículos que no traten sobre agricultura de precisión.• Artículos que no aporten valor añadido.• Estudios duplicados o informes con datos repetidos.• Textos no arbitrados, blogs, informes no científicos o de fuentes no oficiales.• Publicaciones con menos de 25 referencias bibliográficas.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

-
- Investigaciones relacionadas con la producción de banano, incluso si incluye otros cultivos.
 - Estudios enfocados en tecnologías de agricultura de precisión.
 - Temas repetitivos en los documentos.
 - Investigaciones no relevantes de más de cinco años de publicación.
-

Elaboración: Los autores.

Selección de estudios

Para el proceso de selección, se identificaron 221 registros en bases de datos científicas y 6 adicionales desde sitios web y la FAO. Tras eliminar 22 duplicados y descartar 50 por otros motivos, se evaluaron inicialmente 149 estudios. Luego de revisar títulos y resúmenes, se excluyeron 84 por no cumplir con los criterios de inclusión, seleccionándose 71 para revisión completa.

Fase 3. Inclusión

Evaluación de relevancia

La evaluación de calidad de los 71 artículos se realizó por medio de 6 criterios, con tres posibles respuestas “Sí” (puntuación=2.0), “Parcialmente” (puntuación=1.0) o “No” (puntuación=0.0), de la cual, los 71 artículos obtuvieron un puntaje entre 8.0 y 12.0.

Extraer datos requeridos

Para la extracción de información se usó un formulario de extracción de datos, donde se incluía información como: Tecnologías de monitorización de la calidad del aire y del agua, Sistemas de riego automatizado, Agricultura predictiva y prescriptiva, Sensores climáticos y sistemas de predicción meteorológica, Drones para monitorización de cultivos, Sistemas de Gestión Agrícola (FMS), Tecnología de control de plagas con sensores, Tecnologías de fertilización de precisión, y Sensores de humedad y nutrientes del suelo.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

RESULTADOS

Para comprender el impacto de la investigación en agricultura de precisión aplicada al cultivo de banano, se realizó un análisis de las revistas académicas más relevantes, lo cual permitió identificar a los principales autores, fuentes de información y el nivel de calidad de las publicaciones en las que han sido difundidos estos estudios.

Las tecnologías de AP permiten mejorar la eficiencia en el uso de recursos, así como incrementar la productividad, la calidad, la rentabilidad y la sostenibilidad de la producción agrícola. Además, incluye la gestión específica del sitio del cultivo, la cual consiste en adaptar las prácticas agrícolas a la variabilidad espacial del suelo y a las condiciones climáticas particulares de cada parcela. En este sentido, la Figura 1 ilustra cómo las tecnologías están transformando el cultivo de banano en distintos países mediante la implementación de soluciones avanzadas.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

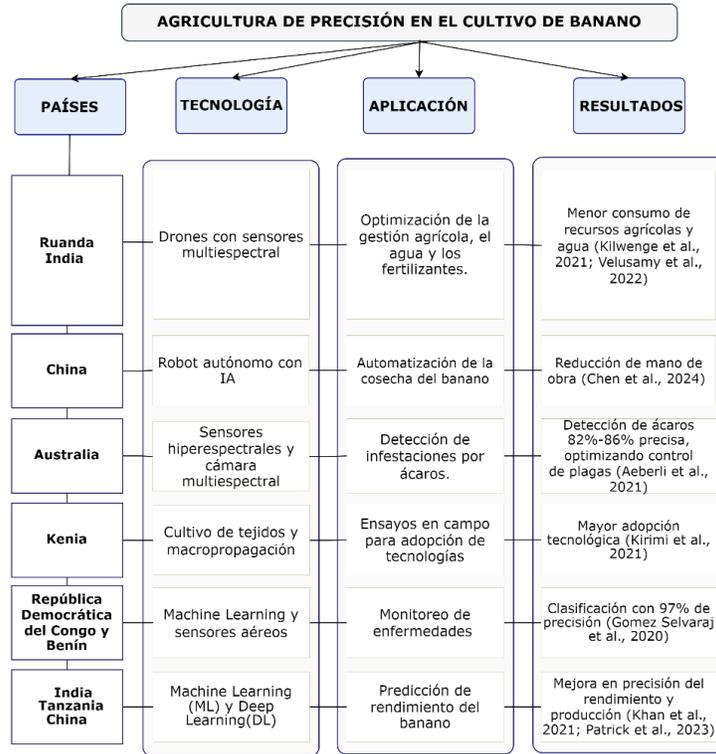


Figura 1. Tecnologías AP aplicadas por país.
Elaboración: Los autores.

A continuación, se describe las respuestas a las preguntas de investigación planteadas en este trabajo:

Tecnologías aplicadas en las fases del cultivo de banano (RQ1)

La agricultura de precisión ha revolucionado el cultivo de banano mediante la incorporación de tecnologías avanzadas que promueven la optimización de la producción y la sostenibilidad. Entre estas herramientas destacan los sensores remotos, los drones multiespectrales y los sistemas de información geográfica (SIG), los cuales permiten un monitoreo detallado de variables clave como la humedad del suelo, el estado fenológico de las plantas y la detección temprana de enfermedades o deficiencias nutricionales.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

Asimismo, la automatización de procesos como el riego y la fertilización, fundamentada en información geoespacial y datos agronómicos, permite optimizar el uso de agua y nutrientes, mejorando la productividad y reduciendo el impacto ambiental. En conjunto, estas prácticas incrementan la competitividad del cultivo en mercados globales exigentes y promueven una agricultura responsable, adaptada a los desafíos de sostenibilidad a largo plazo (Aeberli et al., 2023).

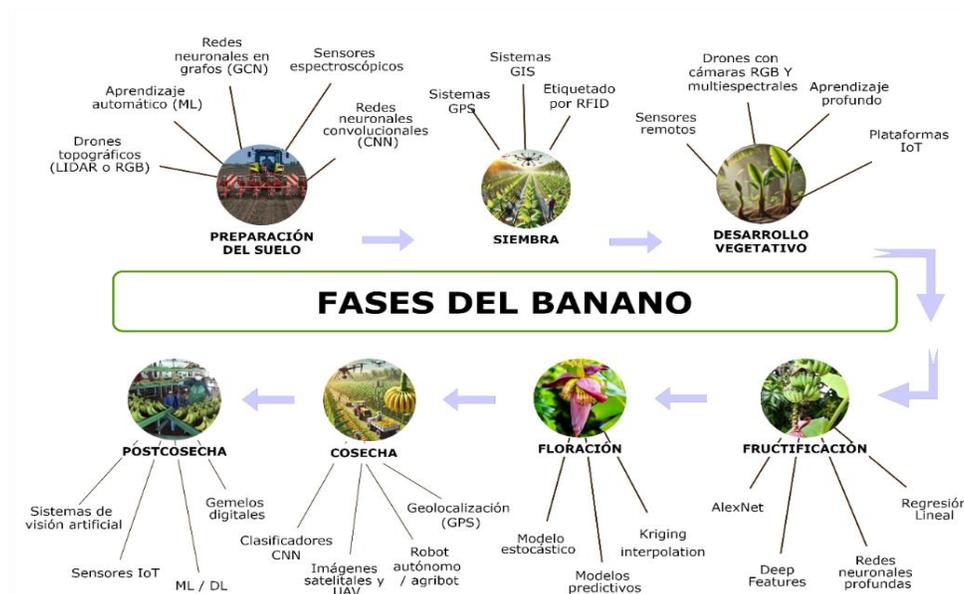


Figura 2. Tecnologías AP aplicadas por fases del cultivo.
Elaboración: Los autores.

En la figura 2, se observa la aplicación de tecnologías AP asociadas en cada etapa del cultivo de banano, desde la preparación del suelo hasta la postcosecha.

- **Preparación del suelo:** La preparación del suelo constituye una etapa fundamental para las prácticas agrícolas, que implica el análisis de sus propiedades físicas y químicas, y la nivelación el terreno. En este proceso, diversas tecnologías agrícolas desempeñan un papel clave. Por ejemplo, los sensores espectroscópicos permiten realizar análisis en tiempo real de nutrientes

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

esenciales como nitrógeno (N), fósforo (P), potasio (K) y del pH del suelo, lo que facilita ajustes inmediatos en los programas de fertilización (Najdenko et al., 2024). Asimismo, se han empleado métodos basados en aprendizaje profundo, como la regresión de mínimos cuadrados parciales (PLSR), técnicas de espectroscopía visible e infrarroja para evaluar carbono, nitrógeno y humedad del suelo, así como redes neuronales convolucionales para clasificar texturas del suelo como arena, limo y arcilla, mediante imágenes procesadas; todas estas herramientas permiten mejorar la precisión y eficiencia en la preparación del terreno (Ahmadi et al., 2021; Babalola et al., 2023). Por otro lado, las redes neuronales en grafos (GCN) han sido utilizadas para procesar de manera conjunta datos edafoclimáticos, optimizando así la planificación y gestión de las actividades agrícolas (Ayesha Barvin y Sampradeepraj, 2023).

- **Siembra y/o plantación:** La siembra implica la disposición de las plantas en el campo bajo condiciones controladas, asegurando un espacio para maximizar el aprovechamiento de los recursos y prevenir competencia. El uso de sistemas GPS/GIS mapean y planifican la disposición de las plantas, optimizando el uso del espacio y de los recursos en áreas agrícolas.
- **Desarrollo vegetativo:** Durante la fase de crecimiento vegetativo, las plantas concentran sus recursos en el desarrollo de raíces, tallos y hojas; es necesario monitorear su estado de salud y suministrar los nutrientes necesarios para alcanzar un desarrollo óptimo. Los drones equipados con cámaras RGB y multiespectrales permiten la captura de imágenes que facilitan la identificación de zonas con estrés fisiológico por deficiencias nutricionales o hídricas (Aslan et al., 2022). El uso de sensores remotos contribuye a la delimitación de áreas productivas, estimación del rendimiento y diagnóstico temprano de enfermedades. Los modelos de aprendizaje profundo permiten diagnosticar deficiencias en

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

micronutrientes, enfermedades y plagas que pueden afectar el crecimiento de las plantas, con el análisis de imágenes de hojas (Muthusamy y Ramu, 2024).

- **Floración:** La fase de floración representa un momento crítico en el ciclo de vida del banano, ya que marca el inicio de la producción de inflorescencias que darán lugar al desarrollo de los frutos, y se caracteriza por ocurrir de manera continua y asincrónica, lo cual representa un desafío para su gestión. Por lo que, se utilizan modelos estocásticos que simulan los eventos de floración en los campos y estiman la duración del ciclo de floración, para optimizar las prácticas de manejo de esta etapa. Adicionalmente, el análisis espacial mediante técnicas como *kriging* y variogramas posibilita la generación de mapas detallados de la duración del ciclo de floración, así como la detección de patrones espaciales asociados a variables como altitud, régimen de riego y variedad cultivada, lo cual contribuye a una toma de decisiones más precisa y localizada (Lamour et al., 2021).
- **Fructificación (Llenado del Racimo):** En esta etapa, es fundamental monitorear el desarrollo del racimo de banano para garantizar la formación de frutos saludables y de calidad. El uso de tecnologías como redes neuronales profundas y modelos pre-entrenados como AlexNet, han permitido clasificar el estado de madurez del fruto mediante análisis de imágenes, facilitando decisiones precisas (Aherwadi et al., 2022; Khoroshevsky et al., 2021), la visión artificial basada en deep features extrae características visuales relacionadas con tamaños y formas, mejorando la estimación del rendimiento (Fu et al., 2020). Por otro lado, la regresión lineal ha mostrado su efectividad para calcular el número total de frutos en los racimos a partir de conteos visibles, contribuyendo así a un control más preciso de la producción (Khoroshevsky et al., 2021).
- **Cosecha:** La cosecha del banano se realiza cuando los frutos alcanzan su estado fisiológico óptimo de madurez. Para ello, se han implementado robots autónomos equipados con sistemas de visión artificial que permiten automatizar el proceso de

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

recolección mediante la detección de racimos y la estimación del punto óptimo de corte, reduciendo la intervención humana y los daños mecánicos en el fruto (Chen et al., 2024). Además, los clasificadores CNN han sido empleados para evaluar el nivel de madurez del banano, categorizándolo en diferentes estados que van desde verde hasta completamente maduro, lo cual facilita su manejo postcosecha y distribución según los requerimientos del mercado (Yang et al., 2024; Almeyda e Ipanaqué, 2022). Asimismo, el procesamiento de imágenes satelitales y captadas por UAVs permite generar mapas de rendimiento geoespaciales para optimizar la planificación de la cosecha, el uso de recursos y la logística de distribución (Fu et al., 2022; Ghazal et al., 2024).

- **Postcosecha:** La fase de postcosecha comprende actividades esenciales como el lavado, clasificación, empaque y almacenamiento de los bananos, con el objetivo de preservar la calidad del producto para satisfacer las demandas del mercado local e internacional. Los sistemas de visión artificial clasifican los frutos según estándares de calidad, detectando defectos en bananos destinados a exportación o consumo local y los gemelos digitales predicen la evolución de la calidad del banano durante el almacenamiento, considerando factores críticos como temperatura y humedad (Ghazal et al., 2024; Melesse et al., 2022). Los modelos de ML y DL clasifican los bananos en categorías específicas basándose en características visuales, optimizan y agilizan el proceso de selección, detectan defectos en la piel y reducen pérdidas postcosecha.

Actividades de gestión del cultivo de banano

En el mantenimiento del cultivo de banano, las tecnologías de agricultura de precisión permiten realizar un seguimiento constante del estado del cultivo y aplicar insumos (agua, fertilizantes, pesticidas) de forma eficiente, localizada y basada en datos reales. En la Figura 3, se muestran algunas tecnologías para estos procesos.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román



Figura 3. Tecnologías AP aplicadas por fases del cultivo.
Elaboración: Los autores.

A continuación, se describen las tecnologías que se pueden aplicar en las actividades de gestión del cultivo.

- **Monitoreo del cultivo**

El monitoreo continuo del cultivo es esencial para evaluar el estado fisiológico de las plantas, identificar de manera oportuna problemas sanitarios o nutricionales, y respaldar decisiones estratégicas orientadas a maximizar la productividad. Tecnologías avanzadas como los vehículos aéreos no tripulados (UAVs o drones) permiten capturar imágenes aéreas multiespectrales y térmicas, facilitando la identificación de anomalías en extensas áreas de cultivo (Aeberli et al., 2021; Bouguettaya et al., 2023). Complementariamente, los modelos predictivos basados en series temporales y aprendizaje profundo como SARIMAX y LSTM, procesan datos históricos y variables climáticas para proyectar rendimientos futuros con mayor precisión (Patrick et al., 2023). Además, el uso de robots agrícolas (agribots) equipados con sensores y sistemas de visión artificial posibilita el monitoreo automatizado del desarrollo del cultivo, la detección de enfermedades como la Sigatoka, y la evaluación del estado de los frutos mediante imágenes aéreas e infrarrojas (Almeyda e Ipanaqué, 2022, Krishnan et al., 2024). Estos sistemas de detección automatizada reducen la dependencia de inspecciones visuales manuales, optimizando

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

el tiempo de respuesta y aumentando la eficiencia operativa en grandes plantaciones (Sangeetha et al., 2023).

Adicionalmente, tecnologías basadas en inteligencia conversacional como los chatbots agrícolas; por ejemplo, Agriculture TalkBot, brindan asistencia personalizada a los agricultores mediante interfaces auditivas. (Calvo-Valverde et al., 2023).

- **Control de Plagas y Enfermedades**

Esta abarca todo el ciclo del cultivo, se enfoca en prevenir, controlar plagas y enfermedades que amenazan la productividad y calidad del banano. Los modelos de aprendizaje profundo detectan enfermedades mediante análisis automatizado de imágenes, ofreciendo diagnósticos rápidos (Balafas et al., 2023; Ghazal et al., 2024, Bouguettaya et al., 2023), mientras que modelos predictivos basados en aprendizaje automático anticipan plagas como trips, usando datos de clima y suelo de sensores IoT (Almeyda e Ipanaqué, 2022). Por otro lado la espectroscopía de campo evalúa daños foliares por plagas o enfermedades para una respuesta oportuna (Aeberli et al., 2022), del mismo modo un chatbot con redes neuronales ayuda a agricultores a identificar enfermedades y aconseja soluciones, mejorando la toma de decisiones (Calvo-Valverde et al., 2023). Además, el análisis de Big Data y la visualización de información climática y de suelo permiten predecir brotes como la Sigatoka Negra, y finalmente la minería de datos descubre relaciones en datos genómicos y ambientales, optimizando la selección de cultivos resilientes a enfermedades (Segall et al., 2024).

- **Fertilización, Riego y Manejo de Nutrientes**

El objetivo de esta fase es proporcionar a las plantas los nutrientes y el agua necesarios para su desarrollo óptimo, implementando estrategias específicas que optimicen la fertilización y los sistemas de riego, logrando un balance adecuado entre eficiencia y sostenibilidad, para lo cual las redes de sensores inalámbricos permiten monitorear en tiempo real factores como humedad y temperatura, lo que ayuda a optimizar el riego y mantener las condiciones ideales para las plantas (Faqir et al., 2024). Los sistemas de

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

riego inteligente regulan automáticamente el flujo de agua en función de las necesidades específicas del cultivo, aumentando la eficiencia y reduciendo el desperdicio (Ghazal et al., 2024; Talaviya et al., 2020). También las Redes Neuronales Convolucionales (CNN) analizan imágenes de las hojas del banano, clasificándolas según deficiencias de nutrientes como nitrógeno, fósforo, potasio, calcio y hierro, lo que mejora la precisión en la gestión nutricional (Mkhatshwa et al., 2024; Nasim et al., 2023).

Beneficios y desafíos de adopción de las tecnologías (RQ2)

El desarrollo de tecnologías aplicadas a la producción agrícola ha permitido mejorar significativamente los procesos y optimizar la gestión de los cultivos. No obstante, su adopción no es automática, y se encuentra condicionada por diversos factores de índole económica, técnica y social. Estas barreras pueden limitar especialmente su implementación en contextos con menor capacidad de inversión, como es el caso de los pequeños productores y países en vías de desarrollo.

A continuación, en la Figura 4, se analizan los principales beneficios y desafíos asociados con la adopción de tecnologías de precisión en la agricultura.

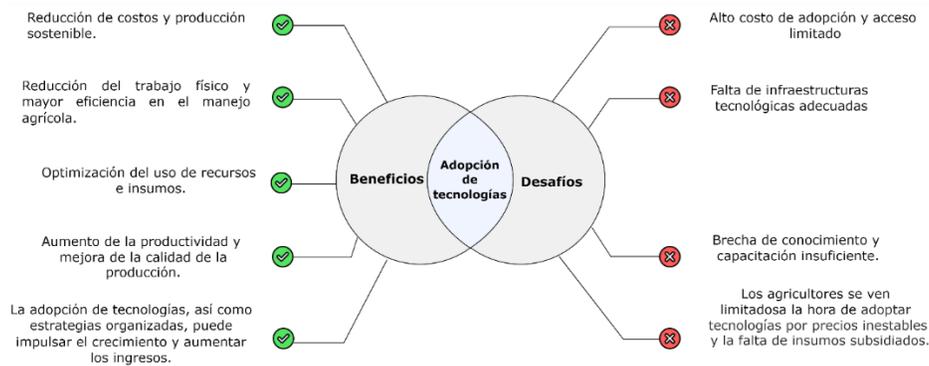


Figura 4. Beneficios y Desafíos de adopción de tecnologías.
Elaboración: Los autores.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

Arquitecturas de sistemas de producción bananera (RQ3)

Modelos referenciales de arquitecturas para agricultura de precisión

Han sugerido varias arquitecturas de referencia para diseñar sistemas de producción agrícola fundamentados en IoT e IA, los cuales han sido usados en estudios para la agricultura de precisión. Se destaca trabajos como Mazon Olivo y Pan (2022), que presenta un modelo de tres capas que se centra en la gestión de datos a través de Middleware IoT orientado al almacenamiento y procesamiento de grandes cantidades de información en entornos agrícolas. En una propuesta más reciente, Mazón Olivo (2023) desarrolló la arquitectura GIA-PA, que integra edge computing, redes de sensores y procesamiento en la nube, con un enfoque específico en el monitoreo y control inteligente del cultivo de banano.

Otro enfoque para la producción agrícola ha sido la arquitectura AgriFusion, que está diseñada para integrar diversas tecnologías emergentes con el objetivo de optimizar la agricultura de precisión y mejorar la eficiencia en la gestión agrícola, por lo que se basa en una estructura de tres capas. (Singh et al., 2021).

Arquitectura propuesta de agricultura de precisión para la gestión de un cultivo de banano

La implementación de la agricultura de precisión en el sector agrario ha impulsado el desarrollo de arquitecturas tecnológicas que permiten la integración de sensores, redes de comunicación y plataformas de análisis de datos. Sin embargo, a pesar de estos avances, se ha identificado una limitada disponibilidad de propuestas arquitectónicas orientadas específicamente al cultivo de banano, lo que representa una barrera para la adopción efectiva de estas tecnologías en este sector. En este contexto, la propuesta arquitectónica representada en la figura 5, sigue un enfoque de tres capas (percepción, red y aplicación), alineado con modelos ampliamente aceptados en la literatura, asegurando una integración eficiente de dispositivos y herramientas de análisis avanzado para la toma de decisiones.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

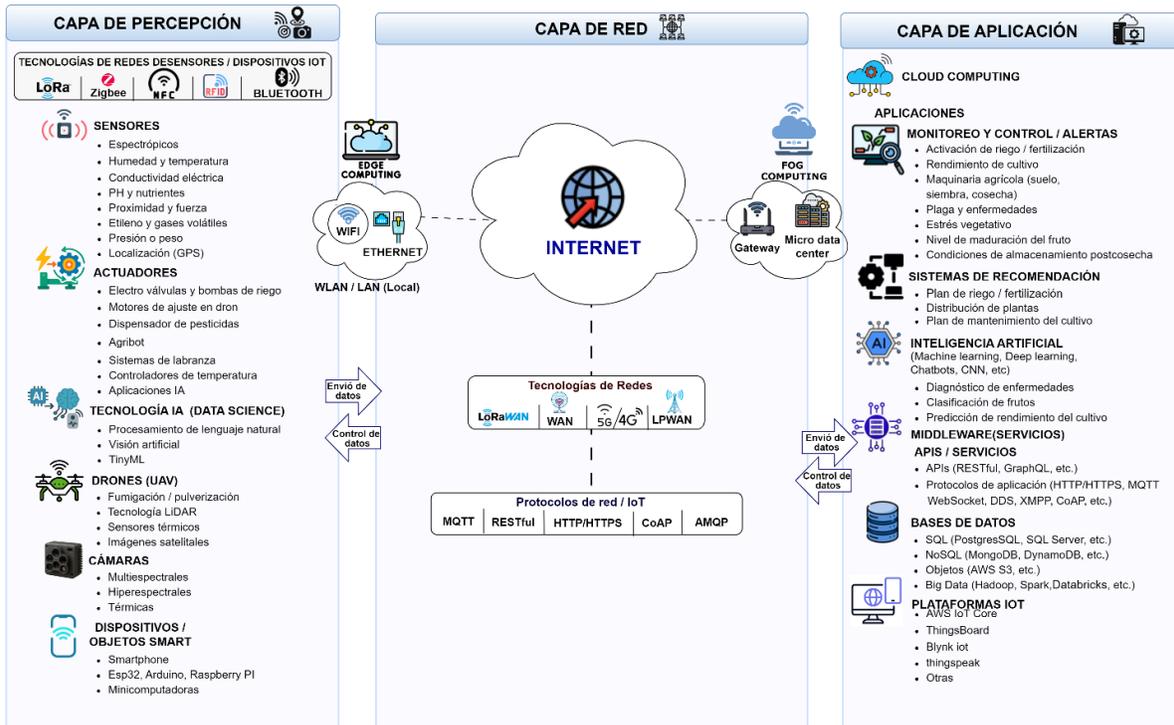


Figura 5. Arquitectura de agricultura de precisión con tecnologías de IoT e IA para gestión de cultivos de banano.

Elaboración: Los autores.

A continuación, se describe cada una de las capas de la arquitectura propuesta.

La Capa de Percepción constituye la base del sistema, la cual se encarga de capturar información directamente del entorno a través de múltiples dispositivos y sensores. Esta capa utiliza tecnologías de redes sensoriales como Zigbee, NFC, RFID y Bluetooth para vincular los dispositivos en el campo.

Se incluyen sensores especializados que miden variables clave como: Humedad del suelo, Temperatura, pH y nutrientes, Conductividad eléctrica, Proximidad y fuerza, Presión ambiental o del suelo, Gases volátiles, y Localización GPS. La figura 6, muestra los modelos de sensores, actuadores, drones y tecnologías IA utilizados en esta capa.

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

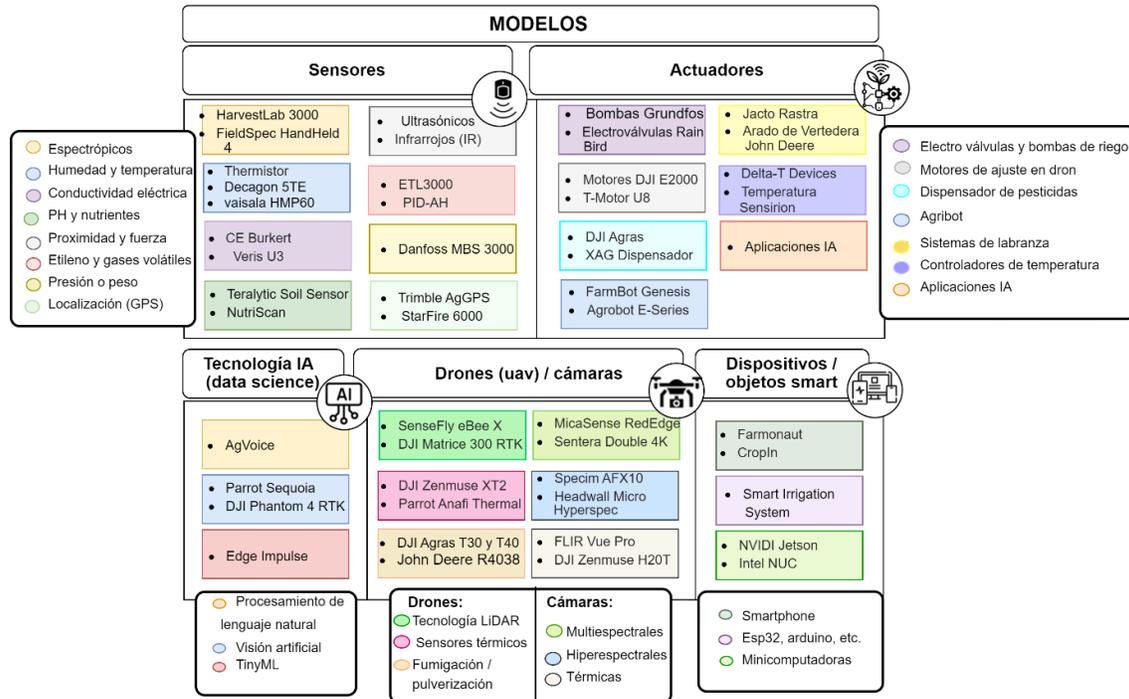


Figura 6. Modelos de dispositivos (Capa Percepción).

Elaboración: Los autores.

También se emplean actuadores como válvulas electrónicas, bombas de riego, motores en drones y dispensadores de pesticidas, que permiten realizar acciones automáticas según las condiciones detectadas (Ghazal et al., 2024; Talaviya et al., 2020). Además, se utilizan drones equipados con tecnología de fumigación y sensores LiDAR, cámaras térmicas y satelitales, que facilitan una observación aérea avanzada del cultivo (Bouguettaya et al., 2023). Se integran herramientas de inteligencia artificial como visión artificial, procesamiento de lenguaje natural (PLN) y TinyML, para ejecutar modelos de análisis directamente en dispositivos de bajo consumo energético (Calvo-Valverde et al., 2023; Nasim et al., 2023). Finalmente, se incluyen dispositivos inteligentes como smartphones, placas de desarrollo ESP32, Arduino, Raspberry Pi y minicomputadoras, que amplían la capacidad del sistema para monitorear, procesar y actuar en tiempo real (Mazón-Olivo, 2023; Singh et al., 2021).

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

La Capa de Red facilita el envío y procesamiento de datos capturados mediante tecnologías de comunicación como WiFi, Ethernet, LoRaWAN, 4G, 5G, LPWAN y WAN, posibilitando la transmisión de información a centros de procesamiento locales o remotos (Edge Computing) para procesar los datos cerca del lugar donde se generan, computación en niebla (Fog Computing) a través de microcentros de datos (micro data centers) para análisis intermedio, o computación en la nube (Cloud Computing) para tareas más complejas y almacenamiento masivo (Mazon Olivo y Pan, 2022; Singh et al., 2021). La interoperabilidad de dispositivos se logra con protocolos IoT como MQTT, CoAP, HTTP/HTTPS, AMQP y RESTful, que habilitan el control y la transferencia segura y eficiente de datos en entornos agrícolas inteligentes (Ghazal et al., 2024; Mazón-Olivo, 2023).

La **Capa de Aplicación** analiza los datos recibidos y ofrece servicios inteligentes al usuario, en ella se crean aplicaciones para el monitoreo y control de variables agrícolas como el riego, la fertilización, el estrés vegetativo, las condiciones del suelo, el rendimiento del cultivo, el estado de las maquinarias y el almacenamiento de los productos cosechados (Faqir et al., 2024; Ghazal et al., 2024). También se integran sistemas de recomendación que ayudan en la toma de decisiones sobre riego, fertilización, distribución de plantas o planes de mantenimiento del cultivo, entre otros (Mkhatshwa et al., 2024; Patrick et al., 2023). La inteligencia artificial juega un papel esencial en esta capa, empleando algoritmos de aprendizaje automático para diagnóstico de enfermedades, clasificación de frutos, predicción de rendimiento y demás (Alexopoulos et al., 2023). Además, se dispone de servicios middleware con APIs REST, GraphQL, protocolos de comunicación (WebSocket, DDS, XMPP), bases de datos SQL, NoSQL, objetos y big data para almacenar y consultar la información, así como plataformas IoT como AWS IoT Core, ThingsBoard, Blynk IoT y ThingSpeak que permiten gestionar todo el ecosistema de manera centralizada (Mazón-Olivo, 2023; Mazon Olivo y Pan, 2022; Singh et al., 2021).

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

CONCLUSIONES

El análisis de 71 estudios recientes permitió identificar las tecnologías más relevantes aplicadas en cada fase del proceso productivo, destacando el uso de sensores, vehículos aéreos no tripulados (UAVs), inteligencia artificial (IA) e Internet de las Cosas (IoT) como herramientas fundamentales para el monitoreo, control y toma de decisiones.

A pesar del avance tecnológico, la adopción de estas herramientas presenta desafíos significativos, especialmente en regiones con limitaciones económicas, técnicas y sociales. Factores como la falta de infraestructura digital, la escasa capacitación técnica y el alto costo de implementación dificultan la incorporación de estas soluciones.

Como contribución, se propuso una arquitectura de referencia estructurada en tres capas (percepción, red y aplicación), la cual integra tecnologías emergentes y facilita su implementación de forma escalable y adaptada al cultivo de banano. Esta arquitectura permite consolidar datos en tiempo real, mejorar la toma de decisiones y optimizar el uso de recursos, aportando así a la sostenibilidad y competitividad del sector.

FINANCIAMIENTO

Esta investigación fue financiada por la Universidad Técnica de Machala, Grupo de Investigación AutoMathTIC, Proyecto de Investigación con Resolución No. 0244-2024-CU-SO-13: “Adopción de las Tecnologías de Inteligencia Artificial e Internet de las Cosas en el Sector Agropecuario de la Provincia de El Oro”.

AGRADECIMIENTO

Agradecemos a la Universidad Técnica de Machala por financiar este trabajo de investigación.

REFERENCIAS CONSULTADAS

- Aeberli, A., Johansen, K., Robson, A., Lamb, D. W., & Phinn, S. (2021). Detection of Banana Plants Using Multi-Temporal Multispectral UAV Imagery. *Remote Sensing*, 13(11). <https://doi.org/10.3390/rs13112123>
- Aeberli, A., Phinn, S., Johansen, K., Robson, A., & Lamb, D. W. (2023). Characterisation of Banana Plant Growth Using High-Spatiotemporal-Resolution Multispectral UAV Imagery. *Remote Sensing*, 15(3), 679. <https://doi.org/10.3390/rs15030679>
- Aeberli, A., Robson, A., Phinn, S., Lamb, D. W., & Johansen, K. (2022). A Comparison of Analytical Approaches for the Spectral Discrimination and Characterisation of Mite Infestations on Banana Plants. *Remote Sensing*, 14(21), 5467. <https://doi.org/10.3390/rs14215467>
- Aherwadi, N., Mittal, U., Singla, J., Jhanjhi, N. Z., Yassine, A., & Hossain, M. S. (2022). Prediction of Fruit Maturity, Quality, and Its Life Using Deep Learning Algorithms. *Electronics*, 11(24), 4100. <https://doi.org/10.3390/electronics11244100>
- Ahmadi, A., Emami, M., Daccache, A., & He, L. (2021). Soil Properties Prediction for Precision Agriculture Using Visible and Near-Infrared Spectroscopy: A Systematic Review and Meta-Analysis. *Agronomy*, 11(3), 433. <https://doi.org/10.3390/agronomy11030433>
- Akkem, Y., Biswas, S. K., & Varanasi, A. (2023). Smart farming using artificial intelligence: A review. *Engineering Applications of Artificial Intelligence*, 120, 105899. <https://doi.org/10.1016/j.engappai.2023.105899>
- Alexopoulos, A., Koutras, K., Ali, S. B., Puccio, S., Carella, A., Ottaviano, R., & Kalogeras, A. (2023). Complementary Use of Ground-Based Proximal Sensing and Airborne/Spaceborne Remote Sensing Techniques in Precision Agriculture: A Systematic Review. *Agronomy*, 13(7), 1942. <https://doi.org/10.3390/agronomy13071942>
- Almeyda, E., & Ipanaqué, W. (2022). Recent developments of artificial intelligence for banana: application areas, learning algorithms, and future challenges. *Engenharia Agrícola*, 42, e20210144. <https://doi.org/10.1590/1809-4430-Eng.Agric.v42nepe20210144/2022>

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

- Aslan, M. F., Durdu, A., Sabanci, K., Ropelewska, E., & Gültekin, S. S. (2022). A Comprehensive Survey of the Recent Studies with UAV for Precision Agriculture in Open Fields and Greenhouses. *Applied Sciences*, 12(3), 1047. <https://doi.org/10.3390/app12031047>
- Ayesha Barvin, P., & Sampradeepraj, T. (2023). Crop Recommendation Systems Based on Soil and Environmental Factors Using Graph Convolution Neural Network: A Systematic Literature Review. *Engineering Proceedings*, 58(1), 97. <https://doi.org/10.3390/ecsa-10-16010>
- Babalola, E.-O., Asad, M. H., & Bais, A. (2023). Soil Surface Texture Classification Using RGB Images Acquired Under Uncontrolled Field Conditions. *IEEE Access*, 11, 67140-67155. <https://doi.org/10.1109/ACCESS.2023.3290907>
- Balafas, V., Karantoumanis, E., Louta, M., & Ploskas, N. (2023). Machine Learning and Deep Learning for Plant Disease Classification and Detection. *IEEE Access*, 11, 114352-114377. <https://doi.org/10.1109/ACCESS.2023.3324722>
- Bouguettaya, A., Zarzour, H., Kechida, A., & Taberkit, A. M. (2023). A survey on deep learning-based identification of plant and crop diseases from UAV-based aerial images. *Cluster Computing*, 26(2), 1297-1317. <https://doi.org/10.1007/s10586-022-03627-x>
- Calvo-Valverde, L. A., Rojas-Salazar, K., Hidalgo-Rodríguez, J. F., Mora, V., Sandoval, J. A., Bolaños-Céspedes, E., y Quirós, C. (2023). Un estudio de tecnologías sobre agentes conversacionales para la asistencia de agricultores del plátano. *Revista Tecnología En Marcha*, 36(4), 3-18. <https://doi.org/10.18845/tm.v36i4.6242>
- Chen, T., Zhang, S., Chen, J., Fu, G., Chen, Y., & Zhu, L. (2024). Development, Integration, and Field Experiment Optimization of an Autonomous Banana-Picking Robot. *Agriculture*, 14(8), 1389. <https://doi.org/10.3390/agriculture14081389>
- FAO. (2024a). *Banano. Análisis del Mercado 2023*. <https://n9.cl/paecd6>
- FAO. (2024b, marzo 12). La FAO pide más cooperación en el sector bananero, de importancia para algunos de los países menos adelantados y los países de bajos ingresos y con déficit de alimentos, así como para los pequeños agricultores. Newsroom. <https://n9.cl/e15i1>
- FAO. (2024c, agosto 26). *Bananas | Markets and Trade | Food and Agriculture Organization of the United Nations*. MarketsAndTrade. <https://n9.cl/rb9cl>

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

- Faqir, Y., Qayoom, A., Erasmus, E., Schutte-Smith, M., & Visser, H. G. (2024). A review on the application of advanced soil and plant sensors in the agriculture sector. *Computers and Electronics in Agriculture*, 226, 109385. <https://doi.org/10.1016/j.compag.2024.109385>
- Fu, L., Duan, J., Zou, X., Lin, J., Zhao, L., Li, J., & Yang, Z. (2020). Fast and Accurate Detection of Banana Fruits in Complex Background Orchards. *IEEE Access*, 8, 196835-196846. <https://doi.org/10.1109/ACCESS.2020.3029215>
- Fu, L., Yang, Z., Wu, F., Zou, X., Lin, J., Cao, Y., & Duan, J. (2022). YOLO-Banana: A Lightweight Neural Network for Rapid Detection of Banana Bunches and Stalks in the Natural Environment. *Agronomy*, 12(2), 391. <https://doi.org/10.3390/agronomy12020391>
- Gao, D., Sun, Q., Hu, B., & Zhang, S. (2020). A Framework for Agricultural Pest and Disease Monitoring Based on Internet-of-Things and Unmanned Aerial Vehicles. *Sensors*, 20(5), 1487. <https://doi.org/10.3390/s20051487>
- Ghazal, S., Munir, A., & Qureshi, W. S. (2024). Computer vision in smart agriculture and precision farming: Techniques and applications. *Artificial Intelligence in Agriculture*, 13, 64-83. <https://doi.org/10.1016/j.aiia.2024.06.004>
- Khan, T., Sherazi, H. H. R., Ali, M., Letchmunan, S., & Butt, U. M. (2021). Deep Learning-Based Growth Prediction System: A Use Case of China Agriculture. *Agronomy*, 11(8), 1551. <https://doi.org/10.3390/agronomy11081551>
- Khoroshevsky, F., Khoroshevsky, S., & Bar-Hillel, A. (2021). Parts-per-Object Count in Agricultural Images: Solving Phenotyping Problems via a Single Deep Neural Network. *Remote Sensing*, 13(13), 2496. <https://doi.org/10.3390/rs13132496>
- Kirimi, F. K., Onyari, C. N., Njeru, L. K., & Mogaka, H. R. (2021). Effect of on-farm testing on adoption of banana production technologies among smallholder farmers in Meru region, Kenya. *Journal of Agribusiness in Developing and Emerging Economies*, 13(1), 90-105. <https://doi.org/10.1108/JADEE-04-2021-0100>
- Krishnan, S., Karuppasamyandian, M., Chandran, R. R., & Devaraj, D. (2024). Revolutionizing agriculture: A comprehensive review of agribots, machine learning, and deep learning in meeting global food demands. *Engineering Research Express*, 6(3), 032201. <https://doi.org/10.1088/2631-8695/ad59f6>

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

- Lamour, J., Le Moguédec, G., Naud, O., Lechaudel, M., Taylor, J., & Tisseyre, B. (2021). Evaluating the drivers of banana flowering cycle duration using a stochastic model and on farm production data. *Precision Agriculture*, 22(3), 873-896. <https://doi.org/10.1007/s11119-020-09762-y>
- Mazón Olivo, B. (2023). *Una arquitectura para la recopilación, integración y análisis de información en el contexto de la Internet de las Cosas. Caso estudio: Aplicaciones en el sector agrícola*. [Tesis Doctoral, Universidad de Coruña]. Repositorio Universidade Coruña <https://ruc.udc.es/dspace/handle/2183/33729>
- Mazon Olivo, B., & Pan, A. (2022). Internet of Things: State-of-the-art, Computing Paradigms and Reference Architectures. *IEEE Latin America Transactions*, 20(1), 49-63. <https://doi.org/10.1109/TLA.2022.9662173>
- Melesse, T. Y., Bollo, M., Pasquale, V. D., Centro, F., & Riemma, S. (2022). Machine Learning-Based Digital Twin for Monitoring Fruit Quality Evolution. *Procedia Computer Science*, 200, 13-20. <https://doi.org/10.1016/j.procs.2022.01.200>
- Mkhatshwa, J., Kavu, T., & Daramola, O. (2024). Analysing the Performance and Interpretability of CNN-Based Architectures for Plant Nutrient Deficiency Identification. *Computation*, 12(6), 113. <https://doi.org/10.3390/computation12060113>
- Molina, E., & Parraga-Alava, J. (2024). Artificial Neural Networks for Classification Tasks: A Systematic Literature Review. *Enfoque UTE*, 15(4), 1–10. <https://doi.org/10.29019/enfoqueute.1058>
- Muthusamy, S., & Ramu, S. P. (2024). IncepV3Dense: Deep Ensemble Based Average Learning Strategy for Identification of Micro-Nutrient Deficiency in Banana Crop. *IEEE Access*, 12, 73779-73792. <https://doi.org/10.1109/ACCESS.2024.3405027>
- Najdenko, E., Lorenz, F., Dittert, K., & Olf, H. W. (2024). Rapid in-field soil analysis of plant-available nutrients and pH for precision agriculture—A review. *Precision Agriculture*, 25(6), 3189-3218. <https://doi.org/10.1007/s11119-024-10181-6>
- Nasim, S., Rashid, M., Syed, S. A., & Brohi, I. (2023). Artificial intelligence techniques for the pest detection in banana field: a systematic review. *Pakistan Journal of Biotechnology*, 20(02), 209-223. <https://doi.org/10.34016/pjbt.2023.20.02.746>

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

- Nowak, B. (2021). Precision Agriculture: Where do We Stand? A Review of the Adoption of Precision Agriculture Technologies on Field Crops Farms in Developed Countries. *Agricultural Research*, 10(4), 515-522. <https://doi.org/10.1007/s40003-021-00539-x>
- OEC. (2024). *Plátanos frescos o secos (HS): Comercio, Exportadores e Importadores*. Observatorio de Complejidad Económica. <https://n9.cl/ya70gg>
- Patrick, S., Mirau, S., Mbalawata, I., & Leo, J. (2023). Time series and ensemble models to forecast banana crop yield in Tanzania, considering the effects of climate change. *Resources, Environment and Sustainability*, 14, 100138. <https://doi.org/10.1016/j.resenv.2023.100138>
- Ramírez-Orellana, A., Ruiz-Palomo, D., Rojo-Ramírez, A., & Burgos-Burgos, J. E. (2021). The Ecuadorian Banana Farms Managers' Perceptions: Innovation as a Driver of Environmental Sustainability Practices. *Agriculture*, 11(3), 213. <https://doi.org/10.3390/agriculture11030213>
- Rosero, L. C. C., Hernandez, G. L., Almanza, K. M., & Cuautle, J. J. A. F. (2024). Sensores Electrónicos en la Agricultura de Precisión. *Ideas en Ciencias de la Ingeniería*, 2(1), 4-16. <https://doi.org/10.36677/ideaseningeneria.v2i1.22176>
- Segall, R. S., Takahashi, S., & Rajbhandari, P. (2024). Big Data Visualization for Black Sigatoka Disease of Bananas and Pathogen–Host Interactions (PHI) of Other Plants. *International Journal of Applied Research in Bioinformatics (IJARB)*, 13(1), 1-22. <https://doi.org/10.4018/IJARB.361940>
- Singh, R. K., Berkvens, R., & Weyn, M. (2021). AgriFusion: An Architecture for IoT and Emerging Technologies Based on a Precision Agriculture Survey. *IEEE Access*, 9, 136253-136283. <https://doi.org/10.1109/ACCESS.2021.3116814>
- Talaviya, T., Shah, D., Patel, N., Yagnik, H., & Shah, M. (2020). Implementation of artificial intelligence in agriculture for optimisation of irrigation and application of pesticides and herbicides. *Artificial Intelligence in Agriculture*, 4, 58-73. <https://doi.org/10.1016/j.aiia.2020.04.002>
- Yang, L., Cui, B., Wu, J., Xiao, X., Luo, Y., Peng, Q., & Zhang, Y. (2024). Automatic Detection of Banana Maturity—Application of Image Recognition in Agricultural Production. *Processes*, 12(4), 799. <https://doi.org/10.3390/pr12040799>

Cristhel Valeria Romero-García; Carmen Marlene Saraguro-Reyes; Bertha Eugenia Mazon-Olivo; Rodrigo Fernando Morocho-Román

©2025 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).