

CIENTÍFICA

Revista de Investigación en Tecnologías
de Información y Comunicación Aplicadas

cedia

14 de julio, 2026, Cuenca, Ecuador



ISSN 3151-8435

01

*Tecnologías de la información y
comunicación aplicadas a la*
AGRICULTURA DE PRECISIÓN

CIENTÍFICA

Revista de Investigación en Tecnologías
de Información y Comunicación Aplicadas


cedia

Cuenca, Ecuador

Vol. 1, Núm. 1

Julio, 14, 2026

ISSN: 3151-8435



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

cedia | Editorial

cedia

Autoridades CEDIA

Cecilia Paredes Verduga, Ph. D. – Presidenta de la Corporación Ecuatoriana para la Investigación y la Academia, CEDIA.

Juan Pablo Carvallo, Ph. D. – Director Ejecutivo de la Corporación Ecuatoriana para la Investigación y la Academia, CEDIA.

Gabriela Cáceres Torres, MSc. Jefa del Área de Innovación y Transferencia Tecnológica de la Corporación Ecuatoriana para la Investigación y la Academia, CEDIA.

Comité editorial

Editor en jefe: Juan Pablo Carvallo, Ph. D. – Director Ejecutivo CEDIA

Editor invitado: Carlos Alberto Ortega-Ojeda, Ph. D. – Universidad Central del Ecuador

Consejo de redacción:

Carlos Alario-Hoyos, Ph. D. – Universidad Carlos III de Madrid
<https://orcid.org/0000-0002-3082-0814> | calario@it.uc3m.es

Linda Guamán, Ph. D. – Universidad UTE
<https://orcid.org/0000-0002-3756-2387> | linda.guaman@ute.edu.ec

Wilmar Hernández Perdomo, Ph. D. – Universidad de las Américas
<https://orcid.org/0000-0003-4643-8377> | wilmar.hernandez@udla.edu.ec

Caroline Bacquet, Ph. D. – Universidad Regional Amazónica Ikiam
<https://orcid.org/0000-0002-1954-1806> | caroline.bacquet@ikiam.edu.ec

Roberto Martínez-Maldonado, Ph. D. – Monash University
<https://orcid.org/0000-0002-8375-1816> | Roberto.MartinezMaldonado@monash.edu

Andrés Caicedo, Ph. D. – Universidad San Francisco de Quito
<https://orcid.org/0000-0001-8821-0333> | acaicedo@usfq.edu.ec

Santiago Berrezueta-Guzman, Ph. D. – Technical University of Munich
<https://orcid.org/0000-0001-5559-2056> | s.berrezueta@tum.de

María del Pilar Cornejo Rodríguez, Ph. D. – Escuela Superior Politécnica del Litoral, ESPOL
<https://orcid.org/0000-0003-4198-2904> | pcornejo@espol.edu.ec

Xavier Franch, Ph. D. – Universitat Politècnica de Catalunya
<https://orcid.org/0000-0001-9733-8830> | xavier.franch@upc.edu

Cecilia Paredes, Ph. D. – Escuela Superior Politécnica del Litoral, ESPOL
<https://orcid.org/0000-0002-7857-6793> | cparedes@espol.edu.ec

Juan Pablo Carvallo, Ph. D. – CEDIA
<https://orcid.org/0000-0001-6678-4774> | jpcarvallo@cedia.org.ec

Carlos Alberto Ortega-Ojeda, Ph. D. – Universidad Central del Ecuador
<https://orcid.org/0000-0002-3930-594X> | caortega@uce.edu.ec

Equipo editorial

Laura Malache Silva, MSc. – Secretaría editorial, Editorial CEDIA

Andrea Urdiales Carchipulla, Lcda. – Correctora de estilo, Editorial CEDIA

Daniel Peña, Dis. – Diseñador gráfico, Editorial CEDIA

Editorial CEDIA

Gonzalo Cordero 2-122

Cuenca, Ecuador

Contacto: cientifica@cedia.org.ec

Sitio web: <https://cientifica.cedia.edu.ec/>

La Revista Científica de CEDIA es de acceso abierto inmediato. Todos los artículos se publican bajo la licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0), que permite leer, descargar, copiar, distribuir, imprimir, buscar o enlazar los textos completos, así como usarlos para cualquier propósito lícito, siempre que se cite al autor y a la revista como fuente original. Los autores conservan los derechos de autor de sus obras y ceden a Editorial CEDIA el derecho de la primera publicación. La revista sigue los lineamientos del Committee on Publication Ethics (COPE).

Los contenidos de la revista se preservan mediante asignación de DOI a través de Crossref, uso de formatos accesibles (PDF/A, HTML, XML-JATS) y almacenamiento descentralizado en repositorios de CEDIA. Se emplean metadatos estandarizados Dublin Core y OAI-PMH para garantizar la recuperación permanente de los archivos.

IDENTIFICADORES



08 CARTA DEL EDITOR EN JEFE

12 EDITORIAL

18 ARTÍCULOS CIENTÍFICOS ORIGINALES

- 19** **Sostenibilidad y agricultura inteligente en los sistemas agrivoltaicos y off-grid de Israel como modelo para la región andina de Ecuador**
/ Sustainability and smart agriculture on agrivoltaic and off-grid systems in Israel as a model for the andean region of Ecuador
Rafael Alexander Cordova Uvidia, Roberto Arias-Hinojosa
- 59** **Sistema portátil de sensores para la medición de nutrientes NPK en cultivos de café orientado a la agricultura de precisión en Loja, Ecuador**
/ Portable sensor system for measuring NPK nutrients in coffee crops, designed for precision agriculture in Loja, Ecuador
Franklin Gustavo Jiménez Peralta, Marianela del Cisne Carrión González
- 103** **Contraste entre TaurusWebs y laboratorio para la estimación bromatológica de pasto Rodas (Pennisetum sp.): Estudio de caso en Santa Ana**
/ Comparison between TaurusWebs and a laboratory for the bromatological analysis of Rodas grass (Pennisetum sp.): A case study in Santa Ana
Victoria Delgado Tejena, Denzel Chevez Paredes, Diego Nevárez Pérez
- 194** **Innovación en agricultura de precisión: panorama de patentes**
/ Innovation in precision agriculture: patent landscape
Gabriela Valarezo Álvarez, Gisselle Soto Minchalo, Francisco Álvarez Arévalo
- 246** **Arquitecturas YOLO y RF-DETR para el diagnóstico temprano de enfermedades en Solanum tuberosum L.**
/ YOLO and RF-DETR architectures for early disease diagnosis in Solanum tuberosum L.
Manolo Sebastián Muñoz-Espinoza

304 REVISIONES SISTEMÁTICAS

- 305** Floricultura 4.0 en el Ecuador: retos y directrices para la integración de tecnologías digitales y políticas públicas en el mejoramiento genético y la innovación productiva

/ Floriculture 4.0 in Ecuador: Challenges and guidelines for the integration of digital technologies and public policies in genetic improvement and productive innovation

Xavier Rojas-Ruilova, Génesis Vásquez, Isabel Marques

- 345** Revisión sistemática de literatura sobre soluciones computacionales aplicadas a la agricultura

/ A systematic literature review of computational solutions applied to agriculture: visual disease diagnosis, postharvest classification, and intelligent IoT-based monitoring

Luis Chamba-Eras, Sergio Jumbo-Gonza, Walter Yaguana-Alejandro, Geovanny Romero-Suquilanda, Gerardo Herrera-Campoverde

399 ARTÍCULO ILUSTRADO

401 INFORMACIÓN PARA AUTORES

407 CALL FOR PAPERS

A los lectores

La ciencia avanza cuando es capaz de mirar los problemas reales con nuevas preguntas, nuevos métodos y nuevas formas de colaboración. En ese camino, las tecnologías de la información y la comunicación han dejado de ser únicamente herramientas de soporte para convertirse en uno de los principales motores de la investigación contemporánea. Su verdadero valor no radica en la tecnología misma, sino en su capacidad para ampliar las posibilidades de observar, comprender y transformar la realidad mediante evidencia científica.

Con enorme satisfacción presentamos el primer número de la Revista Científica CEDIA, una iniciativa que nace con el propósito de visibilizar investigaciones rigurosas en las que las TIC se integran a distintas áreas del conocimiento para ampliar las fronteras de la ciencia y responder a desafíos concretos de la sociedad. La Revista Científica CEDIA parte de la convicción de que la generación de conocimiento alcanza su mayor trascendencia cuando contribuye, de manera verificable, a comprender y resolver problemas que afectan a las personas, las organizaciones, los sistemas productivos y el ambiente. Por ello, promovemos investigaciones que combinen excelencia científica con potencial de impacto en la sociedad.

El volumen inaugural está dedicado a las TIC aplicadas a la agricultura de precisión, un campo que expresa con claridad el espíritu de esta publicación. La agricultura contemporánea enfrenta retos crecientes: producir más y mejor, optimizar el uso del agua y del suelo, anticipar riesgos climáticos y fitosanitarios, reducir impactos ambientales, fortalecer la competitividad y garantizar sistemas productivos más sostenibles. Frente a estos desafíos, la ciencia agrícola ya no puede depender únicamente de la observación tradicional o de la experiencia acumulada; requiere integrar datos, sensores, modelos, imágenes, conectividad, automatización e inteligencia artificial para comprender con mayor profundidad lo que ocurre en el territorio, en el cultivo y en cada decisión productiva.

En este contexto, la agricultura de precisión no representa simplemente la incorporación de dispositivos tecnológicos al campo. Representa una nueva forma de hacer ciencia aplicada: una manera de conectar el conocimiento agronómico, la ingeniería, la informática, la ciencia de datos, la gestión ambiental y la toma de decisiones productivas. Sensores inteligentes, sistemas de información geográfica, imágenes satelitales y de drones, modelos predictivos, internet de las cosas, analítica avanzada y sistemas de apoyo a la decisión permiten construir una agricultura más informada, eficiente y resiliente.

Para el Ecuador, este tema tiene una relevancia particular. Nuestro país posee una extraordinaria diversidad territorial, climática y productiva. Su agricultura, reconocida internacionalmente por la calidad de sus flores, banano, cacao, café y otros productos, constituye una de las bases de su identidad económica y social. Sin embargo, sostener y fortalecer ese liderazgo exige producir conocimiento propio, desarrollar capacidades locales y promover soluciones adaptadas a las condiciones específicas de nuestros territorios. La agricultura de precisión abre una oportunidad estratégica para que la ciencia, la tecnología y el sector productivo dialoguen con mayor profundidad y construyan respuestas pertinentes para el país y la región.

Este primer número refleja precisamente esa convergencia. Los trabajos que aquí se presentan muestran que las TIC adquieren verdadero sentido cuando se integran a preguntas científicas relevantes y a problemas concretos: cómo monitorear cultivos, cómo mejorar la eficiencia productiva, cómo

anticipar enfermedades, cómo gestionar recursos, cómo interpretar datos complejos y cómo convertir la información en decisiones oportunas. En cada caso, la tecnología aparece no como protagonista aislada, sino como aliada de la ciencia para comprender mejor la realidad y transformarla con responsabilidad.

La creación de la Revista Científica CEDIA constituye un paso natural dentro de la misión institucional de CEDIA. Durante más de dos décadas, CEDIA ha impulsado el fortalecimiento del ecosistema nacional de ciencia, tecnología e innovación mediante infraestructura digital avanzada, servicios especializados, capacidades de investigación, cooperación internacional y redes académicas que conectan a las instituciones de educación superior y centros de investigación del Ecuador. La creación de esta revista representa una extensión natural de ese compromiso con la generación, circulación y apropiación social del conocimiento.

Aspiramos a que esta publicación evolucione junto con los campos científicos que aborda. Cada volumen será una oportunidad para explorar cómo las tecnologías digitales contribuyen a nuevas formas de investigación en áreas diversas: salud, educación, ambiente, energía, industria, territorio, cultura, ciencias sociales y muchas otras. La vocación de la Revista Científica CEDIA es convertirse en un punto de encuentro para investigaciones que no separan artificialmente la tecnología de los problemas que busca resolver, sino que la integran críticamente al servicio del conocimiento y del bienestar colectivo.

Este número inaugural marca, por tanto, el inicio de un camino. Un camino que reconoce que la ciencia contemporánea necesita infraestructuras robustas, datos confiables, capacidades computacionales, colaboración entre disciplinas y vínculos sólidos con la sociedad. Pero también necesita comunidades académicas dispuestas a compartir, revisar, debatir y construir conocimiento con rigor, apertura y propósito.

Agradezco profundamente a los autores que confiaron en este proyecto editorial, a los revisores que aportaron con su experiencia y rigurosidad académica, al consejo de redacción por su compromiso y a todas las personas que hicieron posible que esta primera edición vea la luz. Su trabajo colectivo expresa el espíritu que anima a CEDIA: articular capacidades, conectar comunidades y contribuir a que el conocimiento científico genere valor para el Ecuador y la región.

Invito a nuestros lectores a recorrer estas páginas con curiosidad, exigencia académica y mirada interdisciplinaria. Cada artículo es una invitación a pensar cómo la tecnología, cuando se pone al servicio de la ciencia y de los desafíos reales, puede abrir nuevas posibilidades para producir, aprender, innovar y transformar.

Juan Pablo Carvallo, Ph. D.
Director Ejecutivo de CEDIA

Note to our readers

Science advances when it is able to address real-world problems through new questions, new methods, and new forms of collaboration. Along this path, information and communication technologies (ICTs) have evolved beyond being merely support tools to become one of the principal driving forces of contemporary research. Their true value lies not in the technology itself, but in their ability to expand our capacity to observe, understand, and transform reality through scientific evidence.

It is with great satisfaction that we present the inaugural issue of the Revista Científica CEDIA, an initiative created to showcase rigorous research in which ICTs are integrated across diverse fields of knowledge to expand the frontiers of science and address concrete societal challenges. The Revista Científica CEDIA is founded on the conviction that knowledge generation achieves its greatest significance when it contributes, in a verifiable manner, to understanding and solving problems that affect people, organizations, productive systems, and the environment. Accordingly, we promote research that combines scientific excellence with the potential to generate meaningful societal impact.

The inaugural volume is dedicated to ICTs applied to precision agriculture, a field that clearly embodies the spirit of this publication. Contemporary agriculture faces growing challenges: producing more and better, optimizing the use of water and soil resources, anticipating climate-related and phytosanitary risks, reducing environmental impacts, strengthening competitiveness, and ensuring more sustainable production systems. In response to these challenges, agricultural science can no longer rely solely on traditional observation or accumulated experience; it requires the integration of data, sensors, models, imagery, connectivity, automation, and artificial intelligence to achieve a deeper understanding of what occurs across the landscape, within crops, and in every production decision.

In this context, precision agriculture represents far more than the incorporation of technological devices into farming. It represents a new way of conducting applied science: a way of connecting agronomic knowledge, engineering, computer science, data science, environmental management, and production decision-making. Intelligent sensors, geographic information systems, satellite and drone imagery, predictive models, the Internet of Things, advanced analytics, and decision support systems make it possible to build a more informed, efficient, and resilient agricultural sector.

For Ecuador, this topic holds particular significance. Our country possesses extraordinary territorial, climatic, and productive diversity. Its agriculture, internationally recognized for the quality of its flowers, bananas, cocoa, coffee, and other products, constitutes one of the foundations of its economic and social identity. However, sustaining and strengthening this leadership requires generating local knowledge, developing domestic capabilities, and promoting solutions tailored to the specific conditions of our territories. Precision agriculture offers a strategic opportunity for science, technology, and the productive sector to engage more deeply and develop solutions that are relevant to both the country and the region.

This inaugural issue reflects precisely that convergence. The studies presented here demonstrate that ICTs acquire their true value when they are integrated into meaningful scientific questions and concrete challenges: how to monitor crops, improve production efficiency, anticipate diseases, manage resources, interpret complex data, and transform information into timely decisions. In every case, technology appears not as an isolated protagonist but as a partner of science, enabling a deeper understanding of reality and its responsible transformation.

The creation of the Revista Científica CEDIA represents a natural step within CEDIA's institutional mission. For more than two decades, CEDIA has fostered the strengthening of Ecuador's national science, technology, and innovation ecosystem through advanced digital infrastructure, specialized services, research capabilities, international cooperation, and academic networks that connect the country's higher education institutions and research centers. The creation of this journal represents a natural extension of that commitment to the generation, dissemination, and social appropriation of knowledge.

We aspire for this publication to evolve alongside the scientific fields it addresses. Each volume will provide an opportunity to explore how digital technologies contribute to new forms of research across diverse areas, including health, education, the environment, energy, industry, territorial development, culture, the social sciences, and many others. The vocation of the Revista Científica CEDIA is to become a meeting point for research that does not artificially separate technology from the problems it seeks to solve, but instead integrates it critically in the service of knowledge and collective well-being.

This inaugural issue therefore marks the beginning of a journey—a journey that recognizes that contemporary science requires robust infrastructures, reliable data, computational capabilities, interdisciplinary collaboration, and strong connections with society. Yet it also requires academic communities willing to share, review, debate, and build knowledge with rigor, openness, and purpose.

I would like to express my deepest gratitude to the authors who placed their trust in this editorial project, to the reviewers who contributed their expertise and academic rigor, to the editorial board for its commitment, and to everyone whose efforts made this first issue possible. Their collective work embodies the spirit that drives CEDIA: bringing together capabilities, connecting communities, and ensuring that scientific knowledge generates value for Ecuador and the wider region.

I invite our readers to explore these pages with curiosity, academic rigor, and an interdisciplinary perspective. Each article is an invitation to reflect on how technology, when placed at the service of science and real-world challenges, can create new opportunities to produce, learn, innovate, and transform.

Juan Pablo Carvallo, Ph. D.
Executive Director of CEDIA

Donde la tecnología florece: las TIC entre la ciencia, la naturaleza y las artes

Toda revolución tecnológica transforma la manera en que las sociedades producen conocimiento. Las tecnologías de la información y la comunicación (TIC) han dado lugar a formas innovadoras de entender la naturaleza, de expresar nuestros vínculos con esta y de crear.

Vivimos en una época en la que resulta difícil identificar una disciplina completamente ajena a las TIC. Desde la agricultura hasta la medicina, desde la ingeniería hasta las ciencias sociales, pasando por la educación, la conservación ambiental o la gestión del patrimonio cultural, la transformación digital ha redefinido procesos, metodologías y formas de colaboración. Lo verdaderamente significativo es que estas tecnologías ya no representan un campo aislado del conocimiento, sino un lenguaje común que permite conectar disciplinas y generar soluciones para desafíos cada vez más complejos.

Así, las TIC no solo impulsan el progreso científico, también han ampliado las posibilidades de la imaginación humana. La historia demuestra que las grandes innovaciones tecnológicas siempre han encontrado un eco en las artes. Hoy, algoritmos, inteligencia artificial, modelado tridimensional, realidad aumentada, bioarte y visualización de datos forman parte del imaginario creativo de numerosos artistas.

Esta fusión entre ciencia y creación parece partir de una misma inquietud: comprender la realidad para imaginar nuevas posibilidades. La investigación científica observa, formula preguntas y construye conocimiento; el arte interpreta, cuestiona y resignifica aquello que conocemos; y las TIC se establecen como un puente para que la ciencia se transforme en experiencia estética.

Esta relación, por ejemplo, adquiere una dimensión particularmente significativa en la obra HS92-6702: Sustrato Armonizado del artista ecuatoriano Juan Carlos León. En este proyecto, la tecnología deja de ser un simple instrumento para convertirse en un elemento conceptual que dialoga con la biología, la memoria y los sistemas vivos. La obra propone un paralelismo entre los códigos biológicos de la naturaleza y los lenguajes digitales:

“La obra imprime sustrato escultórico vivo sobre un jardín de vegetación artificial cultivado mediante un sistema cnc de dos brazos robóticos que se accionan a partir de información obtenida desde la investigación estadística «especulativa»”.

Juan Carlos León, 2020 (HS92: 6702 SUSTRATO ARMONIZADO
– Juan Carlos León)

Este diálogo entre naturaleza, ciencia y tecnología constituye también el espíritu que inspira el nacimiento de la Revista Científica CEDIA. Concebida como un espacio para la difusión de investigaciones sobre tecnologías de la información y la comunicación, la revista busca visibilizar cómo estas tecnologías impulsan avances en múltiples campos del conocimiento y cómo su aplicación genera soluciones concretas para los desafíos científicos, productivos y sociales de nuestro tiempo.



Figura 1. Detalle de HS92-6702-2, de Juan Carlos León.
Imagen reproducida con autorización del artista.

En este contexto, la elección de la agricultura como eje temático del primer número responde a mucho más que la importancia económica de este sector para el Ecuador. Representa una oportunidad para mostrar cómo convergen disciplinas aparentemente distantes en un mismo escenario de innovación.

La agricultura, tradicionalmente asociada con la vida rural, los ciclos naturales y el trabajo manual se convierte en el objeto de la investigación científica y de sofisticados procesos tecnológicos. En un invernadero moderno conviven sensores ambientales, redes de comunicación, inteligencia artificial, visión por computador, robótica, modelos predictivos y plataformas de análisis de datos que permiten optimizar el uso del agua, anticipar enfermedades, mejorar la productividad y reducir el impacto ambiental.

Los trabajos que conforman esta primera edición reflejan precisamente esa visión interdisciplinaria. Las investigaciones exploran aplicaciones de las TIC orientadas a fortalecer procesos agrícolas, optimizar recursos, mejorar la sostenibilidad y generar conocimiento útil para la sociedad, demostrando que la innovación tecnológica alcanza su verdadero valor cuando responde a necesidades concretas y produce beneficios compartidos.

Esta perspectiva refleja una convicción cada vez más extendida en la comunidad científica: los grandes desafíos ya no pueden abordarse desde disciplinas aisladas. El cambio climático, la seguridad alimentaria, la transformación digital, la conservación de la biodiversidad o la transición energética requieren la colaboración permanente entre especialistas provenientes de diferentes campos del conocimiento.

Desde esta visión, promovemos la colaboración entre universidades, centros de investigación y actores del ecosistema de innovación, fortaleciendo el desarrollo científico mediante infraestructura tecnológica, redes académicas y proyectos cooperativos que impulsan la generación y transferencia de conocimiento. La creación de la Revista Científica CEDIA representa un nuevo paso dentro de ese compromiso.

Aspiramos a consolidar un espacio editorial donde converjan investigadores, desarrolladores, artistas, docentes, emprendedores y profesionales que compartan la convicción de que la innovación surge cuando distintas formas de conocimiento dialogan entre sí. Con esta primera edición iniciamos un proyecto que aspira a acompañar la evolución permanente de las TIC y de sus innumerables aplicaciones.

Esperamos que las páginas que siguen no solo presenten resultados científicos, sino que también inspiren nuevas preguntas, nuevas colaboraciones y nuevas formas de comprender la relación entre tecnología, naturaleza, sociedad y cultura.

Cuando el conocimiento florece, también lo hacen las posibilidades de construir un futuro más innovador, más sostenible y profundamente humano.



Figura 2. Figura 1. Detalle de HS92-6702-2, de Juan Carlos León.
Imagen reproducida con autorización del artista.

Where technology flourishes: ICT at the intersection of science, nature, and the arts

Every technological revolution transforms the way societies generate knowledge. Information and communication technologies (ICT) have given rise to innovative ways of understanding nature, expressing our relationship with it, and fostering creativity.

We live in an era in which it is difficult to identify any discipline that remains completely untouched by ICT. From agriculture to medicine, from engineering to social sciences, including education, environmental conservation, and cultural heritage management, digital transformation has redefined processes, methodologies, and forms of collaboration. More importantly, these technologies no longer represent an isolated field of knowledge but rather a common language that connects disciplines and enables solutions to increasingly complex challenges.

Thus, ICT not only drives scientific progress but has also expanded the possibilities of human imagination. History shows that major technological innovations have always found an echo in the arts. Today, algorithms, artificial intelligence, three-dimensional modeling, augmented reality, bioart, and data visualization have become part of the creative imagination of numerous artists.

This fusion of science and artistic creation appears to stem from a shared aspiration: to understand reality in order to imagine new possibilities. Scientific research observes, formulates questions, and generate knowledge; art interprets, challenges, and redefines what we know; and ICT serves as a bridge through which science is transformed into an aesthetic experience.

This relationship, for example, takes on a particularly meaningful dimension in HS92-6702: Harmonized Substrate, a work by Ecuadorian artist Juan Carlos León. In this project, technology ceases to be merely an instrument and instead becomes a conceptual element that engages in dialogue with biology, memory, and living systems. The work draws a parallel between the biological codes of nature and digital languages:

"The work prints a living sculptural substrate onto a garden of artificial vegetation cultivated through a CNC system of two robotic arms activated by information obtained from 'speculative' statistical research."

Juan Carlos León, 2020 (HS92: 6702 SISTRATO ARMONIZADO
– Juan Carlos León)

This dialogue among nature, science, and technology also embodies the spirit that inspires the creation of the Revista Científica CEDIA. Conceived as a platform for disseminating research on information and communication technologies, the journal seeks to showcase how these technologies drive advances across multiple fields of knowledge and how their application generates practical solutions to the scientific, industrial, and societal challenges of our time.



Figure 1. Detail of HS92-6702-2, by Juan Carlos León.
Image reproduced with the artist's permission.

Within this context, selecting agriculture as the central theme of the inaugural issue reflects far more than the economic importance of this sector for Ecuador. It represents an opportunity to demonstrate how seemingly distant disciplines converge within a shared landscape of innovation.

Agriculture, traditionally associated with rural life, natural cycles, and manual labor, has become the focus of scientific research and sophisticated technological innovation. In a modern greenhouse, environmental sensors, communication networks, artificial intelligence, computer vision, robotics, predictive models, and data analytics platforms coexist to optimize water use, anticipate plant diseases, improve productivity, and reduce environmental impact.

The papers featured in this inaugural issue reflect precisely this interdisciplinary vision. They explore ICT applications aimed at strengthening agricultural processes, optimizing resources use, enhancing sustainability, and generating knowledge that benefits society, demonstrating that technological innovation achieves its greatest value when it addresses real-world needs and produces shared benefits.

Note. The images used in this editorial are from the artwork HS92-6702-2 by Juan Carlos León, available at <https://juancarlosleon.net/2022/04/14/hs92-6702-2/>

This perspective reflects a conviction that is becoming increasingly widespread within the scientific community: today's major challenges can no longer be addressed from isolated disciplines. Climate change, food security, digital transformation, biodiversity conservation, and the energy transition require sustained collaboration among specialists from different fields of knowledge.

From this perspective, we promote collaboration among universities, research centers, and stakeholders within the innovation ecosystem, strengthening scientific development through technological infrastructure, academic networks, and collaborative projects that foster the generation and transfer of knowledge. The creation of the Revista Científica CEDIA represents another step in fulfilling this commitment.

We aspire to establish an editorial platform where researchers, developers, artists, educators, entrepreneurs, and professionals come together, united by the conviction that innovation emerges when different forms of knowledge engage in dialogue. With this inaugural issue, we launch a project that seeks to accompany the continuous evolution of ICT and its countless applications.

We hope that the pages that follow will not only present scientific findings but also inspire new questions, new collaborations, and new ways of understanding the relationship between technology, nature, society, and culture.

When knowledge flourishes, so too do the possibilities for building a future that is more innovative, more sustainable, and profoundly human.



Figura 2. Detail of HS92-6702-2, by Juan Carlos León.
Image reproduced with the artist's permission.

**ARTÍCULOS
CIENTÍFICOS
ORIGINALES**
/ Original Research Articles

Sostenibilidad y agricultura inteligente

**en los sistemas agrivoltaicos y *off-grid* de Israel
como modelo para la región andina de Ecuador**

*Rafael Alexander Cordova Uvidia*¹
*Roberto Arias-Hinojosa*²

¹Escuela Superior Politécnica de Chimborazo,
Vicerrectorado de Investigación y Posgrado,
Riobamba, Ecuador.
<https://orcid.org/0000-0002-5326-3782>
rafael.cordova@epoch.edu.ec

²Escuela Superior Politécnica de Chimborazo,
Decanato de Innovación, Emprendimiento
y Transferencia de Tecnologías, Riobamba,
Ecuador
<https://orcid.org/0000-0003-1357-8648>
robertof.arias@epoch.edu.ec

DOI: 10.61854/rccedia.v1n1.001
Enviado: 11 de febrero de 2026
Aprobado: 27 de abril de 2026
Publicado: martes 14 de julio de 2026



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Resumen

La crisis climática global y la creciente competencia por el uso del suelo exigen una gestión integrada del nexo agua-energía-alimentos (WEF Nexus). Este estudio analizó la integración de las tecnologías de la información y comunicación (TIC) y sistemas agrivoltaicos (Agri-PV) en Israel como un modelo de resiliencia para la región altoandina del Ecuador. El objetivo principal fue evaluar la eficiencia técnica del uso dual del suelo y de tecnologías descentralizadas (off-grid) mediante indicadores normalizados, como la relación de equivalencia de tierra (LER) y la eficiencia de uso de agua (WUE). La metodología consistió en un estudio de caso transdisciplinar en seis unidades de análisis estratégicas (Valle de Arava, Ramat Negev, Ma'ale Gilboa, entre otras), utilizando el internet de las cosas (IoT) y sensores de precisión para el monitoreo de microclimas y productividad. Los resultados demuestran que la agrivoltaica permite alcanzar valores de LER de hasta 1,99, reduciendo la temperatura ambiente en 3,00 °C y mejorando la WUE entre un 20,00 % y un 47,00 %. Aunque se reportó una reducción del 19,40 % en el rendimiento bruto de ciertos cultivos, el beneficio neto anual resultó hasta 9,54 veces superior al modelo convencional, debido a la generación energética distribuida. El estudio concluye que las innovaciones observadas en Israel ofrecen una hoja de ruta viable para la región altoandina ecuatoriana, permitiendo mitigar heladas, reducir la erosión y fortalecer la soberanía energética de las comunidades rurales.

Palabras clave:

agricultura 4.0, tecnología,
información, comunicación,

Introducción

La crisis climática global ha impulsado una transformación radical en la gestión de los recursos naturales, situando a la sostenibilidad y a la agricultura inteligente en el centro de las políticas de desarrollo para asegurar productividad y resiliencia. En este escenario, el nexo agua-energía-alimentos (WEF Nexus) se presenta como un equilibrio precario donde la competencia por el uso del suelo se ha intensificado drásticamente (Chopdar y otros, 2024; Zainali y otros, 2025). El problema central reside en la incompatibilidad técnica de los modelos de producción aislados para los cuales la expansión de infraestructura fotovoltaica, cuya capacidad global superó los 14 GWp en 2021, frecuentemente desplaza la producción agrícola en tierras de alta calidad (Sollazzo y otros, 2025; Widmer y otros, 2024). Las tecnologías de la información y comunicación (TIC) actúan como el motor de la agricultura 4.0, integrando sensores IoT, inteligencia artificial y protocolos de conectividad para maximizar la eficiencia en entornos de escasez (Díaz y otros, 2025; Pathmudi y otros, 2023).

Israel, a través de su modelo de innovación en los kibutzim y centros de I+D, ha validado el paradigma agrivoltaico (Agri-PV) como una solución sistémica que propone la coexistencia vertical de módulos y cultivos (Ben Naim y otros, 2025; Zohar y otros, 2022), resolviendo así el conflicto por el uso del suelo entre la generación de energía y la producción de alimentos (Schinde-

le y otros, 2020; Widmer y otros, 2024; Sollazzo y otros, 2025; De Francesco y otros, 2025; Cosme y otros, 2025). Mediante paneles solares elevados, se logra una sinergia donde las plantas se benefician del sombreado parcial, mientras que los paneles operan a menores temperaturas gracias a la transpiración vegetal (Ben Naim y otros, 2025). Esta tecnología es pertinente para las zonas altoandinas del Ecuador, donde la radiación solar intensa y las heladas nocturnas requieren sistemas de protección climática (CELEC EP, 2024).

El indicador fundamental en agrivoltaica es la relación de equivalencia de tierra (LER), que cuantifica la eficiencia de producir energía y alimentos simultáneamente frente a sistemas separados (Schindele y otros, 2020). Un LER > 1,0 indica una ventaja de uso dual. Estudios recientes demuestran que la productividad total del suelo puede incrementarse hasta en un 60 %, es decir, un LER de 1,6 (NREL, 2023). En la región de transición andino-amazónica de Perú, investigaciones de 2025 han reportado que las configuraciones semitransparentes alcanzan los valores más altos de eficiencia, con un LER de entre 1,95 y 1,99, seguidas por sistemas bifaciales (1,66 a 1,90) y monofaciales (1,51 a 1,72). Estos hallazgos muestran que, en ecosistemas tropicales de montaña, la respuesta del sistema agrícola es el motor principal de la variabilidad del LER, más que la generación energética por sí misma.

A diferencia de las granjas solares convencionales, los sistemas Agri-PV funcionan como modificadores microclimáticos activos. La literatura científica destaca el efecto de enfriamiento mutuo: la transpiración de los cultivos reduce la temperatura del aire local, enfriando los paneles entre 8,9 °C y 10,0 °C, lo que puede incrementar su eficiencia de generación hasta en un 3,0 % (Zainali y otros, 2025). Simultáneamente, la sombra proyectada reduce la temperatura del suelo entre 3 °C y 4 °C y la temperatura ambiente en aproximadamente 1 a 4 °C.

La respuesta fisiológica es altamente específica de la especie y la configuración del sistema. En cultivos de camote (*Ipomoea batatas*) bajo sistemas de espectro dividido, se ha documentado una reducción de la evapotranspiración del 31 % y un incremento de la biomasa fresca del 56 % (Omer y otros, 2024). Por el contrario, en especies heliófilas como el maíz y el trigo, una densidad de paneles excesiva (PCR > 0,40) puede reducir los rendimientos de forma significativa, como se observó en el Medio Oeste estadounidense con pérdidas del 24 % en maíz y 16 % en soya bajo condiciones húmedas (Jia y otros, 2026). No obstante, en regiones semiáridas, la sombra alivia el estrés hídrico, permitiendo incluso incrementos de rendimiento del 6 % en soya (Mehta & Zörner, 2025).

En el marco del nexo WEF, la agrivoltaica mejora la eficiencia de uso de agua (WUE) entre un 20 % y un 47 % (Zainali y otros, 2025). En

España, la integración de Agri-PV con riego deficitario regulado (RDI) permitió reducir el consumo hídrico en tomate en un 50 %, manteniendo la productividad del agua en niveles competitivos a pesar de una caída del 20 % en el rendimiento bruto (Omer y otros, 2024).

La resiliencia hídrica se complementa con sistemas descentralizados. La tecnología de Laguna Innovation, validada en Israel, permite el tratamiento de aguas residuales mediante muros verdes verticales (Vertical Green Wall), operando de forma 100 % autónoma con energía solar y monitoreo IoT remoto (Arava Institute, 2024; Aviram y otros, 2025). Otros avances incluyen la generación de agua atmosférica (WaterGen) y la ultrafiltración (tecnología NUF) que opera por gravedad, sin químicos, beneficiando a comunidades vulnerables en Panamá e Israel (Arava Institute, 2024; Embajada de Israel, 2025).

Aunque el costo de instalación de sistemas Agri-PV es entre un 4 % y un 115 % superior al de sistemas estándar debido a estructuras elevadas de hasta 5 metros para permitir el paso de maquinaria (Sadeghi Chamazkoti y otros, 2025), la diversificación de ingresos compensa esta inversión. El análisis de costo-beneficio para sistemas de bombeo solar *off-grid* muestra una relación de 9,3 frente a 8,4 del sistema de red, con periodos de recuperación de la inversión (*payback*) reducidos entre 3 y 6 años en contextos de sustitución de diésel (Herlina y otros, 2025).

A nivel político, Israel marcó un hito en febrero de 2026 al aprobar el primer plan nacional de uso de suelo dedicado exclusivamente a Agri-PV, estableciendo un marco regulatorio claro para proyectos piloto a gran escala. Esta gobernanza es fundamental para reducir el riesgo financiero de los pequeños agricultores y fomentar la aceptación social (SolarQuarter, 2026).

La Sierra del Ecuador presenta un potencial solar robusto (2,8 a 6,4 kWh/m²/día), pero sufre de una degradación catastrófica del suelo, con tasas de erosión que exceden la formación natural entre 9 y 286 veces. La Agri-PV en los Andes no solo generaría energía limpia para el riego tecnificado, cuya adopción es de apenas el 20 %, sino que actuaría como una barrera contra heladas y eventos de precipitación extrema que aceleran la erosión en pendientes de hasta el 70 %. Estudios en Cuenca y Azogues confirman que cultivos como la lechuga alcanzan altos rendimientos bajo sombra parcial, permitiendo un incremento en el precio de venta por calidad del 66 %.

La relevancia de este estudio radica en la transferencia de estos modelos a la región altoandina de Ecuador. La implementación de sistemas Agri-PV representa una oportunidad de sostenibilidad tridimensional: ambiental, al mitigar heladas y reducir la evapotranspiración; económica, al diversificar ingresos mediante la venta de excedentes energéticos; y social, al fortalecer la soberanía de comunidades rurales desconectadas (Alai Secure, 2025; Coherent Market Insights, 2025).

Los objetivos de este trabajo se centran en la evaluación de la eficiencia técnica de los sistemas Agri-PV y tecnologías descentralizadas (*off-grid*) observados en Israel, utilizando la relación de equivalencia de tierra (LER) y la eficiencia de uso de agua (WUE) como indicadores clave de desempeño. Asimismo, se busca analizar el impacto de la gestión de microclima asistida por TIC sobre la fisiología de cultivos sensibles para mitigar el estrés térmico y, finalmente, establecer una hoja de ruta de sostenibilidad que integre los pilares ambiental, económico y social para la implementación de proyectos piloto en el callejón interandino del Ecuador.

Métodos

La metodología empleada en esta investigación es una revisión analítica con estudio de caso descriptivo, basada en la experiencia de transferencia tecnológica del autor y la síntesis de literatura técnica especializada. El estudio adopta un enfoque transdisciplinar para evaluar el nexo agua-energía-alimentos, priorizando la separación entre evidencia científica verificable y observaciones descriptivas (Zohar y otros, 2022). El levantamiento de información primaria se realizó durante una inmersión técnica en Israel, entre noviembre y diciembre de 2025, con énfasis en la infraestructura de soporte para la agricultura 4.0.

Ubicación de los sitios de estudio y unidades de análisis

Para garantizar la trazabilidad del estudio, se identificaron las coordenadas geográficas exactas de las unidades de análisis seleccionadas por su representatividad en el ecosistema de innovación israelí. Los sitios se distribuyen en diversas zonas climáticas, desde la aridez extrema del sur hasta las elevaciones del norte:

- Instituto Arava de Estudios Ambientales (Ketura): Ubicado en el Kibbutz Ketura, valle de Arava (29°58'3,36"N, 35°4'15,24"E). Este centro lidera la investigación en agrivoltaica móvil y fija en condiciones de hiperaridez.
- Parque Eólico y Almacenamiento Ma'ale Gilboa: Situado en la cima del monte Gilboa, al noreste de la cordillera de Samaria (32°28'35"N, 35°25'13"E). El parque eólico específico se localiza en 32°28'1,6"N, 35°25'36,3"E, sirviendo como modelo de flexibilidad energética y almacenamiento por bombeo.
- Centro Yoel De Malach (Ramat Negev): Estación de investigación agrícola ubicada cerca del Kibbutz Revivim (31°02'33"N, 34°43'15"E aproximadamente). Se especializa en la respuesta de cultivos a la salinidad y el estrés térmico desértico.
- Hub de resiliencia Al-Furaa: Localizado en la aldea beduina no reconocida de Al-Furaa, cerca de la autopista Beersheba-Arad en el Negev central. Es el sitio piloto para tecnologías descentralizadas de agua y energía fuera de la red (*off-grid*).
- Central Térmica Solar Ashalim: Localizada en el desierto del Negev, cerca de la comunidad de Ashalim (30°57'45"N, 34°43'48"E). Se evaluó como referente de infraestructura energética a gran escala.

Definición y operacionalización de variables

Se definieron conceptual y operativamente las variables métricas fundamentales para medir la sostenibilidad del nexo agua-energía-alimentos. En primera instancia, se definió la relación de equivalencia de tierra (LER, por sus siglas en inglés), que es un indicador de la eficiencia del uso dual del suelo, tal como se muestra en la Ecuación 1 (TrinaSolar, 2025; Willockx y otros, 2024).

$$LER = \frac{Y_{cultivo,AV}}{Y_{cultivo,FS}} + \frac{E_{AV}}{E_{FS}} \quad (Ec. 1)$$

La LER se operacionaliza mediante la suma de los rendimientos relativos agrícola y energético; particularmente, $Y_{cultivo}$ hace referencia a la

productividad del cultivo bajo la estructura de los paneles solares (AV) y a pleno sol (FS). Mientras que la letra E representa la producción energética agrivoltaica (AV) y la generación de un sistema fotovoltaico estándar sin cultivos debajo (PV).

Otra variable que se usa en este estudio es la eficiencia de uso de agua (WUE, por sus siglas en inglés), que se define como la relación entre la biomasa total producida y el volumen de agua consumido (kg/m^3), medida a través de caudalímetros electrónicos y sensores de humedad (Zainali y otros, 2025).

Finalmente, se ha considerado la radiación fotosintéticamente activa (PAR), definida como la cantidad de luz disponible para la fotosíntesis en el espectro de 400 a 700 nm, medida bajo los paneles fotovoltaicos en $\mu\text{mol}/\text{m}^2/\text{s}$ (Ben Naim y otros, 2025; Cosme & Vázquez y Parraguirre, 2025).

Instrumentación y técnicas de recolección de datos

El estudio inicialmente se basó en la visita a sitios de interés en Israel en los cuales se evidenció el uso de herramientas avanzadas de monitoreo integradas mediante el internet de las cosas (IoT, por sus siglas en inglés). Se visualizaron redes de sensores para la medición continua de humedad volumétrica del suelo, temperatura ambiental y del suelo, y niveles de nutrientes como carbono y nitrógeno (Santos Valle & Kienzle, 2021).

Se registraron parámetros estructurales como la relación de cobertura de suelo (GCR), la altura de los módulos estandarizada a 5 metros para permitir el paso de maquinaria y el espaciamiento entre hileras (Willockx y otros, 2020). Finalmente, se analizaron los datos provenientes de plataformas de control en tiempo real para evaluar la calidad del agua recuperada en los sistemas de tratamiento de Laguna Innovation y la producción de agua atmosférica de WaterGen (Arava Institute, 2024).

Procedimientos de análisis y validación

Los procedimientos de análisis técnico se centraron en la evaluación del rendimiento agrícola bajo diferentes configuraciones de sombreado fotovoltaico y la eficiencia de sistemas descentralizados. Se examinaron específicamente datos de productividad del tomate y el zuquini (*Cucurbita pepo*), evaluando parámetros de biomasa fresca y seca, así como la calidad postcosecha (Omer y otros, 2024; Rouini y otros, 2025). La validación de la información primaria se realizó mediante la triangulación de datos con investigaciones previas lideradas por la Dra. Tali Zohar y el Dr. Clive Lipchin (Ben Naim y otros, 2025; Zohar y otros, 2022).

Resultados

Los hallazgos de esta investigación se derivan de la observación directa de infraestructuras operativas y el análisis de datos recolectados en el ecosistema de innovación de Israel. Los resultados demuestran que la integración de tecnologías de la información y comunicación (TIC) permite una gestión granular del nexo agua-energía-alimentos, optimizando la productividad en entornos de aridez extrema. La aplicación de estas tecnologías en la zona altoandina del Ecuador puede impactar positivamente en la soberanía alimentaria, sostenibilidad ambiental e independencia energética de comunidades rurales y urbanas.

Agricultura de precisión, robótica y el principio del diseño acoplado

En Israel, el interés agrivoltaico ha trascendido la fase experimental para conectarse con estrategias nacionales de adaptación climática. La evidencia recolectada refuerza el principio de diseño acoplado agronómico-energético, que establece que la configuración del sistema debe ser específica para cada cultivo. Se determinó que parámetros como la altura de los módulos (estandarizada a 1,70 metros en pruebas de baja altura y 5,00 metros para paso de maquinaria), la densidad de paneles y el uso de tecnologías bifaciales son determinantes para el éxito del sistema (Cosme & Vázquez y Parraguirre, 2025; Sollazzo y otros, 2025).

Las TIC son el habilitador crítico para la sostenibilidad agrícola en condiciones de hiperaridez. En la Figura 1, se muestra una composición técnica de los sistemas observados. Se destaca el uso de robots agrícolas autónomos que, ener-

gizados por paneles solares bifaciales, realizan un monitoreo multipunto de variables críticas: humedad volumétrica, concentración de nitrógeno y carbono orgánico en el suelo. Este flujo de datos permite que el sistema suministre la dosificación exacta de agua y fertilizante mediante fertirrigación computarizada, eliminando el desperdicio de insumos en condiciones de escasez (Santos Valle & Kienzle, 2021).

Sistemas *off-grid* para el tratamiento de aguas residuales

En el ámbito de la agricultura inteligente y descentralizada, la tecnología de Laguna Innovation representa un cambio de paradigma en el tratamiento de aguas residuales para riego. El sistema Vertical Green Wall (VGW-BF), operado completamente fuera de la red mediante paneles solares, integra sensores IoT que transmiten datos 24/7 sobre la calidad del efluente y el estado operativo (Figura 2).

En el contexto de la escuela regional de Al-Furaa, que atiende a 1 200 estudiantes, esta infraestructura modular permite la recuperación de efluentes ricos en nutrientes para el riego agrícola local. Los datos operativos indican una eficiencia de remoción de contaminantes superior al 90,00 % en parámetros de demanda bioquímica de oxígeno (DBO5) y sólidos suspendidos totales (SST), eliminando la producción de lodos y reduciendo drásticamente la huella energética en comparación con las redes de saneamiento centralizadas (Arava Institute, 2024; Aviram y otros, 2025).



Figura 1

Composición técnica de agricultura 4.0 y sistemas agrivoltaicos: (A) robot autónomo para riego de precisión y monitoreo de nutrientes (C, N) bajo estructuras bifaciales; (B) vista técnica de la inclinación de módulos sun-tracking para optimización de radiación fotosintéticamente activa (PAR).



Figura 2

Configuración del sistema de tratamiento de aguas residuales VGW-BF de Laguna Innovation.

La investigación específica en el valle de Arava y Ma'ale Gilboa proporciona evidencia cuantitativa sobre la capacidad de los sistemas Agri-PV para modificar positivamente el microclima. Se registró que la gestión inteligente del sombreado reduce la temperatura ambiente bajo los paneles en un promedio de 3,00 °C, creando un refugio térmico para los cultivos.

En el caso del camote (*Ipomoea batatas*), Omer y otros (2024) reportaron una reducción de la evapotranspiración del 31,00 % y un incremento notable en la biomasa fresca del 56,13 % bajo configuraciones agrivoltaicas de espectro dividido, frente al control a pleno sol. Por el contrario, en cultivos como el zuquini (*Cucurbita pepo*), los resultados experimentales en el Instituto Arava no mostraron diferencias estadísticamente significativas en el rendimiento entre parcelas de sombra y sol, lo que sugiere que la especie tolera altos niveles de sombreado sin penalización productiva, permitiendo la generación energética íntegra en la misma área.

Respecto a la productividad dual, el estudio de Ben Naim y otros (2025) sobre tomate es interesante, puesto que, utilizando una configuración de seguimiento solar en un solo eje (single-axis tracking), una altura de 1,70 metros y una relación de cobertura de suelo (GCR) del 26,00 %, se analizaron arreglos de 5, 6 y 7 filas de plantas entre los paneles. Aunque en el escenario de máxima densidad (7 filas) se reportó una pérdida de

rendimiento agrícola bruto del 19,40 % debido a la reducción de luz acumulada, el sistema generó aproximadamente 29 000 kWh por cada 1 000 m² por temporada.

A pesar de la menor biomasa cosechada, el beneficio neto anual fue 9,54 veces superior al de la agricultura convencional. Esto se explica porque los ingresos por la venta de electricidad y el ahorro en costos operativos de agua superan con creces el valor de la cosecha perdida, validando la rentabilidad económica del modelo.

El agua como coadyuvante de la paz y estabilidad regional

En villas palestinas hay proyectos vigentes donde el Dr. Clive Lipchin promueve innovaciones israelíes para ayudar a desalinizar el agua de pozos profundos, como se muestra en la Figura 3, que luego se usa para regar plantaciones de dátiles. La provisión de agua potable y las soluciones de refrigeración solar para la postcosecha no solo han asegurado la soberanía alimentaria, sino que han fortalecido los acuerdos de cooperación transfronteriza, demostrando que la seguridad del nexo hídrico-energético es una precondition para una paz duradera en la región (Arava Institute, 2025). Una prueba de esto es que la paz duradera entre Israel y Jordania se ha logrado con la entrega de agua potable gracias a la innovación israelí de la desalinización.



Figura 3

Villa palestina de Al Auja: proyectos de diplomacia científica con base en el agua

Discusión

La evidencia recolectada en Ma'ale Gilboa y el Arava Institute resalta que el éxito de la agricultura inteligente depende de una gobernanza tecnológica robusta y de la capacidad de transferencia hacia los productores locales. El modelo de los kibutzim en Israel ha demostrado que el aprendizaje compartido y la colectivización del riesgo financiero son precondiciones críticas para la adopción de tecnologías de la información y comunicación (TIC) (Zohar y otros, 2022). Esta estructura de innovación desde el medio (*middle-out*) es particularmente relevante para el Ecuador, donde el sistema agrícola andino requiere de modelos asociativos similares para viabilizar la alta inversión inicial que exigen los sistemas Agri-PV (Serrano y otros, 2024; Zohar y otros, 2022).

Reflexiones sobre la eficiencia en el uso del suelo y el rendimiento

Los hallazgos de esta investigación coinciden con la tendencia global que sitúa a la relación de equivalencia de tierra (LER) consistentemente por encima de 1,00. Mientras que en el estudio de Ben Naim y otros (2025) en Israel se alcanzaron valores de LER entre 1,10 y 1,24 para tomate bajo configuraciones de seguimiento solar, investigaciones en la región de transición andino-amazónica de Perú han reportado LER significativamente superiores, de hasta 1,99, utilizando paneles semitransparentes (Gosgot y otros, 2025). Esta discrepancia sugiere que, en ecosistemas de montaña tropical con alta radiación difusa, el beneficio de la protección radiativa es mayor que en los desiertos de latitud media, lo que supondría un potencial de eficiencia casi duplicada para el callejón

interandino ecuatoriano (Gosgot y otros, 2026).

Los resultados obtenidos en Israel presentan contrastes interesantes con otros climas. La pérdida de rendimiento del 19,40 % en tomate reportada por Ben Naim y otros (2025) es comparable a la reducción del 20,00 % observada en España bajo condiciones de riego deficitario (R. C. M., 2026). Sin embargo, estos datos difieren radicalmente de los obtenidos en regiones semiáridas de Tanzania, donde cultivos como el fréjol y la acelga incrementaron su rendimiento en un 123,70 % y 90,30 %, respectivamente, bajo sombra agrivoltaica (Willockx y otros, 2020). Estas variaciones confirman que la Agri-PV actúa como un amortiguador de estrés térmico; en regiones con temperaturas críticas, el sombreado no es una penalización, sino un potenciador de la productividad (Jia y otros, 2026; Zainali y otros, 2025).

La relación entre el agua, la energía, los alimentos y la sostenibilidad

Desde una perspectiva ambiental, la reducción de la temperatura ambiente en 3,00 °C observada en el valle de Arava se alinea con las mediciones en Arizona, donde se registraron descensos de hasta 8,90 °C en la temperatura de los paneles gracias a la evapotranspiración de los cultivos (Zainali y otros, 2025). Esta sinergia mejora la eficiencia de uso de agua (WUE) entre un 20,00 % y un 47,00 % (Zainali y otros, 2025), factor que resulta vital para los Andes ecuatorianos, donde la irregularidad de las lluvias amenaza la soberanía alimentaria (Barrera y otros, 2020).

En la dimensión económica, la aparente contradicción entre la pérdida de biomasa y el aumento del beneficio neto, que es hasta 9,54 veces

superior en Israel, se explica por la diversificación de ingresos. Este fenómeno ha sido corroborado en Botswana, donde la integración Agri-PV redujo el periodo de recuperación de la inversión (pay-back) de 17 a solo 4 años al sustituir combustibles fósiles por autogeneración solar (National Renewable Energy Laboratory, 2023). En el Ecuador, el beneficio-costo de los sistemas de bombeo solar off-grid se estima en 9,30, superando el 8,40 de los sistemas conectados a la red, lo que valida la viabilidad financiera de desvincular la agricultura rural de la red eléctrica inestable ecuatoriana (Zhang y otros, 2023).

El impacto social se evidencia en el hub de resiliencia de Al-Furaa. La implementación de TIC en comunidades desconectadas no solo provee agua y energía, sino que actúa como una herramienta de diplomacia científica que reduce tensiones geopolíticas (Lipchin y otros, 2025). Para la región andina, el desafío social reside en cerrar la brecha de habilidades digitales. La agricultura 4.0 no debe desplazar al agricultor, sino dotarlo de herramientas de apoyo a la decisión (DSS) que integren el conocimiento ancestral con la analítica de datos en tiempo real (Balamurali y otros, 2025; Zohar y otros, 2022).

Limitaciones y alcance del estudio

A pesar de las ventajas demostradas, esta investigación reconoce limitaciones importantes como los altos costos de capital (CAPEX), que siguen siendo la principal barrera, con incrementos de instalación de hasta el 115,00 % frente a la fotovoltaica convencional (Gadhiya y otros, 2024; GEF, 2024). La respuesta de los cultivos es altamente específica de acuerdo con la especie y la falta de un marco regulatorio claro en el Ecuador para el uso dual del suelo y la inyección de excedentes a la red limita la escalabilidad comercial inmediata (Serrano y otros, 2024). Los futuros estudios deberían enfocarse en evaluaciones de ciclo de vida (LCA) que cuantifiquen la reducción neta de la huella de carbono en la producción de hortalizas andinas bajo este modelo.

Conclusiones

Esta investigación demuestra de manera inequívoca que las tecnologías de la información y comunicación constituyen el núcleo operativo de la sostenibilidad agrícola en entornos de aridez, al articular sistemas de medición, control y analítica con infraestructuras críticas de agua y energía. La evidencia científica analizada confirma que el paradigma agrivoltaico permite superar la competencia por el uso del suelo, logrando consistentemente relaciones de equivalencia de tierra (LER) superiores a 1,00. En configuraciones optimizadas, como las observadas en Israel y validadas en la región andina de Perú, el uso dual del espacio puede incrementar la productividad total del suelo hasta en un 99,00 %, posicionando a esta tecnología como una solución sistémica para la seguridad alimentaria y energética del siglo XXI.

La gestión inteligente del microclima bajo módulos fotovoltaicos actúa como un amortiguador térmico esencial. La reducción de la temperatura ambiente y del suelo, sumada a la mejora en la eficiencia de uso de agua de entre el 20,00 % y el 47,00 %, transforma el entorno del cultivo en un refugio climático resiliente ante olas de calor y sequías prolongadas. Estos beneficios son particularmente críticos para el callejón interandino del Ecuador, donde los sistemas agrivoltaicos ofrecen una protección física contra la radiación UV extrema y las heladas nocturnas, además de mitigar las tasas de erosión catastróficas que actualmente superan la formación natural de suelo en factores de hasta 286 veces.

Este estudio revela que la diversificación de ingresos mediante la generación de electricidad promueve la viabilidad financiera del modelo. Aunque la Agri-PV conlleva reducciones moderadas en el rendimiento de ciertos cultivos, el beneficio neto anual puede ser hasta 9,54 veces superior al de la agricultura convencional debido a la venta de energía y reducción de costos operativos en riego. Para las comunidades altoandinas, la implementación de sistemas descentralizados con periodos de recuperación de la inversión de entre 3 y 6 años representa una oportunidad para desvincular la productividad rural de una red eléctrica a menudo inestable.

El modelo de innovación israelí basado en los kibutzim y los hubs de resiliencia comunitaria como el de Al-Furaa demuestra que la tecnología debe servir como un coadyuvante de la estabilidad y la soberanía local. La transferencia exitosa hacia el Ecuador requiere cerrar la brecha de habilidades digitales y fortalecer los marcos de gobernanza que faciliten el acceso a financiamiento climático. Es imperativo que la academia y el sector público promuevan políticas de generación distribuida y uso dual de suelo, asegurando que la transición hacia una bioeconomía rural resiliente proteja los recursos naturales mientras maximice el bienestar de las familias productoras.

Agradecimientos

El autor agradece al programa de cooperación MASHAV del Estado de Israel por generar oportunidades de movilidad para investigadores de forma que las nuevas tecnologías puedan experimentarse de forma presencial. También se agradece al Instituto de Estudios Ambientales de Arava por gestionar las sesiones presenciales

y en campo, optimizando los recursos para un aprendizaje extendido sobre ciencia, tecnología, sociedad y cultura dentro del curso “Energy Transition and Innovation for Climate Adaptation” desarrollado del 23 de noviembre al 10 de diciembre de 2025.

Declaración de conflictos de interés

El autor declara no tener conflictos de interés.

Fuentes de financiación

Para escribir este artículo se utilizaron fuentes de financiamiento del programa MASHAV de Israel y fuentes de financiamiento personal. Este trabajo se da en el marco del proyecto de investi-

gación DIPI-049 de la Escuela Superior Politécnica de Chimborazo y ha servido para contribuir al proyecto de innovación DIETT-INN-002-2025.

Declaración de uso de inteligencia artificial

Este manuscrito fue elaborado con apoyo puntual de herramientas de inteligencia artificial generativa (IA), específicamente ChatGPT para tareas de asistencia editorial. Toda la información técnica, los valores cuantitativos reportados y la interpretación de hallazgos provienen de fuentes primarias citadas u observaciones directas del

autor en el marco del estudio de caso. El autor revisó y validó todo el contenido producido con apoyo de la IA, asumiendo la responsabilidad por el cumplimiento de las políticas editoriales y de citación de la revista.

Declaración de contribución de autoría (CRediT)

Rafael Alexander Cordova Uvidia: Conceptualización; metodología; análisis formal; investigación; recursos; gestión de datos; redacción - borrador original; redacción - revisión y

edición; adquisición de fondos. Roberto Francisco Arias-Hinojosa: apoyo técnico; revisión y edición; análisis del borrador original; adquisición de fondos para el proyecto ESPOCH-DIETT-INN-002.

Referencias

- Alai Secure. (2025, 6 de mayo). *Ecuador enfrenta retos de tecnificación en el agro: apenas el 20% de su superficie cultivada usa riego tecnificado*.
<https://www.alaisecure.com/ecuador-enfrenta-retos-de-tecnificacion-en-el-agro-ape-nas-el-20-de-su-superficie-cultivada-usa-riego-tecnificado/>
- Arava Institute for Environmental Studies. (2024). *Al-Furaa off-grid hub: A water-energy-food nexus framework*.
<https://arava.org/arava-research-centers/center-for-transboundary-water-management/al-furaa-off-grid-hub/>
- Arava Institute for Environmental Studies. (2025). *Annual report FY24: applied environmental diplomacy and AgriPV research*.
<https://arava.org/wp-content/uploads/2025/03/ARAVA-AnnualReport-FY24-ONLINE-V7for3-3-25.pdf>
- Aviram, R., Lipchin, C., Halevi, A., y Corona, A. (2025). Creating and distributing benefits in water diplomacy: The importance of technology in water treatment. *En Routledge handbook of water diplomacy* (p. 10). Routledge.
<https://doi.org/10.4324/9781003178439-19>
- Balamurali, D., Chakankar, S., Sharma, G., Pagey, A. P., Natarajan, M., Shaik, S., Gnanavendan, S., y Arıcı, M. (2025). A solar-powered, internet of things (IoT)-controlled water irrigation system supported by rainfall forecasts utilizing aerosols: A review. *Environment, Development and Sustainability*.
<https://doi.org/10.1007/s10668-024-05953-z>
- Ben Naim, Y., Ladell, C., y Cohen, Y. (2025). Agri-photovoltaic technology allows dual use of land for tomato production and electricity generation. *Scientific Reports*, 15, 43717.
<https://doi.org/10.1038/s41598-025-27602-9>
- CELEC EP. (2024, 22 de febrero). *Gobierno Nacional presentará a los ecuatorianos el Mapa Solar*.
<https://www.celec.gob.ec/noticias/gobierno-nacional-presentara-a-los-ecuatorianos-el-mapa-solar/>
- Chopdar, R. K., Sengar, N., Giri, N. C., y Halliday, D. (2024). Comprehensive review on agrivoltaics with technical, environmental and societal insights. *Renewable and Sustainable Energy Reviews*, 197, 114387.
<https://doi.org/10.1016/j.rser.2024.114387>

- Coherent Market Insights. (2025). *United States agrivoltaics market: value, forecasts and growth projections (2025-2032)*.
<https://www.coherentmi.com/industry-reports/united-states-agrivoltaics-market>
- Cosme, I., y Vázquez y Parraguirre, S. (2025). Deconstructing agrivoltaic microclimates: A critical review of inherent complexity and a minimum viable monitoring framework. *Agronomy*, 15(12), 2829.
<https://doi.org/10.3390/agronomy15122829>
- De Francesco, C., Centorame, L., Toscano, G., y Duca, D. (2025). Opportunities, technological challenges and monitoring approaches in agrivoltaic systems for sustainable management. *Sustainability*, 17(2), 634.
<https://doi.org/10.3390/su17020634>
- Díaz, J., Quiñonez, Y., De-la-Hoz-Franco, E., Butt-Aziz, S., Mercado, T., y Salcedo, D. (2025). Information and communication technologies used in precision agriculture: A systematic review. *AgriEngineering*, 7(6), 167.
<https://doi.org/10.3390/agriengineering7060167>
- Embajada de Israel. (2025). Entrega Donación de Sistema que Dotará de Agua Potable a más de Dos Mil Cien Personas.
<https://embassies.gov.il/panama/es/node/7892>
- Gosgot Angeles, W., Montenegro Santillan, Y., Santillan Gomez, H., Yalta Chappa, M., Mori Servan, D. C., Oliva-Cruz, M., Ordinola Ramírez, C., Espinoza Canaza, F. I., Gamarra-Torres, O. A., Barrena Gurbillón, M. Á., y Lopes Silva, D. A. (2026). Land-Use Efficiency of Agrivoltaic Systems Under Different Photovoltaic Configurations in an Andean–Amazon Transition Region of Peru. *Energies*, 19(8), 1881.
<https://doi.org/10.3390/en19081881>
- Herlina, Firda y Khalid, Anhar y Muttaqin, Idzani y Arifin, Jainal y Suprpto, M. y Mujiburahman, y Dwiretnosari, y Panca, Yuli. (2025). Solar-Powered Clean Water Treatment: Applications, Future Prospects, and Challenges. *International Journal of Educational and Life Sciences*. 3. 2951-2962. 10.59890/ijels.v3i10.183.
- Jia, M, B. Peng, K. Guan, D.M. Lawrence, E.H. DeLucia, A.K. Knapp, G.A. Barron-Gafford, M. Khanna, D.L. Lombardozzi, M.A. Sturchio, S.A. Kannenberg, L. Zhao, J. McCall, J. Tang, C.J. Bernacchi, P. Mwebaze, F. Majeed, D. Lee, y A. Time, Climate-driven divergence in biophysical and economic impacts of agrivoltaics, *Proc. Natl. Acad. Sci. U.S.A.* 123 (10) e2514380123,
<https://doi.org/10.1073/pnas.2514380123> (2026).

- Mehta, K., y Zörner, W. (2025). Optimizing Agri-PV System: Systematic Methodology to Assess Key Design Parameters. *Energies*, 18(14), 3877.
<https://doi.org/10.3390/en18143877>
- NREL [National Renewable Energy Laboratory]. (2023). *Agrivoltaics: Solar Farming for a Greener Future*. National Renewable Energy Laboratory.
<https://docs.nrel.gov/docs/fy24osti/87786.pdf>
- Omer, A., Liu, W., Liu, X., Li, M., Zhang, X., Chen, F., ... Zhang, Z. (2024). Effects of Agricultural Photovoltaic Systems Development on Sweet Potato Growth: Novel Agrivoltaics for Water Food Energy Nexus. *Agrivoltaics Conference Proceedings*, 1.
<https://doi.org/10.52825/agripv.v1i.588>
- Oñate-Valdivieso F, Oñate-Paladines A and Díaz R (2024) Soil degradation in andean watersheds: a case study using remote sensing. *Front. Earth Sci.* 12:1325189. doi: 10.3389/feart.2024.1325189
- Pathmudi, V. R., Khatri, N., Kumar, S., Abdul-Qawy, A. S. H., & Vyas, A. K. (2023). A systematic review of IoT technologies and their constituents for smart and sustainable agriculture applications. *Scientific African*, 19, e01577.
<https://doi.org/10.1016/j.sciaf.2023.e01577>
- R. C. M. (2026, 23 de marzo). *Regar menos y generar energía, la doble apuesta que puede salvar el tomate español de la sequía*. Diario de Sevilla.
https://www.diariodesevilla.es/medio-ambiente/agua/regar-generar-energia-doble-apuesta_0_2006277300.html
- Rouini N, Salazar A, Murphy P, Lepley K and Barron-Gafford GA (2025) High-shade dryland agrivoltaic conditions enhanced carbon uptake and water-use efficiency in zucchini (*Cucurbita pepo*). *Front. Sustain. Food Syst.* 9:1686773. doi: 10.3389/fsufs.2025.1686773
- Sadeghi Chamazkoti, S., Hajinezhad, A., y Moosavian, S. F. (2025). Techno-economic analysis and optimization of agrivoltaic systems for green hydrogen production in diverse climates. *International Journal of Hydrogen Energy*, 123, 247–264.
<https://doi.org/10.1016/j.ijhydene.2025.03.434>
- Santos Valle, S. y Kienzle, J. 2021. *Agricultura 4.0: Robótica agrícola y equipos automatizados para la producción agrícola sostenible*. Gestión integrada de cultivos, N. 24. Roma, FAO.
<https://openknowledge.fao.org/handle/20.500.14283/cb2186es>

- Schindele, S., Trommsdorff, M., Schlaak, A., Obergfell, T., Bopp, G., Wieland, C., Weselek, A., Högy, P., y Weber, E. (2020). Implementation of agrophotovoltaics: Techno-economic analysis of the price-performance ratio and its policy implications. *Applied Energy*, 265, 114737.
<https://doi.org/10.1016/j.apenergy.2020.114737>
- Serrano Guerrero, J. X., Peralta Alvarez, J. C., Quito Zhinin, M. M., Barragan Escandon, E. A., y Zalaméa León, E. (2024). *Agrovoltaic Systems for Crop Improvement in Equatorial Andean Regions*. Ponencia presentada en la 22.^a International Conference on Renewable Energies and Power Quality (ICRE PQ'24), Lisboa, Portugal.
- SolarQuarter. (2026, 21 de febrero). *Israel Approves First National Land-Use Plan For Agrivoltaic Projects*.
<https://solarquarter.com/2026/02/26/israel-approves-first-national-land-use-plan-for-agrivoltaic-projects/>
- Sollazzo, L., Mangherini, G., Diolaiti, V., y Vincenzi, D. (2025). A comprehensive review of agrivoltaics: Multifaceted developments and the potential of luminescent solar concentrators and semi-transparent photovoltaics. *Sustainability*, 17(5), 2206.
<https://doi.org/10.3390/su17052206>
- TrinaSolar. (2025, 16 de junio). *Maximizing LER and PV system performance in agrivoltaics*.
<https://www.trinasolar.com/us/resources/blog/Maximizing-LER-and-PV-System-Performance-in-Agrivoltaics-20250626>
- Widmer, A., Christ, O., Grenz, J., y Norgrove, L. (2024). Agrivoltaics, a promising new tool for electricity and food production: A systematic review. *Renewable and Sustainable Energy Reviews*, 192, 114277.
<https://doi.org/10.1016/j.rser.2023.114277>
- Willockx, B., Uytterhaegen, B., Ronsijn, B., Herteleer, B., y Cappelle, J. (2020). A standardized classification and performance indicators of agrivoltaic systems. *En Proceedings of the 37th European Photovoltaic Solar Energy Conference and Exhibition (EU PVSEC 2020)* (pp. 1995–1998).
<https://doi.org/10.4229/EUPVSEC20202020-6CV.2.47>
- Zainali, S., Ma Lu, S., Bellone, Y., y Campana, P. (2025). *Optimisation of agrivoltaic systems within the water-energy-food nexus*. EarthArXiv.
<https://doi.org/10.31223/X5WJ00>
- Zohar, T., Parag, Y., y Ayalon, O. (2022). Weaving an innovation network from the middle-out: The case of the renewable energy ecosystem. *Energy, Sustainability and Society*, 12, 54.
<https://doi.org/10.1186/s13705-022-00364-2>

Sustainability and smart agriculture

on agrivoltaic and off-grid systems in Israel as a model for the andean region of Ecuador

Rafael Alexander Cordova Uvidia¹
Roberto Arias-Hinojosa²

¹Escuela Superior Politécnica de Chimborazo,
Vicerrectorado de Investigación y Posgrado,
Riobamba, Ecuador.
<https://orcid.org/0000-0002-5326-3782>
rafael.cordova@esPOCH.edu.ec

²Escuela Superior Politécnica de Chimborazo,
Decanato de Innovación, Emprendimiento
y Transferencia de Tecnologías, Riobamba,
Ecuador
<https://orcid.org/0000-0003-1357-8648>
robertof.arias@esPOCH.edu.ec

DOI: 10.61854/rccedia.v1n1.001
Sent: February 11, 2026
Approved: April 27, 2026
Published: Tuesday, July 14, 2026



This work is licensed under a Creative Commons
Attribution-NonCommercial 4.0 International License.

Abstract

The global climate crisis and increasing competition for land use demand an integrated management of the water-energy-food (WEF) nexus. This study analyzes the integration of Information and Communication Technologies (ICTs) and agrivoltaic (Agri-PV) systems in Israel as a resilience model for the high Andean region of Ecuador. The primary objective was to evaluate the technical efficiency of dual land use and decentralized (off-grid) technologies using standardized indicators such as the Land Equivalent Ratio (LER) and Water Use Efficiency (WUE). The methodology involved a transdisciplinary case study across six strategic analysis units (Arava Valley, Ramat Negev, Ma'ale Gilboa, among others) utilizing IoT instrumentation and precision sensors for microclimate and productivity monitoring. Results demonstrate that agrivoltaics can achieve LER values of up to 1.99, reducing ambient temperatures by 3.00 °C and improving WUE between 20.00 % and 47.00 %. Although a 19,40% reduction in gross yield was reported for certain crops, the annual net profit was 9.54 times higher than the conventional model due to distributed energy generation. The study concludes that the innovations observed in Israel offer a viable roadmap for the Ecuadorian highlands, enabling frost mitigation, erosion reduction, and the strengthening of energy sovereignty in rural communities.

Keywords:

*agriculture 4.0, technology,
information, communication,*

Introduction

The global climate crisis has driven a radical transformation in natural resource management, placing sustainability and smart agriculture at the center of development policies to ensure productivity and resilience. In this context, the water-energy-food (WEF) Nexus is characterized by a fragile balance in which competition for land use has intensified dramatically (Chopdar et al., 2024; Zainali et al., 2025). The central challenge lies in the technical incompatibility of isolated production models, whereby the expansion of photovoltaic infrastructure, whose global installed capacity exceeded 14 GWp in 2021, frequently displaces agricultural production from high-quality farmland (Sollazzo et al., 2025; Widmer et al., 2024). Information and communication technologies (ICT) act as the driving force of Agriculture 4.0 by integrating IoT sensors, artificial intelligence, and connectivity protocols to maximize efficiency under resource-scarce conditions (Díaz et al., 2025; Pathmudi et al., 2023).

Israel, through its innovation model based on kibbutzim and R&D centers, has validated the agrivoltaic (Agri-PV) paradigm as a systemic solution that proposes the vertical coexistence of photovoltaic modules and crops (Ben Naim et al., 2025; Zohar et al., 2022), thereby resolving the land-use conflict between energy generation and food production (Schindele et al., 2020; Widmer et al., 2024; Sollazzo et al., 2025; De Francesco et al., 2025; Cosme et al., 2025). By using elevated solar panels, a synergistic effect is achieved in which plants benefit from partial shading, while

the panels operate at lower temperatures due to plant transpiration (Ben Naim et al., 2025). This technology is particularly relevant for the Ecuadorian highlands, where intense solar radiation and nighttime frost require climate protection systems (CELEC EP, 2024).

The fundamental indicator in agrivoltaics is the Land Equivalent Ratio (LER), which quantifies the efficiency of producing energy and food simultaneously compared with separate production systems (Schindele et al., 2020). An LER > 1.0 indicates a dual land-use advantage. Recent studies demonstrate that total land productivity can increase by up to 60%, corresponding to an LER of 1.6 (NREL, 2023). In the Andean-Amazon transition region of Peru, studies published in 2025 reported that semitransparent configurations achieved the highest efficiency values, with an LER ranging from 1.95 to 1.99, followed by bifacial systems (1.66 to 1.90) and monofacial systems (1.51 to 1.72). These findings indicate that, in tropical mountain ecosystems, the response of the agricultural system is the primary driver of LER variability rather than energy generation itself.

Unlike conventional solar farms, Agri-PV systems function as active microclimate modifiers. The scientific literature highlights the mutual cooling effect: crop transpiration reduces local air temperature, cooling the solar panels by between 8.9°C and 10.0°C, which can increase power generation efficiency by up to 3.0% (Zainali et al., 2025). Simultaneously, the projected shade reduces soil temperature by between 3°C and 4°C and

ambient temperature by approximately 1 to 4°C.

The physiological response is highly species- and system-specific. In sweet potato (*Ipomoea batatas*) cultivated under spectrum-splitting systems, a 31% reduction in evapotranspiration and a 56% increase in fresh biomass have been documented (Omer et al., 2024). In contrast, for heliophilous species such as maize and wheat, excessive panel density ($PCR > 0.40$) may significantly reduce yields, as observed in the U.S. Midwest, where maize and soybean yields decreased by 24% and 16%, respectively, under humid conditions (Jia et al., 2026). However, in semiarid regions, shading alleviates water stress, allowing soybean yields to increase by up to 6% (Mehta & Zörner, 2025).

Within the WEF Nexus framework, agri-voltaics improves water use efficiency (WUE) by between 20% and 47% (Zainali et al., 2025). In Spain, integrating Agri-PV with regulated deficit irrigation (RDI) reduced water consumption in tomato cultivation by 50%, while maintaining competitive water productivity despite a 20% reduction in gross yield (Omer et al., 2024).

Water resilience is further strengthened through decentralized systems. The Laguna Innovation technology, validated in Israel, enables wastewater treatment using Vertical Green Walls, operating entirely autonomously with solar power and remote IoT monitoring (Arava Institute, 2024; Aviram et al., 2025). Other advances include atmospheric water generation (WaterGen) and ultrafiltration (NUF technology), which operates by

gravity without chemicals, benefiting vulnerable communities in Panama and Israel (Arava Institute, 2024; Embassy of Israel, 2025).

Although the installation cost of Agri-PV systems is between 4% and 115% higher than that of standard photovoltaic systems due to elevated support structures of up to 5 meters that allow agricultural machinery to pass beneath them (Sadeghi Chamazkoti et al., 2025), income diversification compensates for this investment. Cost-benefit analysis of off-grid solar pumping systems shows a benefit-cost ratio of 9.3 compared with 8.4 for grid-connected systems, with investment payback periods reduced to between 3 and 6 years in diesel replacement scenarios (Herlina et al., 2025).

At the policy level, Israel reached a milestone in February 2026 by approving the first national land-use plan dedicated exclusively to Agri-PV, establishing a clear regulatory framework for large-scale pilot projects. This governance framework is essential for reducing the financial risk faced by smallholder farmers and promoting social acceptance (SolarQuarter, 2026).

The Ecuadorian Highlands possess strong solar potential (2.8 to 6.4 kWh/m²/day) but suffer from catastrophic soil degradation, with erosion rates exceeding natural soil formation by 9 to 286 times. Agri-PV in the Andes would not only generate clean energy for pressurized irrigation systems, whose adoption rate is only 20%, but would also serve as a protective barrier against frost and extreme precipitation events that accelerate erosion on slopes of up to 70%. Studies conducted

in Cuenca and Azogues confirm that crops such as lettuce achieve high yields under partial shade, allowing a 66% increase in market price due to improved quality (Oñate-Valdivieso et al., 2024).

The relevance of this study lies in the transfer of these models to the Ecuadorian high-Andean region. The implementation of Agri-PV systems represents an opportunity for three-dimensional sustainability: environmental, by mitigating frost and reducing evapotranspiration; economic, by diversifying income through the sale of surplus electricity; and social, by strengthening the sovereignty of disconnected rural communities (Alai Secure, 2025; Coherent Market Insights, 2025).

The objectives of this study focus on evaluating the technical efficiency of Agri-PV systems and decentralized (off-grid) technologies observed in Israel, using the Land Equivalent Ratio (LER) and Water Use Efficiency (WUE) as key performance indicators. In addition, the study seeks to analyze the impact of ICT-assisted microclimate management on the physiology of sensitive crops to mitigate thermal stress and, finally, to establish a sustainability roadmap integrating the environmental, economic, and social pillars for the implementation of pilot projects in Ecuador's Inter-Andean Valley.

Methods

The methodology employed in this study is an analytical review with a descriptive case study, based on the author's technology transfer experience and the synthesis of specialized technical literature. The study adopts a transdisciplinary approach to evaluate the water-energy-food (WEF) Nexus, prioritizing the distinction between verifiable scientific evidence and descriptive observations (Zohar et al., 2022). Primary data collection was conducted during a technical immersion in Israel between November and December 2025, with an emphasis on the infrastructure supporting Agriculture 4.0.

Study sites and units of analysis

To ensure the traceability of the study, the exact geographic coordinates of the units of analysis were identified based on their representativeness within the Israeli innovation ecosystem. The sites are distributed across diverse climatic zones, ranging from the extreme aridity of the south to the elevated regions of the north:

- Arava Institute for Environmental Studies (Ketura): Located in Kibbutz Ketura, Arava Valley (29°58'3.36"N, 35°4'15.24"E). This center leads research on fixed and mobile agrivoltaic systems under hyper-arid conditions.
- Ma'ale Gilboa Wind Farm and Energy Storage Facility: Located at the summit of Mount Gilboa, northeast of the Samaria mountain range (32°28'35"N, 35°25'13"E). The specific wind farm is located at 32°28'1.6"N, 35°25'36.3"E, serving as a model for energy flexibility and pumped-storage energy systems.

- Yoel De Malach Center (Ramat Negev): Agricultural research station located near Kibbutz Revivim (approximately 31°02'33"N, 34°43'15"E). It specializes in crop responses to salinity and desert thermal stress.
- Al-Furaa Resilience Hub: Located in the unrecognized Bedouin village of Al-Furaa, near the Beersheba-Arad highway in the central Negev. It serves as the pilot site for decentralized off-grid water and energy technologies.
- Ashalim Solar Thermal Power Station: Located in the Negev Desert, near the community of Ashalim (30°57'45"N, 34°43'48"E). It was evaluated as a benchmark for large-scale energy infrastructure.

Definition and operationalization of variables

The fundamental metric variables used to measure the sustainability of the water-energy-food Nexus were conceptually and operationally defined. First, the Land Equivalent Ratio (LER) was defined as an indicator of dual land-use efficiency, as shown in Equation 1 (TrinaSolar, 2025; Willockx et al., 2020).

$$LER = \frac{Y_{cultivo,AV}}{Y_{cultivo,FS}} + \frac{E_{AV}}{E_{FS}} \quad (Ec. 1)$$

The LER is operationalized as the sum of the relative agricultural and energy yields. Specifically, $Y_{cultivo}$ refers to crop productivity under the agrivoltaic structure (AV) and under full sunlight

(FS), whereas E represents agrivoltaic energy production (AV) and the energy generation of a standard photovoltaic system without crops beneath the panels (PV).

Another variable used in this study is Water Use Efficiency (WUE), defined as the ratio between the total biomass produced and the volume of water consumed (kg/m^3), measured using electronic flow meters and soil moisture sensors (Zainali et al., 2025).

Finally, Photosynthetically Active Radiation (PAR) was considered, defined as the amount of light available for photosynthesis within the 400 to 700 nm spectrum, measured beneath photovoltaic panels in $\mu\text{mol}/\text{m}^2/\text{s}$ (Ben Naim et al., 2025; Cosme & Vázquez and Parraguirre, 2025).

Instrumentation and data collection techniques

The study was initially based on visits to sites of interest in Israel where the use of advanced monitoring tools integrated through the Internet of Things (IoT) was observed. Sensor networks were examined for the continuous measurement of volumetric soil moisture, ambient and soil temperature, and nutrient levels such as carbon and nitrogen (Santos Valle & Kienzle, 2021).

Structural parameters were recorded, including the Ground Coverage Ratio (GCR), the module height standardized at 5 meters to allow the passage of agricultural machinery, and the spacing between rows (Willockx et al., 2020). Finally, data obtained from real-time monitoring platforms were analyzed to evaluate the quality of reclaimed water in Laguna Innovation treatment systems and the atmospheric water production of WaterGen (Arava Institute, 2024).

Analysis and validation procedures

The technical analysis procedures focused on evaluating agricultural performance under different photovoltaic shading configurations and the efficiency of decentralized systems. Productivity data for tomato and zucchini (*Cucurbita pepo*) were specifically examined by evaluating fresh and dry biomass parameters, as well as postharvest quality (Omer et al., 2024; Rouini et al., 2025). The validation of the primary information was carried out through data triangulation with previous research led by Dr. Tali Zohar and Dr. Clive Lipchin (Ben Naim et al., 2025; Zohar et al., 2022).

Results

The findings of this study are derived from the direct observation of operational infrastructure and the analysis of data collected within Israel's innovation ecosystem. The results demonstrate that the integration of information and communication technologies (ICT) enables granular management of the water-energy-food (WEF) Nexus, optimizing productivity in extremely arid environments. The application of these technologies in the Ecuadorian highlands has the potential to positively impact food sovereignty, environmental sustainability, and the energy independence of rural and urban communities

Precision Agriculture, Robotics, and the Coupled Design Principle

In Israel, interest in agrivoltaics has moved beyond the experimental stage to become integrated with national climate adaptation strategies. The collected evidence reinforces the agronomic-energy coupled design principle, which states that system configuration must be tailored to each specific crop. It was determined that parameters such as module height (standardized at 1.70 m in low-height trials and 5.00 m to allow the passage of agricultural machinery), panel density, and the use of bifacial technologies are critical determinants of system success (Cosme & Vázquez and Parraguirre, 2025; Sollazzo et al., 2025).

ICT is the critical enabler of agricultural sustainability under hyper-arid conditions. Figure 1 presents a technical composition of the observed systems. It highlights the use of autonomous agricultural robots powered by bifacial solar panels to perform multipoint monitoring of critical varia-

bles, including volumetric soil moisture, nitrogen concentration, and soil organic carbon. This data stream enables the system to deliver the exact amount of water and fertilizer through computerized fertigation, eliminating input waste under conditions of resource scarcity (Santos Valle & Kienzle, 2021).

Off-Grid Systems for Wastewater Treatment

Within the context of smart and decentralized agriculture, Laguna Innovation technology represents a paradigm shift in wastewater treatment for irrigation. The Vertical Green Wall (VGW-BF) system, operated entirely off-grid using solar panels, integrates IoT sensors that transmit 24/7 data on effluent quality and operational status (Figure 2).

At the Al-Furaa Regional School, which serves 1,200 students, this modular infrastructure enables the recovery of nutrient-rich effluents for local agricultural irrigation. Operational data indicate contaminant removal efficiencies exceeding 90.00% for biochemical oxygen demand (BOD₅) and total suspended solids (TSS), while eliminating sludge production and drastically reducing the energy footprint compared with centralized sanitation networks (Arava Institute, 2024; Aviram et al., 2025).




Figure 1

Technical composition of Agriculture 4.0 and agrivoltaic systems: (A) autonomous robot for precision irrigation and nutrient (C, N) monitoring under bifacial structures; (B) technical view of the inclination of sun-tracking modules for optimizing photosynthetically active radiation (PAR).



Figure 2

Configuration of the Laguna Innovation VGW-BF wastewater treatment system

The research conducted in the Arava Valley and Ma'ale Gilboa provides quantitative evidence of the ability of Agri-PV systems to positively modify the microclimate. It was observed that intelligent shading management reduced ambient temperature beneath the panels by an average of 3.00°C, creating a thermal refuge for crops.

For sweet potato (*Ipomoea batatas*), Omer et al. (2024) reported a 31.00% reduction in evapotranspiration and a remarkable 56.13% increase in fresh biomass under spectrum-splitting agri-voltaic configurations compared with the full-sun control. In contrast, for zucchini (*Cucurbita pepo*), experimental results at the Arava Institute showed no statistically significant differences in yield between shaded and full-sun plots, suggesting that the species tolerates high levels of shading without yield penalties, thereby allowing full energy generation within the same area.

Regarding dual productivity, the study by Ben Naim et al. (2025) on tomato cultivation is particularly noteworthy. Using a single-axis tracking configuration, a module height of 1.70 m, and a ground coverage ratio (GCR) of 26.00%, the authors evaluated arrangements of 5, 6, and 7 crop rows between the panels. Although the highest-density configuration (7 rows) resulted in a 19.40% reduction in gross agricultural yield due to decreased cumulative light availability, the system generated approximately 29 000 kWh per 1 000 m² per growing season.

Despite the lower harvested biomass, the annual net profit was 9.54 times higher than that of conventional agriculture. This is explained by the fact that revenues from electricity sales and savings in water-related operating costs more than compensated for the value of the lost harvest, validating the economic profitability of the model.

Water as a catalyst for peace and regional stability

In Palestinian villages, ongoing projects led by Dr. Clive Lipchin promote Israeli innovations to desalinate water from deep wells, as shown in Figure 3, which is subsequently used to irrigate date palm plantations. The provision of drinking water and solar-powered cooling solutions for postharvest preservation has not only strengthened food sovereignty but has also reinforced cross-border cooperation agreements, demonstrating that water-energy Nexus security is a prerequisite for lasting peace in the region (Arava Institute, 2025). Evidence of this is the enduring peace between Israel and Jordan, which has been sustained through the provision of drinking water enabled by Israeli desalination innovation.



Figure 3

Al Auja Palestinian village: water-based scientific diplomacy projects

Discussion

The evidence collected at Ma'ale Gilboa and the Arava Institute highlights that the success of smart agriculture depends on robust technological governance and the capacity to transfer knowledge to local producers. The kibbutz model in Israel has demonstrated that shared learning and the collective distribution of financial risk are critical prerequisites for the adoption of information and communication technologies (ICT) (Zohar et al., 2022). This middle-out innovation structure is particularly relevant for Ecuador, where the Andean agricultural system requires similar associative models to make the high initial investment required by Agri-PV systems feasible (Serrano et al., 2024; Zohar et al., 2022).

Reflections on land use efficiency and productivity

The findings of this study are consistent with the global trend of Land Equivalent Ratio (LER) values consistently exceeding 1.00. Whereas the study by Ben Naim et al. (2025) in Israel reported LER values ranging from 1.10 to 1.24 for tomatoes under solar tracking configurations, studies conducted in the Andean-Amazon transition region of Peru have reported significantly higher LER values, reaching up to 1.99 through the use of semitransparent panels (Gosgot et al., 2026). This discrepancy suggests that, in tropical mountain ecosystems with high diffuse solar radiation, the benefits of radiative protection are greater than those observed in mid-latitude deserts, implying the potential for nearly double the efficiency in Ecuador's Inter-Andean Valley (Gosgot et al., 2026; Serrano et al., 2024).

The results obtained in Israel present interesting contrasts with those reported under other climatic conditions. The 19.40% yield reduction in tomato reported by Ben Naim et al. (2025) is comparable to the 20.00% reduction observed in Spain under regulated deficit irrigation conditions (R. C. M., 2026). However, these findings differ markedly from those obtained in semiarid regions of Tanzania, where crops such as common bean and Swiss chard increased their yields by 123.70% and 90.30%, respectively, under agrivoltaic shading (Willockx et al., 2020). These variations confirm that Agri-PV functions as a thermal stress buffer; in regions experiencing critical temperatures, shading is not a productivity penalty but rather a productivity enhancer (Jia et al., 2026; Zainali et al., 2025).

The relationship between water, energy, food, and sustainability

From an environmental perspective, the 3.00°C reduction in ambient temperature observed in the Arava Valley is consistent with measurements reported in Arizona, where crop evapotranspiration reduced panel temperatures by up to 8.90°C (Zainali et al., 2025). This synergy improves Water Use Efficiency (WUE) by between 20.00% and 47.00% (Zainali et al., 2025), a factor of critical importance for the Ecuadorian Andes, where irregular rainfall threatens food sovereignty.

From an economic perspective, the apparent contradiction between biomass losses and the increase in net profit—up to 9.54 times higher in Israel—is explained by income diversification. This phenomenon has also been confirmed in Botswana, where Agri-PV integration reduced the investment payback period from 17 to only 4 years

by replacing fossil fuels with solar self-generation (National Renewable Energy Laboratory, 2023). In Ecuador, the benefit-cost ratio of off-grid solar pumping systems is estimated at 9.30, exceeding the value of 8.40 for grid-connected systems, thereby confirming the financial viability of decoupling rural agriculture from Ecuador's unstable electrical grid (Herlina et al., 2025).

The social impact is evidenced by the AI-Furraa Resilience Hub. The implementation of ICT in disconnected communities not only provides water and energy but also serves as a scientific diplomacy tool that reduces geopolitical tensions (Aviram et al., 2025). For the Andean region, the primary social challenge lies in closing the digital skills gap. Agriculture 4.0 should not replace farmers but rather equip them with Decision Support Systems (DSS) that integrate traditional knowledge with real-time data analytics (Balamurali et al., 2025; Zohar et al., 2022).

Limitations and Scope of the Study

Despite the demonstrated advantages, this study acknowledges important limitations. High capital expenditures (CAPEX) remain the principal barrier, with installation costs increasing by as much as 115.00% compared with conventional photovoltaic systems (Sadeghi Chamazkoti et al., 2025). Crop response is highly species-specific, and the absence of a clear regulatory framework in Ecuador governing dual land use and surplus electricity injection into the power grid limits immediate commercial scalability (Serrano et al., 2024). Future studies should focus on life cycle assessments (LCA) to quantify the net reduction in the carbon footprint associated with the production of Andean vegetable crops under this model.

Conclusions

This study demonstrates that information and communication technologies (ICT) constitute the operational core of agricultural sustainability in arid environments by integrating measurement, control, and analytics systems with critical water and energy infrastructure. The scientific evidence analyzed confirms that the agrivoltaic paradigm overcomes land-use competition by consistently achieving Land Equivalent Ratio (LER) values greater than 1.00. Under optimized configurations, such as those observed in Israel and validated in the Andean region of Peru, dual land use can increase total land productivity by up to 99.00%, positioning this technology as a systemic solution for food and energy security in the twenty-first century.

Intelligent microclimate management beneath photovoltaic modules functions as an essential thermal buffer. The reduction in ambient and soil temperatures, together with improvements in Water Use Efficiency (WUE) ranging from 20.00% to 47.00%, transforms the crop environment into a climate-resilient refuge against heat waves and prolonged droughts. These benefits are particularly critical for Ecuador's Inter-Andean Valley, where agrivoltaic systems provide physical protection against extreme UV radiation and nighttime frost while also mitigating catastrophic erosion rates that currently exceed natural soil formation by factors of up to 286.

This study reveals that income diversification through electricity generation enhances the financial viability of the model. Although Agri-PV may result in moderate yield reductions for certain crops, annual net profit can be up to 9.54 times higher than that of conventional agriculture due to electricity sales and reduced irrigation operating costs. For high-Andean communities, the implementation of decentralized systems with investment payback periods ranging from 3 to 6 years represents an opportunity to decouple rural productivity from an often unstable electrical grid.

The Israeli innovation model based on kibbutzim and community resilience hubs such as Al-Furaa demonstrates that technology should serve as a catalyst for stability and local sovereignty. Successful transfer to Ecuador requires closing the digital skills gap and strengthening governance frameworks that facilitate access to climate financing. It is imperative that academia and the public sector promote policies supporting distributed generation and dual land use, ensuring that the transition toward a resilient rural bioeconomy protects natural resources while maximizing the well-being of farming families.

Acknowledgements

The author gratefully acknowledges the MASHAV cooperation program of the State of Israel for providing mobility opportunities that enabled researchers to experience emerging technologies firsthand. The author also thanks the Arava Institute for Environmental Studies for or-

ganizing the on-site and field sessions, optimizing resources for an extended learning experience on science, technology, society, and culture within the course “Energy Transition and Innovation for Climate Adaptation,” held from November 23 to December 10, 2025.

Conflict of interest statement

The author declares that there are no conflicts of interest.

Funding sources

This article was prepared using funding from the MASHAV program of Israel and the author's personal financial resources. This work was carried out within the framework of research project

DIPI-049 of the Escuela Superior Politécnica de Chimborazo and has contributed to innovation project DIETT-INN-002-2025.

Declaration on the use of artificial intelligence

This manuscript was prepared with limited support from generative artificial intelligence (AI) tools, specifically ChatGPT, for editorial assistance tasks. All technical information, reported quantitative values, and interpretation of the findings originate from the cited primary sources or from the author's direct observations within the fra-

mework of the case study. The author reviewed and validated all content generated with AI support and assumes full responsibility for compliance with the journal's editorial and citation policies.

Author contributions (CRediT)

Rafael Alexander Córdova Uvidia: Conceptualization; methodology; formal analysis; investigation; resources; data curation; writing – original draft; writing.

Roberto Francisco Arias-Hinojosa: Technical support; review and editing; original draft analysis; funding acquisition for the ESPOCH-DIETT-INN-002 project.

References

- Alai Secure. (2025, 6 de mayo). *Ecuador enfrenta retos de tecnificación en el agro: apenas el 20% de su superficie cultivada usa riego tecnificado*.
<https://www.alaisecure.com/ecuador-enfrenta-retos-de-tecnificacion-en-el-agro-ape-nas-el-20-de-su-superficie-cultivada-usa-riego-tecnificado/>
- Arava Institute for Environmental Studies. (2024). *Al-Furaa off-grid hub: A water-energy-food nexus framework*.
<https://arava.org/arava-research-centers/center-for-transboundary-water-management/al-furaa-off-grid-hub/>
- Arava Institute for Environmental Studies. (2025). *Annual report FY24: applied environmental diplomacy and AgriPV research*.
<https://arava.org/wp-content/uploads/2025/03/ARAVA-AnnualReport-FY24-ONLINE-V7for3-3-25.pdf>
- Aviram, R., Lipchin, C., Halevi, A., y Corona, A. (2025). Creating and distributing benefits in water diplomacy: The importance of technology in water treatment. *En Routledge handbook of water diplomacy* (p. 10). Routledge.
<https://doi.org/10.4324/9781003178439-19>
- Balamurali, D., Chakankar, S., Sharma, G., Pagey, A. P., Natarajan, M., Shaik, S., Gnanavendan, S., y Arıcı, M. (2025). A solar-powered, internet of things (IoT)-controlled water irrigation system supported by rainfall forecasts utilizing aerosols: A review. *Environment, Development and Sustainability*.
<https://doi.org/10.1007/s10668-024-05953-z>
- Ben Naim, Y., Ladell, C., y Cohen, Y. (2025). Agri-photovoltaic technology allows dual use of land for tomato production and electricity generation. *Scientific Reports*, 15, 43717.
<https://doi.org/10.1038/s41598-025-27602-9>
- CELEC EP. (2024, 22 de febrero). *Gobierno Nacional presentará a los ecuatorianos el Mapa Solar*.
<https://www.celec.gob.ec/noticias/gobierno-nacional-presentara-a-los-ecuatorianos-el-mapa-solar/>
- Chopdar, R. K., Sengar, N., Giri, N. C., y Halliday, D. (2024). Comprehensive review on agrivoltaics with technical, environmental and societal insights. *Renewable and Sustainable Energy Reviews*, 197, 114387.
<https://doi.org/10.1016/j.rser.2024.114387>

- Coherent Market Insights. (2025). *United States agrivoltaics market: value, forecasts and growth projections (2025-2032)*.
<https://www.coherentmi.com/industry-reports/united-states-agrivoltaics-market>
- Cosme, I., y Vázquez y Parraguirre, S. (2025). Deconstructing agrivoltaic microclimates: A critical review of inherent complexity and a minimum viable monitoring framework. *Agronomy*, 15(12), 2829.
<https://doi.org/10.3390/agronomy15122829>
- De Francesco, C., Centorame, L., Toscano, G., y Duca, D. (2025). Opportunities, technological challenges and monitoring approaches in agrivoltaic systems for sustainable management. *Sustainability*, 17(2), 634.
<https://doi.org/10.3390/su17020634>
- Díaz, J., Quiñonez, Y., De-la-Hoz-Franco, E., Butt-Aziz, S., Mercado, T., y Salcedo, D. (2025). Information and communication technologies used in precision agriculture: A systematic review. *AgriEngineering*, 7(6), 167.
<https://doi.org/10.3390/agriengineering7060167>
- Embajada de Israel. (2025). Entrega Donación de Sistema que Dotará de Agua Potable a más de Dos Mil Cien Personas.
<https://embassies.gov.il/panama/es/node/7892>
- Gosgot Angeles, W., Montenegro Santillan, Y., Santillan Gomez, H., Yalta Chappa, M., Mori Servan, D. C., Oliva-Cruz, M., Ordinola Ramírez, C., Espinoza Canaza, F. I., Gamarra-Torres, O. A., Barrena Gurbillón, M. Á., y Lopes Silva, D. A. (2026). Land-Use Efficiency of Agrivoltaic Systems Under Different Photovoltaic Configurations in an Andean–Amazon Transition Region of Peru. *Energies*, 19(8), 1881.
<https://doi.org/10.3390/en19081881>
- Herlina, Firda y Khalid, Anhar y Muttaqin, Idzani y Arifin, Jainal y Suprpto, M. y Mujiburahman, y Dwiretnosari, y Panca, Yuli. (2025). Solar-Powered Clean Water Treatment: Applications, Future Prospects, and Challenges. *International Journal of Educational and Life Sciences*. 3. 2951-2962. 10.59890/ijels.v3i10.183.
- Jia, M, B. Peng, K. Guan, D.M. Lawrence, E.H. DeLucia, A.K. Knapp, G.A. Barron-Gafford, M. Khanna, D.L. Lombardozzi, M.A. Sturchio, S.A. Kannenberg, L. Zhao, J. McCall, J. Tang, C.J. Bernacchi, P. Mwebaze, F. Majeed, D. Lee, y A. Time, Climate-driven divergence in biophysical and economic impacts of agrivoltaics, *Proc. Natl. Acad. Sci. U.S.A.* 123 (10) e2514380123,
<https://doi.org/10.1073/pnas.2514380123> (2026).

- Mehta, K., y Zörner, W. (2025). Optimizing Agri-PV System: Systematic Methodology to Assess Key Design Parameters. *Energies*, 18(14), 3877.
<https://doi.org/10.3390/en18143877>
- NREL [National Renewable Energy Laboratory]. (2023). *Agrivoltaics: Solar Farming for a Greener Future*. National Renewable Energy Laboratory.
<https://docs.nrel.gov/docs/fy24osti/87786.pdf>
- Omer, A., Liu, W., Liu, X., Li, M., Zhang, X., Chen, F., ... Zhang, Z. (2024). Effects of Agricultural Photovoltaic Systems Development on Sweet Potato Growth: Novel Agrivoltaics for Water Food Energy Nexus. *Agrivoltaics Conference Proceedings*, 1.
<https://doi.org/10.52825/agripv.v1i.588>
- Oñate-Valdivieso F, Oñate-Paladines A and Díaz R (2024) Soil degradation in andean watersheds: a case study using remote sensing. *Front. Earth Sci.* 12:1325189. doi: 10.3389/feart.2024.1325189
- Pathmudi, V. R., Khatri, N., Kumar, S., Abdul-Qawy, A. S. H., & Vyas, A. K. (2023). A systematic review of IoT technologies and their constituents for smart and sustainable agriculture applications. *Scientific African*, 19, e01577.
<https://doi.org/10.1016/j.sciaf.2023.e01577>
- R. C. M. (2026, 23 de marzo). *Regar menos y generar energía, la doble apuesta que puede salvar el tomate español de la sequía*. Diario de Sevilla.
https://www.diariodesevilla.es/medio-ambiente/agua/regar-generar-energia-doble-apuesta_0_2006277300.html
- Rouini N, Salazar A, Murphy P, Lepley K and Barron-Gafford GA (2025) High-shade dryland agrivoltaic conditions enhanced carbon uptake and water-use efficiency in zucchini (*Cucurbita pepo*). *Front. Sustain. Food Syst.* 9:1686773. doi: 10.3389/fsufs.2025.1686773
- Sadeghi Chamazkoti, S., Hajinezhad, A., y Moosavian, S. F. (2025). Techno-economic analysis and optimization of agrivoltaic systems for green hydrogen production in diverse climates. *International Journal of Hydrogen Energy*, 123, 247–264.
<https://doi.org/10.1016/j.ijhydene.2025.03.434>
- Santos Valle, S. y Kienzle, J. 2021. *Agricultura 4.0: Robótica agrícola y equipos automatizados para la producción agrícola sostenible*. Gestión integrada de cultivos, N. 24. Roma, FAO.
<https://openknowledge.fao.org/handle/20.500.14283/cb2186es>

- Schindele, S., Trommsdorff, M., Schlaak, A., Obergfell, T., Bopp, G., Wieland, C., Weselek, A., Högy, P., y Weber, E. (2020). Implementation of agrophotovoltaics: Techno-economic analysis of the price-performance ratio and its policy implications. *Applied Energy*, 265, 114737.
<https://doi.org/10.1016/j.apenergy.2020.114737>
- Serrano Guerrero, J. X., Peralta Alvarez, J. C., Quito Zhinin, M. M., Barragan Escandon, E. A., y Zalaméa León, E. (2024). *Agrovoltaic Systems for Crop Improvement in Equatorial Andean Regions*. Ponencia presentada en la 22.^a International Conference on Renewable Energies and Power Quality (ICRE PQ'24), Lisboa, Portugal.
- SolarQuarter. (2026, 21 de febrero). *Israel Approves First National Land-Use Plan For Agrivoltaic Projects*.
<https://solarquarter.com/2026/02/26/israel-approves-first-national-land-use-plan-for-agrivoltaic-projects/>
- Sollazzo, L., Mangherini, G., Diolaiti, V., y Vincenzi, D. (2025). A comprehensive review of agrivoltaics: Multifaceted developments and the potential of luminescent solar concentrators and semi-transparent photovoltaics. *Sustainability*, 17(5), 2206.
<https://doi.org/10.3390/su17052206>
- TrinaSolar. (2025, 16 de junio). *Maximizing LER and PV system performance in agrivoltaics*.
<https://www.trinasolar.com/us/resources/blog/Maximizing-LER-and-PV-System-Performance-in-Agrivoltaics-20250626>
- Widmer, A., Christ, O., Grenz, J., y Norgrove, L. (2024). Agrivoltaics, a promising new tool for electricity and food production: A systematic review. *Renewable and Sustainable Energy Reviews*, 192, 114277.
<https://doi.org/10.1016/j.rser.2023.114277>
- Willockx, B., Uytterhaegen, B., Ronsijn, B., Herteleer, B., y Cappelle, J. (2020). A standardized classification and performance indicators of agrivoltaic systems. *En Proceedings of the 37th European Photovoltaic Solar Energy Conference and Exhibition (EU PVSEC 2020)* (pp. 1995–1998).
<https://doi.org/10.4229/EUPVSEC20202020-6CV.2.47>
- Zainali, S., Ma Lu, S., Bellone, Y., y Campana, P. (2025). *Optimisation of agrivoltaic systems within the water-energy-food nexus*. EarthArXiv.
<https://doi.org/10.31223/X5WJ00>
- Zohar, T., Parag, Y., y Ayalon, O. (2022). Weaving an innovation network from the middle-out: The case of the renewable energy ecosystem. *Energy, Sustainability and Society*, 12, 54.
<https://doi.org/10.1186/s13705-022-00364-2>

Sistema portátil de sensores

**para la medición de nutrientes NPK en cultivos de
café orientado a la agricultura de precisión en Loja,
Ecuador**

*Franklin Jiménez Peralta¹,
Marianela Carrión González²*

¹Universidad Nacional de Loja, Facultad de la
Energía, las Industrias y los Recursos Naturales
no Renovables, Carrera de Ingeniería en
Telecomunicaciones, Loja, Ecuador,
<https://orcid.org/0000-0002-4976-1017>
franklin.g.jimenez@unl.edu.ec

²Universidad Nacional de Loja, Facultad de la
Energía, las Industrias y los Recursos Naturales
no Renovables, Carrera de Ingeniería en
Telecomunicaciones, Loja, Ecuador,
<https://orcid.org/0000-0002-4976-1017>
marianela.carrion@unl.edu.ec

DOI: 10.61854/rccedia.v1n1.002

Enviado: 13 de febrero de 2026

Aprobado: 09 de abril de 2026

Publicado: martes 14 de julio de 2026



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Resumen

El monitoreo oportuno de nutrientes en suelos agrícolas es fundamental para optimizar la fertilización y mejorar la productividad en cultivos de café bajo esquemas de agricultura de precisión. El objetivo de este estudio fue desarrollar y evaluar preliminarmente un sistema portátil de monitoreo de nitrógeno (N), fósforo (P) y potasio (K) basado en un microcontrolador Arduino y un sensor comercial con comunicación RS-485, aplicado en un cultivo de café en Loja, Ecuador. Se realizaron diez mediciones in situ en un terreno de aproximadamente tres hectáreas y los resultados fueron comparados con un análisis de laboratorio obtenido a partir de una muestra compuesta representativa del área de estudio. Los valores promedio obtenidos por el sistema fueron 32,71 ppm para N; 32,92 ppm para P; y 0,216 meq/100 ml para K. A la par, el laboratorio reportó 31,0 ppm, 34,0 ppm y 0,21 meq/100 ml, respectivamente. Los errores relativos fueron 5,5 % para N, -3,2 % para P y 2,9 % para K. Los resultados muestran una alta concordancia promedio entre el sistema propuesto y el análisis convencional, evidenciando su potencial como herramienta de monitoreo preliminar para la gestión nutricional en el cultivo de café.

Palabras clave:

*agrosensores, macronutrientes,
monitoreo de suelos, variabilidad
espacial, validación experimental.*

Introducción

La creciente demanda de alimentos y la necesidad de optimizar el uso de insumos agrícolas han impulsado el desarrollo de estrategias basadas en agricultura de precisión, orientadas a mejorar la eficiencia productiva y reducir el impacto ambiental. Este enfoque se fundamenta en la caracterización espacial y temporal de la variabilidad dentro de los sistemas agrícolas, permitiendo una gestión diferenciada del suelo y los cultivos (Nath, 2023). En este contexto, el monitoreo de nutrientes esenciales como nitrógeno (N), fósforo (P) y potasio (K) resulta determinante para la sostenibilidad y rentabilidad de los sistemas productivos.

La producción de café constituye uno de los sistemas agrícolas más relevantes a nivel mundial, tanto por su impacto económico como por su importancia social en países en desarrollo. Se estima que más de 25 millones de familias dependen directamente del cultivo de café, especialmente en regiones tropicales de América Latina, África y Asia (International Coffee Organization [ICO], 2022). En este contexto, la sostenibilidad de los sistemas cafetaleros depende en gran medida del manejo adecuado de la fertilidad del suelo, particularmente del equilibrio de los nutrientes esenciales de N, P y K, cuya disponibilidad influye directamente en el crecimiento vegetativo, la floración, el llenado del fruto y la calidad del grano (Eponon y otros, 2023).

El nitrógeno es un componente estructural fundamental de proteínas y clorofila, siendo determinante en el desarrollo foliar y en la capacidad fotosintética del cultivo. El fósforo participa en procesos energéticos y en el desarrollo radicular, mientras que el potasio regula funciones osmóticas, apertura estomática y resistencia al estrés hídrico (Eponon y otros, 2023). Deficiencias o excesos de estos nutrientes pueden afectar significativamente el rendimiento y la calidad del café, así como incrementar costos de producción y riesgos ambientales asociados a lixiviación o escorrentía de fertilizantes (Sadeghian, 2022).

El análisis convencional de fertilidad del suelo se realiza mediante métodos de laboratorio estandarizados que ofrecen alta confiabilidad analítica. Sin embargo, estos procedimientos suelen implicar costos elevados, tiempos prolongados de procesamiento y limitaciones logísticas en zonas rurales. Estas restricciones dificultan la obtención de información oportuna y con suficiente resolución espacial para una adecuada toma de decisiones agronómicas. Aunque los sensores de suelo y las tecnologías de medición in situ han emergido como alternativas prometedoras, su implementación en sistemas productivos reales, especialmente en cultivos de café en regiones andinas, sigue siendo limitada (Riaño & Barrero Sánchez, 2023).

En este contexto, si bien diversos estudios han desarrollado dispositivos portátiles basados

en sensores para la estimación de propiedades del suelo, existe aún una brecha en cuanto a la validación de estos sistemas en condiciones específicas de campo y su capacidad para estimar con precisión concentraciones de NPK en cultivos cafetaleros. Esta limitación restringe su adopción como herramientas confiables para la gestión nutricional en agricultura de precisión, particularmente en entornos con alta variabilidad edáfica como los presentes en la provincia de Loja (Ecuador).

Por lo tanto, el problema de investigación radica en la falta de sistemas portátiles validados que permitan medir de manera rápida, confiable e *in situ* los niveles de N, P y K en suelos de cultivos de café, facilitando la toma de decisiones agronómicas basadas en información oportuna y espacialmente representativa. En este escenario, el desarrollo de soluciones tecnológicas accesibles adquiere especial relevancia, ya que puede contribuir a mejorar la eficiencia en el uso de fertilizantes, reducir costos de producción y minimizar impactos ambientales asociados al manejo inadecuado de nutrientes.

Bajo este marco, el presente estudio propone el desarrollo de un sistema portátil basado en sensores para la medición de nutrientes NPK, utilizando un microcontrolador y comunicación RS-485, aplicado en un cultivo de café en Loja, Ecuador. A partir de mediciones realizadas en distintos puntos de un lote productivo y su contraste con los resultados de laboratorio obtenidos mediante métodos convencionales, se evalúa el desempeño del dispositivo y su potencial como herramienta de apoyo para la gestión nutricional en agricultura de precisión.

Métodos

Tipo de estudio

El estudio desarrollado se centró netamente en una validación inicial del sistema portátil de monitoreo NPK, que se comparó con una muestra de laboratorio en una zona de cultivo de café para evaluar su precisión y respuesta mediante análisis estadístico.

Área de estudio

El estudio se desarrolló en un cultivo de café ubicado en la ciudad de Loja, Ecuador, a una altitud aproximada de 2 100 m s. n. m. La zona se caracteriza por condiciones agroecológicas andinas con variabilidad topográfica y suelos de origen volcánico, factores que influyen en la disponibilidad y dinámica de nutrientes (Food and Agriculture Organization of the United Nations [FAO], 2015). El lote evaluado posee una extensión aproximada de tres hectáreas, donde se seleccionaron diez puntos de muestreo distribuidos espacialmente para capturar la heterogeneidad interna del terreno.

Diseño experimental y variables de estudio

El estudio se desarrolló bajo un enfoque experimental de tipo aplicado, orientado a la validación preliminar de un sistema portátil de monitoreo de nutrientes (N, P, K) en condiciones reales de campo. El diseño experimental se estructuró

como un muestreo puntual distribuido espacialmente dentro de un lote productivo, con el objetivo de evaluar el desempeño del sensor y su capacidad para detectar variabilidad intraparcela.

Variables de estudio

Se definieron como variables principales:

Variables dependientes:

- Concentración de nitrógeno (N) en ppm
- Concentración de fósforo (P) en ppm
- Concentración de potasio (K) en meq/100 ml

Variable independiente:

- Método de medición (sensor portátil vs. análisis de laboratorio)

Variables de control (no manipuladas):

- Profundidad de medición (0-20 cm)
- Tipo de suelo (suelo volcánico andino)
- Condiciones de campo al momento de la medición (no controladas experimentalmente)
- Posible humedad del suelo (no cuantificada)

Sistema de monitoreo NPK

Se diseñó e implementó un sistema portátil de adquisición de datos basado en un microcontrolador Arduino UNO (ATmega328P, 16 MHz). El dispositivo fue integrado con un sensor comercial de suelo capaz de estimar concentraciones de nitrógeno (N), fósforo (P) y potasio (K) en un rango de 0-1 999 mg/kg, utilizando comunicación RS-485 bajo protocolo Modbus RTU. La interfaz eléctrica se realizó mediante un módulo transceptor MAX485 en configuración *half-duplex*, permi-

tiendo la conversión de señal diferencial a niveles TTL compatibles con el microcontrolador.

La arquitectura embebida incluyó además un módulo de visualización LCD para mostrar lecturas en tiempo real. La adquisición de datos se efectuó a 9 600 bps, promediando diez lecturas consecutivas por punto, con el fin de reducir ruido eléctrico y variabilidad instantánea, práctica común en sistemas de censado embebido (Monk, 2016). El sistema fue alimentado mediante una fuente regulada de 5 V DC y este se muestra en la Figura 1.




Figura 1

Diagrama del sistema

El sensor empleado estima los nutrientes de forma indirecta a partir de propiedades eléctricas del suelo y modelos internos de calibración del fabricante, lo que hace necesaria su evaluación comparativa frente a métodos de referencia (Viscarra Rossel y otros, 2011).

Procedimiento de muestreo en campo

Las mediciones in situ se realizaron introduciendo la sonda del sensor a una profundidad aproximada de 0 a 20 cm, correspondiente a la zona activa de absorción radicular en cultivos de café. En cada uno de los diez puntos seleccionados se registraron valores de N, P y K, generando un conjunto de datos representativo de la variabilidad espacial del lote. El esquema de medición se muestra en la Figura 2.




Figura 2

Esquema de medición

Posteriormente, se recolectaron submuestras de suelo en los mismos puntos evaluados, las cuales fueron homogeneizadas para conformar una muestra compuesta representativa del área total. Este procedimiento es común cuando se busca obtener una caracterización promedio

del lote, reduciendo costos analíticos de laboratorio (Havlin y otros, 2014). A continuación, en las tablas 1 y 2 se muestran tanto los datos de los diez puntos como los datos de la muestra de laboratorio.

Tabla 1
Datos del sensor NPK

Número de muestra (sensor)	Nitrógeno (N) (ppm)	Fósforo (P) (ppm)	Potasio (K) (meq/100ml)
1	38,4	19,0	0,33
2	30,7	33,6	0,30
3	28,9	39,1	0,28
4	35,4	21,8	0,21
5	27,0	23,3	0,15
6	25,2	33,6	0,22
7	31,8	45,0	0,20
8	40,7	31,1	0,11
9	36,7	44,4	0,18
10	32,3	38,3	0,18

Tabla 2
Datos del análisis de laboratorio

Número de muestra (laboratorio)	Nitrógeno (N) (ppm)	Fósforo (P) (ppm)	Potasio (K) (meq/100ml)
1	31,0	34,0	0,21

Análisis de laboratorio

La muestra compuesta fue sometida a análisis de fertilidad mediante métodos estandarizados. El nitrógeno fue determinado por digestión y cuantificación según el método Kjeldahl; el fósforo se determinó mediante extracción química y lectura espectrofotométrica; y el potasio fue cuantificado mediante fotometría de llama, expresándose los resultados en ppm para N y P, y en meq/100 ml para K, conforme a procedimientos agronómicos convencionales (Jones, 2001).

Análisis comparativo

Dado que el laboratorio proporcionó un valor único representativo del lote (muestra compuesta), la comparación se realizó entre el valor promedio de las diez mediciones del sensor y el valor reportado por el laboratorio. Se calculó el error relativo porcentual para cada nutriente, de acuerdo con la expresión

$$Error(\%) = \frac{Valor_{sensor} - Valor_{laboratorio}}{Valor_{laboratorio}} * 100$$

Asimismo, se evaluó la variabilidad interna del sensor mediante el rango y análisis descriptivo de los datos obtenidos en el sitio, con el fin de examinar su capacidad para detectar heterogeneidad espacial dentro del lote productivo. Este enfoque metodológico corresponde a una validación preliminar bajo condiciones reales de campo, orientada a analizar la concordancia promedio del sistema embebido frente al método convencional de referencia (Bland & Altman, 1986).

Resultados

Comportamiento descriptivo de las mediciones del sistema portátil

Las mediciones realizadas con el sistema portátil de monitoreo NPK en los diez puntos distribuidos dentro del lote de aproximadamente tres hectáreas evidenciaron una variabilidad espacial

apreciable en las concentraciones de nitrógeno (N), fósforo (P) y potasio (K). Estos valores se muestran en la Tabla 3.

Tabla 3
Comportamiento estadístico de los datos del sistema portátil

Variables	Rango	Media	Desviación estándar	Coefficiente de variación (CV%)	Tipo de variabilidad
Nitrógeno (N)	25,2 – 40,7 ppm	32,71	5,06	15,47	Moderada
Fósforo (P)	19,0 – 45,0 ppm	32,92	8,69	26,41	Alta
Potasio (K)	0,11 – 0,33 meq/100 ml	0,22	0,07	31,94	Alta

Estos resultados confirman la presencia de heterogeneidad intraparcela, característica común en sistemas agrícolas andinos, donde factores como la topografía, el manejo agronómico y la

distribución de materia orgánica influyen significativamente en la dinámica de nutrientes del suelo (Gebbers & Adamchuk, 2010).

Comparación con análisis de laboratorio

El análisis de laboratorio de la muestra compuesta reportó concentraciones de 31,0 ppm para N, 34,0 ppm para P y 0,21 meq/100 ml para K. Al comparar los valores promedio obtenidos por

el sistema portátil con los resultados del laboratorio, se determinaron los errores relativos que se muestran en la Tabla 4.

Tabla 4
Error relativo

Variables	Error relativo (%)
Nitrógeno (N)	5,5
Fósforo (P)	-3,2
Potasio (K)	2,9

Las diferencias observadas fueron inferiores al 6 % en todos los casos, lo que indica una alta concordancia promedio entre el sistema propuesto y el método convencional de referencia. En términos prácticos, estos niveles de desviación pueden considerarse aceptables para aplicacio-

nes preliminares de diagnóstico nutricional en el sitio, especialmente cuando el objetivo es identificar tendencias generales o variabilidad espacial más que reemplazar completamente el análisis de laboratorio (Adamchuk y otros, 2004).

Variabilidad interna del lote

El análisis descriptivo de las mediciones del sensor permitió identificar diferencias notables entre puntos dentro del mismo terreno. El fósforo mostró la mayor amplitud de variación (26 ppm de diferencia entre valores mínimo y máximo), seguido del nitrógeno y el potasio.

Esta capacidad del sistema para detectar diferencias espaciales resulta relevante desde la perspectiva de la agricultura de precisión, donde la gestión diferenciada de fertilización depende de la identificación de zonas con distinta disponibilidad de nutrientes (Gebbers & Adamchuk, 2010). La obtención de datos *in situ* en tiempo real facilita la generación de mapas de variabilidad y la toma de decisiones sitio-específicas.

Limitaciones

Es importante señalar que el análisis realizado se basa en una comparación entre el promedio de las mediciones del sensor y un único valor de referencia de laboratorio, lo que limita la posibilidad de aplicar métodos estadísticos inferenciales como correlación o regresión. En este sentido, los resultados deben interpretarse como una validación inicial o preliminar del sistema.

Se recomienda que futuros estudios incluyan un mayor número de muestras de laboratorio y un mayor número de mediciones del terreno, lo que permitiría realizar análisis de regresión, cálculo de error cuadrático medio (RMSE) y evaluación de concordancia mediante metodologías más robustas.

El tamaño muestral de 10 puntos se justifica por tratarse de una validación inicial del sistema, donde el objetivo principal es evaluar su desempeño funcional en condiciones reales. La selección de puntos distribuidos espacialmente en un terreno de tres hectáreas permite capturar la variabilidad intraparcela, mientras que el uso de valores promedio reduce la necesidad de grandes tamaños muestrales. Además, se consideraron restricciones operativas propias del muestreo en el campo y del análisis de laboratorio.

Lo que se busca con el estudio de validación preliminar es verificar el funcionamiento del sistema portátil, identificar tendencias y estimar errores iniciales. Además, los 10 puntos permiten una cobertura básica de la variabilidad espacial del terreno, suficiente para una caracterización exploratoria del comportamiento del sensor.

Síntesis de resultados

En conjunto, los resultados obtenidos evidencian que el sistema portátil de monitoreo NPK presenta una adecuada concordancia promedio con el análisis convencional de laboratorio, con errores relativos inferiores al 6 % para nitrógeno, fósforo y potasio. Esta proximidad entre valores sugiere que el dispositivo es capaz de estimar de manera confiable el nivel nutricional promedio del suelo en condiciones reales del terreno, lo que respalda su viabilidad como herramienta de diagnóstico preliminar.

Desde una perspectiva práctica, estos resultados indican que el sistema puede emplearse como una alternativa operativa para la evaluación rápida del estado nutricional del suelo, especialmente en contextos donde los análisis de laboratorio resultan limitados por factores económicos, logísticos o de tiempo. En este sentido, el dispositivo permite generar información oportuna que puede apoyar la toma de decisiones agronómicas, tales como la identificación de posibles deficiencias o excesos de nutrientes, la priorización de zonas de intervención y el seguimiento de tendencias nutricionales a lo largo del tiempo.

Un aspecto relevante del estudio es la capacidad del sistema para detectar variabilidad espacial dentro del lote evaluado. Las diferencias observadas entre los puntos de muestreo, particularmente en el caso del fósforo y el potasio, evidencian la presencia de heterogeneidad intraparcela, condición característica de sistemas agrícolas en entornos andinos. En términos agronómicos, esta variabilidad implica que prácticas de

fertilización homogénea pueden resultar ineficientes, generando desequilibrios en la disponibilidad de nutrientes. En este contexto, el sistema portátil ofrece una ventaja significativa al permitir identificar zonas con distinto comportamiento nutricional, contribuyendo potencialmente a la implementación de estrategias de fertilización diferenciada y al uso más eficiente de insumos.

Asimismo, el hecho de que los valores reportados por el laboratorio se encuentren dentro del rango de variación de las mediciones del sensor refuerza la capacidad del sistema para representar adecuadamente el comportamiento global del suelo. Este resultado sugiere que el dispositivo no solo proporciona estimaciones promedio consistentes, sino que también captura la dinámica espacial de los nutrientes en el terreno, lo cual es fundamental en aplicaciones de agricultura de precisión.

No obstante, es importante señalar que el alcance de estos resultados se enmarca en una validación preliminar del sistema. La comparación realizada entre el promedio de las mediciones del sensor y un único valor de referencia de laboratorio, obtenido a partir de una muestra compuesta, limita la posibilidad de evaluar la precisión

individual de las mediciones y de aplicar análisis estadísticos inferenciales más robustos. En consecuencia, los resultados no permiten establecer relaciones cuantitativas detalladas entre ambos métodos ni generalizar el desempeño del sensor a otras condiciones edáficas o productivas.

En este sentido, el sistema debe ser considerado, en esta etapa, como una herramienta complementaria para el monitoreo nutricional en campo y no como un sustituto del análisis químico convencional. Su principal valor radica en la posibilidad de realizar mediciones rápidas, frecuentes y de bajo costo, facilitando la obtención de información preliminar que puede orientar la toma de decisiones y optimizar la gestión de la fertilización.

Finalmente, los hallazgos obtenidos evidencian el potencial del sistema para su integración en esquemas de agricultura de precisión, particularmente si se complementa con herramientas de georreferenciación y análisis espacial. Futuras investigaciones que incorporen un mayor número de muestras, validaciones punto a punto y modelos de calibración específicos permitirán ampliar el alcance del dispositivo y consolidar su aplicabilidad en contextos productivos reales.

Discusión

Los resultados obtenidos en este estudio evidencian que el sistema portátil de monitoreo NPK desarrollado presenta una concordancia promedio elevada frente al análisis convencional de laboratorio, con errores relativos inferiores al 6 % para nitrógeno, fósforo y potasio. Esta magnitud de desviación se encuentra dentro de rangos considerados aceptables para herramientas de diagnóstico preliminar en agricultura de precisión, especialmente cuando el propósito principal es la identificación de tendencias espaciales más que la sustitución absoluta del análisis químico de referencia (McBratney y otros, 2005; Naderi-Boldaji y otros, 2013).

Comparativa con trabajos previos

Diversos estudios han reportado que los sensores comerciales de nutrientes basados en propiedades eléctricas del suelo pueden presentar errores variables dependiendo de condiciones edáficas y ambientales. La estimación indirecta de NPK suele estar influenciada por la conductividad eléctrica, contenido de humedad y composición mineralógica del suelo (Viscarra Rossel y otros, 2011; Muñoz-Huerta y otros, 2013). En investigaciones realizadas en sistemas agrícolas templados, se han observado errores que pueden superar el 15 % cuando no se aplican calibraciones locales específicas (Shaviv, 2001).

En comparación con dichos reportes, los errores promedio obtenidos en el presente estudio resultan relativamente bajos. Esta concordancia puede atribuirse a varios factores:

- Homogeneidad relativa del lote evaluado.
- Uso de promediado de lecturas para reducir ruido.
- Comparación frente a muestra compuesta, lo que suaviza variaciones puntuales.

Sin embargo, es importante reconocer que la comparación promedio puede subestimar discrepancias locales que solo podrían identificarse mediante análisis pareados individuales. La literatura recomienda que la validación robusta de sensores incluya análisis punto a punto y aplicación de métricas como RMSE, coeficiente de determinación (R^2) y análisis de concordancia de Bland–Altman (Bland & Altman, 1986; Giavarina, 2015). En este sentido, el presente trabajo sienta las bases para investigaciones posteriores de mayor profundidad estadística.

Condiciones ambientales

Un aspecto crítico que debe considerarse en la interpretación de los resultados es el efecto de las condiciones ambientales sobre la respuesta del sensor. Estudios previos han demostrado que variables como la humedad del suelo, la conductividad eléctrica y la temperatura influyen directamente en las mediciones de sensores basados en propiedades eléctricas (Viscarra Rossel y otros, 2011; Muñoz-Huerta y otros, 2013). En particular, la presencia de humedad, ya sea por condiciones naturales del suelo o por eventos recientes de lluvia, puede alterar la conductividad eléctrica y, en consecuencia, afectar la estimación indirecta de nutrientes.

En el presente estudio no se controlaron ni registraron de manera sistemática estas variables, lo que introduce una fuente potencial de incertidumbre. Por ejemplo, un aumento en la humedad del suelo podría generar una sobreestimación o subestimación de los nutrientes dependiendo de las condiciones específicas del medio, lo cual debe ser considerado al interpretar los resultados.

Asimismo, la realización de mediciones en un único momento temporal limita la capacidad de evaluar la estabilidad del sistema frente a variaciones climáticas. La posible ocurrencia de lluvias previas al muestreo, no documentadas en el estudio, podría haber influido en la distribución y disponibilidad de nutrientes, así como en la respuesta del sensor. En este sentido, la ausencia de control sobre estas variables reduce la posibilidad de generalizar los resultados a otras condiciones ambientales o épocas del año.

Tamaño muestral

Otra limitación relevante es el tamaño muestral y el uso de una única muestra de laboratorio como referencia. Si bien este enfoque es aceptable en estudios de validación preliminar, limita la aplicación de análisis estadísticos inferenciales y la evaluación de concordancia punto a punto. Como consecuencia, los resultados deben interpretarse como una aproximación inicial al desempeño del sistema, más que como una validación definitiva. La literatura recomienda que la validación de sensores incluya un mayor número de muestras independientes y análisis estadísticos robustos para garantizar la confiabilidad de los resultados (Bland & Altman, 1986; Giavarina, 2015).

Variabilidad espacial y su relevancia agronómica

La variabilidad intraparcela observada en los resultados coincide con hallazgos ampliamente documentados en agricultura de precisión, donde incluso en parcelas de tamaño moderado pueden existir diferencias significativas en disponibilidad de nutrientes (McBratney y otros, 2005; Gebbers & Adamchuk, 2010). En cultivos de café establecidos en terrenos andinos con pendiente variable, la redistribución natural de nutrientes por escorrentía y procesos erosivos puede generar patrones heterogéneos de fertilidad.

El fósforo mostró la mayor amplitud de variación entre los nutrientes evaluados. Este comportamiento es consistente con su baja movilidad en el suelo y su tendencia a formar complejos insolubles en ambientes ácidos o con alto contenido de óxidos de hierro y aluminio, características comunes en suelos volcánicos andinos (Havlin y otros, 2014). La detección de esta variabilidad mediante el sistema portátil sugiere que la herramienta podría ser útil para delimitar zonas específicas que requieran ajustes diferenciados de fertilización fosfatada.

En el caso del nitrógeno, la variabilidad observada podría estar asociada a diferencias en mineralización de materia orgánica, historia de fertilización o variaciones microambientales en humedad. El potasio, por su parte, presentó menor rango absoluto, aunque suficiente para evidenciar diferencias agronómicamente relevantes.

Implicaciones para la sostenibilidad y eficiencia en el uso de fertilizantes

El uso excesivo o ineficiente de fertilizantes nitrogenados y fosfatados ha sido identificado como una de las principales fuentes de contaminación ambiental en sistemas agrícolas intensivos, debido a procesos de lixiviación y escorrentía que pueden afectar cuerpos de agua superficiales y subterráneos (Tilman y otros, 2002). En este contexto, la implementación de herramientas que permitan monitoreo más frecuente y localizado de nutrientes podría contribuir a reducir aplicaciones innecesarias y mejorar la eficiencia del uso de insumos.

Desde el punto de vista económico, la posibilidad de realizar mediciones *in situ* sin recurrir constantemente a análisis de laboratorio distantes, demorados y costosos puede representar una ventaja significativa para productores de pequeña y mediana escala. Aunque el análisis químico continúa siendo el estándar de referencia, su costo puede limitar la frecuencia de monitoreo. Un sistema portátil de bajo costo puede complementar dichos análisis, permitiendo evaluaciones intermedias entre campañas de laboratorio.

Comparativa con sensores comerciales

En relación con sensores comerciales disponibles, diversos estudios han destacado que los dispositivos basados en tecnologías de sensado proximal pueden ofrecer mediciones rápidas y no destructivas, aunque con limitaciones en precisión dependiendo de las condiciones de uso (Riaño & Barrero Sánchez, 2023; Viscarra Rossel y otros,

2011). En comparación, el sistema propuesto en este estudio presenta varias ventajas relevantes.

En primer lugar, su bajo costo de implementación, basado en plataformas de hardware abierto como Arduino, lo convierte en una alternativa accesible para pequeños y medianos productores, a diferencia de sensores comerciales de alto costo. En segundo lugar, la capacidad de obtener mediciones en tiempo real directamente en el terreno representa una ventaja significativa frente a los análisis de laboratorio, que requieren mayor tiempo y recursos logísticos. Finalmente, los niveles de error observados sugieren que, bajo condiciones controladas, el sistema puede ofrecer una precisión comparable a la de dispositivos comerciales de gama media, al menos en términos de estimación promedio.

No obstante, es importante reconocer que los sensores comerciales avanzados suelen incorporar calibraciones específicas, compensación por variables ambientales y algoritmos de procesamiento más sofisticados, lo que puede mejorar su desempeño en condiciones fluctuantes. En este contexto, el sistema propuesto aún requiere procesos de calibración local y validación extendida para alcanzar niveles de robustez equivalentes.

Robustez tecnológica del sistema embebido

El desempeño estable del sistema durante las mediciones de campo indica que la arquitectura basada en Arduino y comunicación RS-485 resultó adecuada para entornos agrícolas. La transmisión diferencial RS-485 ofrece ventajas frente a interfaces analógicas simples, al reducir susceptibilidad a interferencias eléctricas (Modbus

Organization, 2012). La implementación del protocolo Modbus RTU permitió una lectura confiable de registros del sensor, sin evidencia de pérdidas de datos o inconsistencias durante la adquisición.

La modularidad del diseño facilita futuras mejoras, tales como:

- Incorporación de almacenamiento en tarjeta SD.
- Integración con módulos de comunicación inalámbrica (LoRa, WiFi).
- Georreferenciación mediante GPS.
- Integración con plataformas de análisis en la nube.

Estas posibilidades alinean el sistema con tendencias actuales de agricultura digital y agricultura 4.0, donde la interconectividad y el análisis de datos juegan un papel central (Zhang y otros, 2002).Proyección futura

Proyección futura y aplicabilidad

La ampliación del estudio hacia diseños experimentales más robustos permitiría desarrollar modelos de calibración específicos para suelos andinos de la región sur del Ecuador. Asimismo, la integración del sistema con herramientas de mapeo espacial podría facilitar la construcción de mapas de fertilidad intraparcels, apoyando decisiones de fertilización diferenciada. El desarrollo continuo de soluciones tecnológicas locales, adaptadas a contextos productivos específicos, puede contribuir a reducir brechas tecnológicas en regiones donde la adopción de la agricultura de precisión aún es limitada.

En términos de aplicabilidad, los resultados coinciden con la literatura en señalar que los sensores portátiles deben considerarse como herramientas complementarias al análisis de laboratorio, más que como sustitutos (Naderi-Boldaji y otros, 2013). Su principal valor radica en la posibilidad de realizar monitoreos frecuentes, identificar tendencias y apoyar la toma de decisiones en campo de manera oportuna. En particular, en sistemas cafetaleros como los evaluados en este estudio, donde la variabilidad espacial y las limitaciones de acceso a servicios de laboratorio son factores relevantes, el uso de este tipo de tecnologías puede contribuir a mejorar la eficiencia en la gestión de nutrientes y reducir el uso innecesario de fertilizantes.

Finalmente, el presente estudio debe entenderse como una validación preliminar del sistema bajo condiciones reales de operación. Futuras investigaciones deberán incorporar un mayor número de muestras, validaciones punto a punto, registro de variables ambientales y modelos de calibración específicos para condiciones edáficas locales. Asimismo, la integración del sistema con herramientas de georreferenciación y análisis espacial permitirá ampliar su alcance hacia aplicaciones más avanzadas en agricultura de precisión, como la generación de mapas de fertilidad y la implementación de estrategias de manejo sitio-específicas (McBratney y otros, 2005; Zhang y otros, 2002).

Conclusiones

El desarrollo e implementación de un sistema portátil de monitoreo de nutrientes NPK basado en un microcontrolador Arduino y comunicación RS-485 demostró viabilidad técnica y operativa bajo condiciones reales de campo en un cultivo de café ubicado en Loja, Ecuador. La arquitectura embebida diseñada permitió la adquisición estable de datos, procesamiento mediante promediado de lecturas y visualización en tiempo real, evidenciando un desempeño adecuado del conjunto microcontrolador-sensor en entornos agrícolas.

Los resultados obtenidos mostraron una alta concordancia promedio entre las mediciones del sistema portátil y el análisis convencional de laboratorio, con errores relativos inferiores al 6 % para nitrógeno, fósforo y potasio. Aunque la comparación se realizó frente a una muestra compuesta representativa del lote, la proximidad entre valores sugiere que el dispositivo puede constituir una herramienta preliminar confiable para el monitoreo nutricional en el campo. Esta concordancia es particularmente relevante considerando que el sensor empleado realiza estimaciones indirectas basadas en propiedades eléctricas del suelo.

La variabilidad intraparcela detectada en las mediciones confirma la presencia de heterogeneidad nutricional dentro del lote evaluado, fenómeno característico de sistemas agrícolas andinos con topografía variable. La capacidad del sistema para identificar diferencias espaciales en la disponibilidad de nutrientes refuerza su potencial aplicación

en esquemas de agricultura de precisión orientados a la gestión diferenciada de fertilización.

Desde una perspectiva tecnológica, la modularidad del sistema permite su escalabilidad e integración futura con herramientas de georreferenciación, almacenamiento de datos y transmisión inalámbrica, facilitando su incorporación en plataformas de agricultura digital. Asimismo, el uso de componentes de bajo costo amplía las posibilidades de adopción por parte de productores de pequeña y mediana escala, contribuyendo a reducir brechas tecnológicas en regiones cafetaleras.

No obstante, es importante reconocer que el carácter preliminar del estudio, el tamaño muestral limitado y el uso de muestra compuesta de laboratorio restringen el alcance estadístico de las conclusiones. Se recomienda, en futuras investigaciones, realizar validaciones con muestras pareadas individuales, incrementar el número de puntos de medición e incorporar métricas estadísticas robustas que permitan evaluar concordancia punto a punto y desarrollar modelos de calibración específicos para condiciones edáficas locales.

En síntesis, el sistema portátil propuesto representa una alternativa tecnológica prometedora para el monitoreo preliminar de nutrientes en cultivos de café, con potencial para fortalecer estrategias de fertilización más eficientes, sostenibles y adaptadas a la variabilidad espacial del suelo.

Declaración de conflictos de interés

Quienes firman este artículo declaran no tener conflictos de interés.

Fuentes de financiación

El presente trabajo fue desarrollado en el marco del proyecto 41-DI-FEIRNR-2025 denominado: Desarrollo de prototipos tecnológicos para

monitoreo y caracterización de cultivos de café. Financiado por la Universidad Nacional de Loja.

Declaración de uso de inteligencia artificial

Durante la preparación de este manuscrito, se utilizó la herramienta ChatGPT (OpenAI, modelo GPT-5.3) con el propósito de apoyar en la mejora de la redacción, claridad del lenguaje académico y organización estructural del contenido. El uso de esta herramienta se limitó exclu-

sivamente a tareas de asistencia en la escritura y edición del texto.

Los autores revisaron críticamente todo el contenido generado, realizaron las modificaciones necesarias y asumen plena responsabilidad por la integridad, exactitud y originalidad del manuscrito.

Declaración de contribución de autoría (CRedit)

Franklin Gustavo Jiménez Peralta: Conceptualización; metodología; validación; análisis formal; investigación; gestión de datos; administración del proyecto.

Marianela del Cisne Carrión González: Conceptualización; metodología; validación; investigación; redacción - borrador original; redacción - revisión y edición; supervisión.

Referencias

- Adamchuk, V. I., Hummel, J. W., Morgan, M. T., & Upadhyaya, S. K. (2004). On-the-go soil sensors for precision agriculture. *Computers and Electronics in Agriculture*, 44(1), 71–91.
<https://doi.org/10.1016/j.compag.2004.03.002>
- Bland, J. M., & Altman, D. G. (1986). Statistical methods for assessing agreement between two methods of clinical measurement. *The Lancet*, 327(8476), 307–310.
[https://doi.org/10.1016/S0140-6736\(86\)90837-8](https://doi.org/10.1016/S0140-6736(86)90837-8)
- Eponon, E. C., Kassi, K., Kouame, K. D., Snoeck, D., Ouattara, T., Camara, M., Chérif, M., & Koné, D. (2023). The soil diagnostic method to formulate fertilizer requirements for coffee trees in côte d'Ivoire. *Archives of Current Research International*, 23(4), 51–59.
<https://doi.org/10.9734/acri/2023/v23i4569>
- Food and Agriculture Organization of the United Nations [FAO]. (2015). Status of the world's soil resources (SWSR): *Main report*. Food and Agriculture Organization of the United Nations.
- Gebbers, R., & Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828–831.
<https://doi.org/10.1126/science.1183899>
- Giavarina, D. (2015). Understanding Bland–Altman analysis. *Biochemia Medica*, 25(2), 141–151.
<https://doi.org/10.11613/BM.2015.015>
- Havlin, J. L., Tisdale, S. L., Nelson, W. L., & Beaton, J. D. (2014). *Soil fertility and fertilizers: An introduction to nutrient management* (8th ed.). Pearson.
- International Coffee Organization [ICO]. (2022). *Coffee development report 2022*.
- Jones, J. B. (2001). *Laboratory guide for conducting soil tests and plant analysis*. CRC Press.
- McBratney, A., Whelan, B., Ancev, T., & Bouma, J. (2005). Future directions of precision agriculture. *Precision Agriculture*, 6(1), 7–23.
<https://doi.org/10.1007/s11119-005-0681-8>
- Modbus Organization. (2012). *Modbus application protocol specification V1. 1b3*.
<https://www.modbus.org/file/secure/modbusprotocolspecification.pdf>

- Monk, S. (2016). *Programming Arduino: Getting started with sketches* (2nd ed.). McGraw-Hill Education.
- Muñoz-Huerta, R. F., Guevara-Gonzalez, R. G., Contreras-Medina, L. M., Torres-Pacheco, I., Prado-Olivarez, J., & Ocampo-Velazquez, R. V. (2013). A review of methods for sensing the nitrogen status in plants: Advantages, disadvantages and recent advances. *Sensors*, 13(8), 10823–10843.
<https://doi.org/10.3390/s130810823>
- Naderi-Boldaji, M., Alimardani, R., & Sharifi, A. (2013). Design and development of a soil nutrient measurement system for precision agriculture. *Journal of Agricultural Science and Technology*, 15, 651–662.
- Nath, S. (2024). A vision of precision agriculture: Balance between agricultural sustainability and environmental stewardship. *Agronomy Journal*, 116(3), 1126–1143.
<https://doi.org/10.1002/agj2.21405>
- Pérez-Expósito, J. P., Fernández-Caramés, T. M., Fraga-Lamas, P., & Castedo, L. (2017). VineSens: An eco-smart decision-support viticulture system. *Sensors*, 17(3), 465.
<https://doi.org/10.3390/s17030465>
- Raun, W. R., Solie, J. B., Johnson, G. V., Stone, M. L., Lukina, E. V., Thomason, W. E., & Schempers, J. S. (2005). Optical sensor-based algorithm for crop nitrogen fertilization. *Agronomy Journal*, 97(3), 815–820.
<https://doi.org/10.2134/agronj2004.0271>
- Riaño, S., & Barrero Sánchez, F. H. (2023). Implementación de los nodos de una red inalámbrica de sensores aplicada en cultivos de café. Encuentro Internacional de Educación en Ingeniería.
<https://doi.org/10.26507/paper.3180>
- Sadeghian, S. (2022). Nutrición de cafetales: Fertilice con mayor eficiencia agronómica y económica. *Memorias Seminario Científico Cenicafé*, 71(1), e71138.
<https://doi.org/10.38141/10795/71138>
- Shaviv, A. (2001). Advances in controlled-release fertilizers. *Advances in Agronomy*, 71, 1–49.
[https://doi.org/10.1016/S0065-2113\(01\)71011-5](https://doi.org/10.1016/S0065-2113(01)71011-5)
- Tilman, D., Cassman, K. G., Matson, P. A., Naylor, R., & Polasky, S. (2002). Agricultural sustainability and intensive production practices. *Nature*, 418, 671–677.
<https://doi.org/10.1038/nature01014>

Viscarra Rossel, R. A., McBratney, A. B., & Minasny, B. (2011). Proximal soil sensing. *Geoderma*, 162(1–2), 1–5.

<https://doi.org/10.1016/j.geoderma.2010.12.017>

Zhang, N., Wang, M., & Wang, N. (2002). Precision agriculture: A worldwide overview. *Computers and Electronics in Agriculture*, 36(2–3), 113–132.

[https://doi.org/10.1016/S0168-1699\(02\)00096-0](https://doi.org/10.1016/S0168-1699(02)00096-0)

Portable sensor system for measuring

NPK nutrients in coffee crops, designed for precision agriculture in Loja, Ecuador

*Franklin Jiménez Peralta¹,
Marianela Carrión González²*

¹Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales no Renovables, Carrera de Ingeniería en Telecomunicaciones, Loja, Ecuador,
<https://orcid.org/0000-0002-4976-1017>
franklin.g.jimenez@unl.edu.ec

²Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales no Renovables, Carrera de Ingeniería en Telecomunicaciones, Loja, Ecuador,
<https://orcid.org/0000-0001-6164-8669>
marianela.carrion@unl.edu.ec

DOI: 10.61854/rccedia.v1n1.002

Sent: February 13, 2026

Approved: April 9, 2026

Published: Tuesday, July 14, 2026



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

Abstract

Timely monitoring of nutrients in agricultural soils is essential for optimizing fertilization and improving productivity in coffee crops under precision farming schemes. The aim of this study was to develop and preliminarily evaluate a portable monitoring system for nitrogen (N), phosphorus (P), and potassium (K) based on an Arduino microcontroller and a commercial sensor with RS-485 communication, applied to a coffee crop in Loja, Ecuador. Ten in situ measurements were taken on a plot of approximately three hectares, and the results were compared with a laboratory analysis obtained from a composite sample representative of the study area. The average values obtained by the system were 32.71 ppm for N, 32.92 ppm for P, and 0.216 meq/100 ml for K, while the laboratory reported 31.0 ppm, 34.0 ppm, and 0.21 meq/100 ml, respectively. The relative errors were 5.5% for N, -3.2% for P, and 2.9% for K. The results show a high average concordance between the proposed system and conventional analysis, demonstrating its potential as a preliminary monitoring tool for nutritional management in coffee.

Keywords:

agricultural sensors, macronutrients, soil monitoring, spatial variability, experimental validation.

Introduction

The growing demand for food and the need to optimize the use of agricultural inputs have driven the development of precision agriculture strategies aimed at improving production efficiency and reducing environmental impact. This approach is based on the spatial and temporal characterization of variability within agricultural systems, enabling site-specific management of soil and crops (Nath, 2023). In this context, monitoring essential nutrients such as nitrogen (N), phosphorus (P), and potassium (K) is critical for the sustainability and profitability of production systems.

Coffee production is one of the world's most important agricultural systems due to both its economic impact and its social importance in developing countries. It is estimated that more than 25 million families depend directly on coffee cultivation, particularly in tropical regions of Latin America, Africa, and Asia (International Coffee Organization [ICO], 2022). In this context, the sustainability of coffee production systems largely depends on the proper management of soil fertility, particularly the balance of the essential nutrients N, P, and K, whose availability directly influences vegetative growth, flowering, fruit filling, and bean quality (Eponon et al., 2023).

Nitrogen is a fundamental structural component of proteins and chlorophyll and plays a key role in leaf development and the photosynthetic capacity of the crop. Phosphorus is involved in energy-related processes and root development, whereas potassium regulates osmotic functions, stomatal opening, and resistance to water stress (Eponon et al., 2023). Deficiencies or excesses of these nutrients can significantly affect coffee yield and quality, as well as increase production costs and environmental risks associated with fertilizer leaching or runoff (Sadeghian, 2022).

Conventional soil fertility analysis is performed using standardized laboratory methods that provide high analytical reliability. However, these procedures often involve high costs, long processing times, and logistical constraints in rural areas. These limitations hinder the acquisition of timely information with sufficient spatial resolution for appropriate agronomic decision-making. Although soil sensors and in situ measurement technologies have emerged as promising alternatives, their implementation in real production systems, particularly in coffee crops in the Andean region, remains limited (Riaño & Barrero Sánchez, 2023).

In this context, although several studies have developed portable sensor-based devices for estimating soil properties, there is still a gap regarding the validation of these systems under specific field conditions and their ability to accurately estimate NPK concentrations in coffee crops. This limitation restricts their adoption as reliable tools for nutritional management in precision agriculture, particularly in environments with high soil variability such as those found in the province of Loja (Ecuador).

Therefore, the research problem lies in the lack of validated portable systems capable of rapidly, reliably, and in situ measuring N, P, and K levels in coffee-growing soils, thereby facilitating agronomic decision-making based on timely and spatially representative information. In this scenario, the development of accessible technological solutions becomes particularly relevant, as it can contribute to improving fertilizer use efficiency, re-

ducing production costs, and minimizing environmental impacts associated with improper nutrient management. Within this framework, the present study proposes the development of a portable sensor-based system for measuring NPK nutrients using a microcontroller and RS-485 communication, applied to a coffee crop in Loja, Ecuador. Based on measurements collected at different points within a production plot and their comparison with laboratory results obtained using conventional methods, the performance of the device and its potential as a support tool for nutritional management in precision agriculture are evaluated.

Methods

Study type

The study focused exclusively on the initial validation of the portable NPK monitoring system, which was compared with a laboratory sample collected from a coffee-growing area to evaluate its accuracy and response through statistical analysis.

Study area

The study was conducted in a coffee plantation located in the city of Loja, Ecuador, at an approximate altitude of 2,100 m above sea level. The area is characterized by Andean agroecological conditions with topographic variability and volcanic soils, factors that influence nutrient availability and dynamics (Food and Agriculture Organization of the United Nations [FAO], 2015). The evaluated plot covers approximately three hectares, where ten sampling points were spatially distributed to capture the internal heterogeneity of the terrain.

Experimental design and study variables

The study was conducted under an applied experimental approach aimed at the preliminary validation of a portable nutrient (N, P, K) monitoring system under real field conditions. The experimental design consisted of a spatially distributed point sampling within a production plot to evaluate

the sensor's performance and its ability to detect within-plot variability.

Study variables

The following variables were defined:

Dependent variables:

- CNitrogen (N) concentration in ppm
- Phosphorus (P) concentration in ppm
- Potassium (K) concentration in meq/100 ml

Independent variable:

- Measurement method (portable sensor vs. laboratory analysis)

Control variables (not manipulated):

- Measurement depth (0–20 cm)
- Soil type (Andean volcanic soil)
- Field conditions at the time of measurement (not experimentally controlled)
- Possible soil moisture (not quantified)

NPK Monitoring System

A portable data acquisition system based on an Arduino UNO microcontroller (ATmega328P, 16 MHz) was designed and implemented. The device was integrated with a commercial soil sensor

capable of estimating nitrogen (N), phosphorus (P), and potassium (K) concentrations within a range of 0–1,999 mg/kg using RS-485 communication under the Modbus RTU protocol. The electrical interface was implemented through a MAX485 transceiver module configured in half-duplex mode, enabling the conversion of differential signals into TTL levels compatible with the microcontroller.

The embedded architecture also included an LCD display module for real-time visualization of measurements. Data acquisition was performed at 9,600 bps by averaging ten consecutive readings per sampling point to reduce electrical noise and instantaneous variability, a common practice in embedded sensing systems (Monk, 2016). The system was powered by a regulated 5 V DC supply and is shown in Figure 1.




Figure 1

Diagram of the system

The sensor estimates nutrient concentrations indirectly from soil electrical properties and the manufacturer's internal calibration models, making comparative evaluation against reference methods necessary (Viscarra Rossel et al., 2011).

Field sampling procedure

In situ measurements were performed by inserting the sensor probe to an approximate depth of 0–20 cm, corresponding to the active root uptake zone of coffee crops. N, P, and K values were recorded at each of the ten selected sampling points, generating a dataset representative of the plot's spatial variability. The measurement scheme is shown in Figure 2.




Figure 2

Measurement scheme

Subsequently, soil subsamples were collected from the same sampling points and homogenized to produce a composite sample representative of the entire study area. This procedure is commonly used when the objective is

to obtain an average characterization of the plot while reducing laboratory analysis costs (Havlin et al., 2014). Tables 1 and 2 present the data collected from the ten sensor sampling points and the laboratory analysis results, respectively.

Table 1
NPK sensor data

Sensor sample number	Nitrogen (N) (ppm)	Phosphorus (P) (ppm)	Potassium (K) (meq/100 ml)
1	38,4	19,0	0,33
2	30,7	33,6	0,30
3	28,9	39,1	0,28
4	35,4	21,8	0,21
5	27,0	23,3	0,15
6	25,2	33,6	0,22
7	31,8	45,0	0,20
8	40,7	31,1	0,11
9	36,7	44,4	0,18
10	32,3	38,3	0,18

Table 2
Laboratory analysis data

Laboratory Sample Number	Nitrogen (N) (ppm)	Phosphorus (P) (ppm)	Potassium (K) (meq/100 ml)
1	31,0	34,0	0,21

Laboratory analysis

The composite sample was subjected to soil fertility analysis using standardized methods. Nitrogen was determined by digestion and quantification according to the Kjeldahl method; phosphorus was determined through chemical extraction followed by spectrophotometric measurement; and potassium was quantified using flame photometry. Results were expressed in ppm for N and P and in meq/100 ml for K, following conventional agronomic procedures (Jones, 2001).

Comparative analysis

Since the laboratory provided a single value representative of the entire plot (composite sample), the comparison was performed between the mean value of the ten sensor measurements and the laboratory-reported value. The relative percentage error was calculated for each nutrient according to the following expression:

$$Error(\%) = \frac{Valor_{sensor} - Valor_{laboratory}}{Valor_{laboratory}} * 100$$

In addition, the internal variability of the sensor was evaluated using the range and descriptive analysis of the field data to examine its ability to detect spatial heterogeneity within the production plot. This methodological approach corresponds to a preliminary validation under real field conditions aimed at analyzing the average agreement between the embedded system and the conventional reference method (Bland & Altman, 1986).

Results

Descriptive behavior of the portable system measurements

Measurements obtained with the portable NPK monitoring system at the ten sampling points distributed across the approximately three-hectare plot revealed appreciable spatial

variability in nitrogen (N), phosphorus (P), and potassium (K) concentrations. These values are presented in Table 3.

Table 3
Descriptive Statistics of the Portable System Data

Variables	Range	Mean	Standard Deviation	Coefficient of Variation (CV%)	Variability Level
Nitrogen (N)	25,2 – 40,7 ppm	32,71	5,06	15,47	Moderate
Phosphorus (P)	19,0 – 45,0 ppm	32,92	8,69	26,41	High
Potassium (K)	0,11 – 0,33 meq/100 ml	0,22	0,07	31,94	High

These results confirm the presence of within-field heterogeneity, a common characteristic of Andean agricultural systems, where factors such as topography, agronomic management,

and organic matter distribution significantly influence soil nutrient dynamics (Gebbers & Adamchuk, 2010).

Comparison with laboratory analysis

Laboratory analysis of the composite sample reported concentrations of 31.0 ppm for N, 34.0 ppm for P, and 0.21 meq/100 ml for K. By compa-

ring the average values obtained with the portable system against the laboratory results, the relative errors shown in Table 4 were calculated.

Table 4
Relative Error

Variables	Relative error (%)
Nitrogen (N)	5,5
Phosphorus (P)	-3,2
Potassium (K)	2,9

The observed differences were below 6% in all cases, indicating high average agreement between the proposed system and the conventional reference method. From a practical perspective, these levels of deviation can be considered accep-

table for preliminary on-site nutritional diagnostic applications, particularly when the objective is to identify general trends or spatial variability rather than to completely replace laboratory analysis (Adamchuk et al., 2004).

Within-field variability

The descriptive analysis of the sensor measurements identified notable differences among sampling points within the same field. Phosphorus exhibited the greatest variation, with a 26 ppm difference between the minimum and maximum values, followed by nitrogen and potassium.

The system's ability to detect spatial differences is particularly relevant from the perspective of precision agriculture, where site-specific fertilizer management depends on identifying areas with different nutrient availability (Gebbers & Adamchuk, 2010). Real-time, in situ data acquisition facilitates the generation of variability maps and supports site-specific decision-making.

Limitations

It is important to note that the analysis was based on a comparison between the average sensor measurements and a single laboratory reference value, limiting the application of inferential statistical methods such as correlation or regression analysis. Consequently, the findings should be interpreted as an initial or preliminary validation of the system. Future studies should include a larger number of laboratory samples and a greater number of field measurements, enabling regression analyses, root mean square error (RMSE) calculations, and agreement assessments using more robust methodologies.

The sample size of ten sampling points is justified because this study represents an initial system validation, whose primary objective was to evaluate functional performance under real field conditions. The selection of spatially distributed sampling points across a three-hectare field allowed the capture of within-field variability, while the use of average values reduced the need for large sample sizes. In addition, operational constraints associated with field sampling and laboratory analysis were taken into consideration.

The purpose of this preliminary validation study was to verify the operation of the portable system, identify trends, and estimate initial errors. Furthermore, the ten sampling points provided basic coverage of the field's spatial variability, which is sufficient for an exploratory characterization of sensor performance.

Summary of results

Overall, the results demonstrate that the portable NPK monitoring system exhibits good average agreement with conventional laboratory analysis, with relative errors below 6% for nitrogen, phosphorus, and potassium. This close correspondence suggests that the device can reliably estimate the average soil nutrient status under real field conditions, supporting its feasibility as a preliminary diagnostic tool.

From a practical standpoint, these findings indicate that the system can be used as an operational alternative for rapid soil nutritional assessment, particularly in situations where laboratory analyses are constrained by economic, logistical, or time-related factors. In this context, the device provides timely information that can support agronomic decision-making, including the identification of potential nutrient deficiencies or excesses, prioritization of intervention areas, and monitoring of nutritional trends over time.

A notable finding of this study is the system's ability to detect spatial variability within the evaluated field. The differences observed among sampling points, particularly for phosphorus and potassium, demonstrate the presence of within-field heterogeneity, a characteristic feature of agricultural systems in Andean environments. From an agronomic perspective, this variability implies that uniform fertilizer applications may be inefficient, leading to nutrient imbalances. In this context, the portable system offers a significant advantage by identifying areas with different nutritional behavior, thereby potentially supporting the implementation of site-specific fertilization strategies and more efficient input use.

Furthermore, the fact that the laboratory values fell within the range of variation measured by the sensor reinforces the system's ability to accurately represent the overall behavior of the soil. This finding suggests that the device not only provides consistent average estimates but also captures the spatial dynamics of soil nutrients, which is essential for precision agriculture applications.

Nevertheless, it is important to emphasize that these findings correspond to a preliminary validation of the system. The comparison between the average sensor measurements and a single laboratory reference value obtained from a composite sample limits the ability to evaluate the accuracy of individual measurements and to perform more robust inferential statistical analyses. Consequently, the results do not permit detailed quantitative relationships between the two methods nor the generalization of sensor performance to other soil or production conditions.

At this stage, the system should therefore be regarded as a complementary tool for in-field nutrient monitoring rather than a substitute for conventional chemical soil analysis. Its principal value lies in its ability to provide rapid, frequent, and low-cost measurements, facilitating the acquisition of preliminary information that can guide decision-making and optimize fertilizer management.

Finally, the findings highlight the system's potential for integration into precision agriculture frameworks, particularly when combined with georeferencing and spatial analysis tools. Future research incorporating a larger number of samples, point-by-point validation, and crop- or site-specific calibration models will broaden the applicability of the device and strengthen its use under real production conditions.

Discussion

The results obtained in this study demonstrate that the developed portable NPK monitoring system exhibits high average agreement with conventional laboratory analysis, with relative errors below 6% for nitrogen, phosphorus, and potassium. This level of deviation falls within the ranges considered acceptable for preliminary diagnostic tools in precision agriculture, particularly when the primary objective is the identification of spatial trends rather than the complete replacement of reference chemical analysis (McBratney et al., 2005; Naderi-Boldaji et al., 2013).

Comparison with previous studies

Several studies have reported that commercial nutrient sensors based on soil electrical properties may exhibit variable errors depending on soil and environmental conditions. The indirect estimation of NPK is generally influenced by electrical conductivity, soil moisture content, and soil mineralogical composition (Viscarra Rossel et al., 2011; Muñoz-Huerta et al., 2013). Studies conducted in temperate agricultural systems have reported errors exceeding 15% when site-specific calibrations are not applied (Shaviv, 2001).

Compared with these reports, the average errors obtained in the present study are relatively low. This agreement may be attributed to several factors:

- The relative homogeneity of the evaluated field.
- The use of averaged sensor readings to reduce measurement noise.
- Comparison against a composite soil sample, which smooths point-to-point variability.

However, it is important to acknowledge that average-based comparisons may underestimate local discrepancies that could only be identified through paired point-by-point analyses. The literature recommends that robust sensor validation should include point-by-point comparisons together with metrics such as root mean square error (RMSE), coefficient of determination (R^2), and Bland–Altman agreement analysis (Bland & Altman, 1986; Giavarina, 2015). In this regard, the present study provides the foundation for future investigations involving more comprehensive statistical validation.

Environmental conditions

An important aspect to consider when interpreting the results is the influence of environmental conditions on sensor performance. Previous studies have demonstrated that variables such as soil moisture, electrical conductivity, and temperature directly affect measurements obtained from sensors based on soil electrical properties (Viscarra Rossel et al., 2011; Muñoz-Huerta et al., 2013). In particular, soil moisture resulting from natural field conditions or recent rainfall events may alter electrical conductivity and consequently affect the indirect estimation of nutrient concentrations.

In the present study, these environmental variables were neither controlled nor systematically recorded, introducing a potential source of uncertainty. For example, increased soil moisture could lead to either overestimation or underestimation of nutrient concentrations depending on the specific field conditions, and this should be taken into account when interpreting the results.

Furthermore, measurements were performed at a single point in time, limiting the ability to evaluate system stability under varying climatic conditions. Undocumented rainfall events occurring before sampling may have influenced both nutrient distribution and sensor response. Consequently, the lack of control over these environmental variables reduces the generalizability of the findings to other environmental conditions or seasons.

Sample size

Another important limitation is the sample size and the use of a single laboratory sample as the reference. Although this approach is acceptable for a preliminary validation study, it limits the application of inferential statistical analyses and point-by-point agreement assessment. Therefore, the results should be interpreted as an initial evaluation of system performance rather than a definitive validation. The literature recommends that sensor validation should include a larger number of independent samples and more robust statistical analyses to ensure reliable conclusions (Bland & Altman, 1986; Giavarina, 2015).

Spatial variability and its agronomic relevance

The within-field variability observed in this study is consistent with findings widely reported in precision agriculture, where significant differences in nutrient availability may exist even within moderately sized fields (McBratney et al., 2005; Gebbers & Adamchuk, 2010). In coffee plantations established on sloping Andean terrain, the natural redistribution of nutrients through runoff and erosion processes may generate heterogeneous fertility patterns.

Phosphorus exhibited the greatest variability among the evaluated nutrients. This behavior is consistent with its low mobility in soil and its tendency to form insoluble complexes in acidic environments or soils with high concentrations of iron and aluminum oxides, characteristics commonly found in Andean volcanic soils (Havlin et al., 2014). The detection of this variability using the portable system suggests that the device could be useful for identifying specific areas requiring site-specific phosphorus fertilization.

For nitrogen, the observed variability may be associated with differences in organic matter mineralization, fertilization history, or local variations in soil moisture. Potassium exhibited the smallest absolute range, although the observed differences remain agronomically meaningful.

Implications for sustainability and fertilizer use efficiency

The excessive or inefficient use of nitrogen and phosphorus fertilizers has been recognized as one of the major sources of environmental pollution in intensive agricultural systems because of nutrient leaching and runoff affecting both surface and groundwater resources (Tilman et al., 2002). In this context, implementing tools capable of providing more frequent and site-specific nutrient monitoring could contribute to reducing unnecessary fertilizer applications and improving input-use efficiency.

From an economic perspective, the ability to perform in situ measurements without relying continuously on distant, time-consuming, and costly laboratory analyses represents a significant advantage for small- and medium-scale producers. Although laboratory chemical analysis remains the reference standard, its cost may limit monitoring frequency. A low-cost portable system can complement laboratory analyses by providing intermediate assessments between laboratory campaigns.

Comparison with commercial sensors

Regarding commercially available sensors, several studies have reported that proximal sensing technologies provide rapid and non-destructive measurements, although their accuracy depends strongly on operating conditions (Riaño & Barrero Sánchez, 2023; Viscarra Rossel et al., 2011). Compared with these systems, the portable device proposed in this study offers several relevant advantages.

First, its low implementation cost, based on open-source hardware platforms such as Arduino, makes it an accessible alternative for small- and medium-scale producers compared with high-cost commercial sensors. Second, its capability to provide real-time measurements directly in the field represents a significant advantage over laboratory analyses, which require additional time and logistical resources. Finally, the observed error levels suggest that, under controlled conditions, the proposed system can achieve an average estimation accuracy comparable to that of mid-range commercial devices.

Nevertheless, it is important to recognize that advanced commercial sensors generally incorporate site-specific calibrations, environmental compensation mechanisms, and more sophisticated processing algorithms, which can improve performance under changing environmental conditions. Consequently, the proposed system still requires local calibration procedures and extended validation to achieve comparable levels of robustness.

Technological robustness of the embedded system

The stable performance of the system throughout the field measurements indicates that the Arduino-based architecture combined with RS-485 communication is well suited for agricultural environments. Differential RS-485 transmission offers advantages over simple analog interfaces by reducing susceptibility to electrical interference (Modbus Organization, 2012). The implementation of the Modbus RTU protocol enabled reliable sensor register acquisition without evidence of data loss or inconsistencies during data collection.

The modular architecture also facilitates future enhancements, including:

- Integration of SD card data storage.
- Incorporation of wireless communication modules (LoRa, Wi-Fi).
- GPS-based georeferencing.
- Integration with cloud-based data analysis platforms.

These capabilities align the proposed system with current trends in digital agriculture and Agriculture 4.0, where connectivity and data analytics play central roles (Zhang et al., 2002).

Future perspectives and applicability

Expanding this study through more robust experimental designs would enable the development of calibration models specifically tailored to Andean soils in southern Ecuador. Likewise, integrating the system with spatial mapping tools could facilitate the generation of within-field fertility maps, supporting site-specific fertilization decisions. The continued development of locally adapted technological solutions has the potential to reduce technological gaps in regions where the adoption of precision agriculture remains limited.

In terms of practical applicability, the present findings agree with the literature in indicating that portable sensors should be regarded as complementary tools to laboratory analysis rather than direct replacements (Naderi-Boldaji et al., 2013). Their principal value lies in enabling frequent monitoring, identifying spatial trends, and supporting

timely field-based decision-making. In coffee production systems such as those evaluated in this study, where spatial variability and limited access to laboratory services are important constraints, these technologies have the potential to improve nutrient management efficiency and reduce unnecessary fertilizer use.

Finally, this study should be regarded as a preliminary validation of the proposed system under real operating conditions. Future research should incorporate larger sample sizes, point-by-point validation, systematic recording of environmental variables, and site-specific calibration models for local soil conditions. Furthermore, integrating the system with georeferencing and spatial analysis tools will extend its applicability to more advanced precision agriculture applications, including fertility mapping and site-specific management strategies (McBratney et al., 2005; Zhang et al., 2002).

Conclusions

The development and implementation of a portable NPK nutrient monitoring system based on an Arduino microcontroller and RS-485 communication demonstrated technical and operational feasibility under real field conditions in a coffee plantation located in Loja, Ecuador. The embedded architecture enabled stable data acquisition, processing through averaged sensor readings, and real-time visualization, demonstrating reliable performance of the integrated microcontroller–sensor system in agricultural environments.

The results showed high average agreement between the measurements obtained with the portable system and conventional laboratory analysis, with relative errors below 6% for nitrogen, phosphorus, and potassium. Although the comparison was performed against a composite soil sample representative of the study field, the close agreement between the values suggests that the device may serve as a reliable preliminary tool for in-field nutrient monitoring. This level of agreement is particularly noteworthy considering that the sensor provides indirect nutrient estimations based on the electrical properties of the soil.

The within-field variability detected by the measurements confirms the presence of nutritional heterogeneity across the evaluated plot, a characteristic feature of Andean agricultural systems with variable topography. The system's ability to identify spatial differences in nutrient

availability reinforces its potential application in precision agriculture frameworks aimed at site-specific fertilizer management.

From a technological perspective, the modular design of the system enables future scalability and integration with georeferencing tools, data storage capabilities, and wireless communication technologies, facilitating its incorporation into digital agriculture platforms. Moreover, the use of low-cost components increases its potential adoption by small- and medium-scale producers, contributing to the reduction of technological gaps in coffee-producing regions.

Nevertheless, it is important to acknowledge that the preliminary nature of this study, the limited sample size, and the use of a composite laboratory sample restrict the statistical scope of the conclusions. Future research should include validation using paired individual soil samples, an increased number of sampling locations, and robust statistical metrics to assess point-by-point agreement and develop calibration models specifically adapted to local soil conditions.

In summary, the proposed portable system represents a promising technological alternative for preliminary nutrient monitoring in coffee crops, with the potential to support more efficient, sustainable, and spatially informed fertilization strategies.

Conflict of interest statement

The authors declare that they have no conflicts of interest.

Funding sources

This work was carried out within the framework of project 41-DI-FEIRNR-2025, entitled Development of Technological Prototypes for Co-

ffee Crop Monitoring and Characterization, funded by the National University of Loja.

Declaration on the use of artificial intelligence

During the preparation of this manuscript, ChatGPT (OpenAI, GPT-5.3 model) was used to support improvements in writing quality, academic language clarity, and the structural organization of the manuscript. The use of this tool was limited exclusively to writing assistance and text editing tasks.

The authors critically reviewed all AI-generated content, made the necessary revisions, and assume full responsibility for the integrity, accuracy, and originality of the manuscript.

Author contributions (CRediT)

Franklin Gustavo Jiménez Peralta: Conceptualization; methodology; validation; formal analysis; investigation; data curation; project administration.

Marianela del Cisne Carrión González: Conceptualization; methodology; validation; investigation; writing – original draft; writing – review & editing; supervision.

Referencias

- Adamchuk, V. I., Hummel, J. W., Morgan, M. T., & Upadhyaya, S. K. (2004). On-the-go soil sensors for precision agriculture. *Computers and Electronics in Agriculture*, 44(1), 71–91.
<https://doi.org/10.1016/j.compag.2004.03.002>
- Bland, J. M., & Altman, D. G. (1986). Statistical methods for assessing agreement between two methods of clinical measurement. *The Lancet*, 327(8476), 307–310.
[https://doi.org/10.1016/S0140-6736\(86\)90837-8](https://doi.org/10.1016/S0140-6736(86)90837-8)
- Eponon, E. C., Kassi, K., Kouame, K. D., Snoeck, D., Ouattara, T., Camara, M., Chérif, M., & Koné, D. (2023). The soil diagnostic method to formulate fertilizer requirements for coffee trees in côte d'Ivoire. *Archives of Current Research International*, 23(4), 51–59.
<https://doi.org/10.9734/acri/2023/v23i4569>
- Food and Agriculture Organization of the United Nations [FAO]. (2015). Status of the world's soil resources (SWSR): *Main report*. Food and Agriculture Organization of the United Nations.
- Gebbers, R., & Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828–831.
<https://doi.org/10.1126/science.1183899>
- Giavarina, D. (2015). Understanding Bland–Altman analysis. *Biochemia Medica*, 25(2), 141–151.
<https://doi.org/10.11613/BM.2015.015>
- Havlin, J. L., Tisdale, S. L., Nelson, W. L., & Beaton, J. D. (2014). *Soil fertility and fertilizers: An introduction to nutrient management* (8th ed.). Pearson.
- International Coffee Organization [ICO]. (2022). *Coffee development report 2022*.
- Jones, J. B. (2001). *Laboratory guide for conducting soil tests and plant analysis*. CRC Press.
- McBratney, A., Whelan, B., Ancev, T., & Bouma, J. (2005). Future directions of precision agriculture. *Precision Agriculture*, 6(1), 7–23.
<https://doi.org/10.1007/s11119-005-0681-8>
- Modbus Organization. (2012). *Modbus application protocol specification V1. 1b3*.
<https://www.modbus.org/file/secure/modbusprotocolspecification.pdf>

- Monk, S. (2016). *Programming Arduino: Getting started with sketches* (2nd ed.). McGraw-Hill Education.
- Muñoz-Huerta, R. F., Guevara-Gonzalez, R. G., Contreras-Medina, L. M., Torres-Pacheco, I., Prado-Olivarez, J., & Ocampo-Velazquez, R. V. (2013). A review of methods for sensing the nitrogen status in plants: Advantages, disadvantages and recent advances. *Sensors*, 13(8), 10823–10843.
<https://doi.org/10.3390/s130810823>
- Naderi-Boldaji, M., Alimardani, R., & Sharifi, A. (2013). Design and development of a soil nutrient measurement system for precision agriculture. *Journal of Agricultural Science and Technology*, 15, 651–662.
- Nath, S. (2024). A vision of precision agriculture: Balance between agricultural sustainability and environmental stewardship. *Agronomy Journal*, 116(3), 1126–1143.
<https://doi.org/10.1002/agj2.21405>
- Pérez-Expósito, J. P., Fernández-Caramés, T. M., Fraga-Lamas, P., & Castedo, L. (2017). VineSens: An eco-smart decision-support viticulture system. *Sensors*, 17(3), 465.
<https://doi.org/10.3390/s17030465>
- Raun, W. R., Solie, J. B., Johnson, G. V., Stone, M. L., Lukina, E. V., Thomason, W. E., & Schempers, J. S. (2005). Optical sensor-based algorithm for crop nitrogen fertilization. *Agronomy Journal*, 97(3), 815–820.
<https://doi.org/10.2134/agronj2004.0271>
- Riaño, S., & Barrero Sánchez, F. H. (2023). Implementación de los nodos de una red inalámbrica de sensores aplicada en cultivos de café. Encuentro Internacional de Educación en Ingeniería.
<https://doi.org/10.26507/paper.3180>
- Sadeghian, S. (2022). Nutrición de cafetales: Fertilice con mayor eficiencia agronómica y económica. *Memorias Seminario Científico Cenicafé*, 71(1), e71138.
<https://doi.org/10.38141/10795/71138>
- Shaviv, A. (2001). Advances in controlled-release fertilizers. *Advances in Agronomy*, 71, 1–49.
[https://doi.org/10.1016/S0065-2113\(01\)71011-5](https://doi.org/10.1016/S0065-2113(01)71011-5)
- Tilman, D., Cassman, K. G., Matson, P. A., Naylor, R., & Polasky, S. (2002). Agricultural sustainability and intensive production practices. *Nature*, 418, 671–677.
<https://doi.org/10.1038/nature01014>

Viscarra Rossel, R. A., McBratney, A. B., & Minasny, B. (2011). Proximal soil sensing. *Geoderma*, 162(1–2), 1–5.

<https://doi.org/10.1016/j.geoderma.2010.12.017>

Zhang, N., Wang, M., & Wang, N. (2002). Precision agriculture: A worldwide overview. *Computers and Electronics in Agriculture*, 36(2–3), 113–132.

[https://doi.org/10.1016/S0168-1699\(02\)00096-0](https://doi.org/10.1016/S0168-1699(02)00096-0)

Contraste entre TaurusWebs y laboratorio

**para la estimación bromatológica de pasto Rodas
(*Pennisetum sp.*): Estudio de caso en Santa Ana**

*Victoria Delgado Tejena*¹

*Denzel Chevez Paredes*²

*Diego Nevárez Pérez*³

¹Universidad Laica Eloy Alfaro de Manabí, Facultad Ciencias de
la Vida Tecnologías, Manta, Ecuador,
<https://orcid.org/0009-0002-6610-1237>
victoriadelte2002@gmail.com

²Universidad Laica Eloy Alfaro de Manabí, Facultad Ciencias de
la Vida Tecnologías, Manta, Ecuador,
<https://orcid.org/0009-0006-9491-8876>
chevezparedesdenzelandres@gmail.com

³Universidad Laica Eloy Alfaro de Manabí, Facultad Ciencias de
la Vida Tecnologías, Manta, Ecuador,
<https://orcid.org/0000-0002-0336-2862>
diego.nevarez@uleam.edu.ec

DOI: 10.61854/rccedia.v1n1.003

Enviado: 16 de febrero de 2026

Aprobado: 27 de abril de 2026

Publicado: martes 14 de julio de 2026



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Resumen

El presente trabajo tiene el propósito de comparar los resultados del ensayo del pasto Rodas (*Pennisetum* sp.), mediante el software TaurusWebs, con los obtenidos a través de métodos tradicionales de laboratorio, con énfasis en las variables: proteína, materia seca, energía neta de lactancia, fibra detergente neutra, fibra detergente ácida y minerales. La investigación se realizó en dos áreas definidas de pastizales en el cantón Santa Ana, provincia de Manabí, donde se aplicó un diseño experimental basado en tres muestreos durante periodos de 15, 30 y 45 días. El estudio consideró diversas condiciones lumínicas y tres altitudes de captura (20, 50 y 100 m s. n. m.) para evaluar la precisión de la respuesta frente a la variabilidad del entorno.

De acuerdo con las pruebas estadísticas, se concluye que el software de análisis de imágenes constituye una herramienta viable y eficiente para la estimación de proteína, materia seca y minerales en el pasto Rodas. No obstante, se identificaron limitaciones en la predicción de energía y fracciones de fibra. Estas discrepancias no restan validez a la herramienta, sino que derivan de las diferencias intrínsecas entre la espectroscopia y los métodos químicos del laboratorio. Por otro lado, su implementación debe considerarse como un complemento al método tradicional, especialmente en la evaluación de fibra, donde los valores difieren significativamente debido a la naturaleza de los algoritmos de procesamiento. Estos hallazgos subrayan la importancia de potenciar el uso de tecnologías digitales en la gestión ganadera local, optimizando la toma de decisiones nutricionales de manera ágil y económica.

Palabras clave:
análisis comparativo, espectroscopia de
infrarrojo cercano, fibra detergente, forrajes,
proteína bruta, valor nutricional.

Introducción

En el Ecuador, la provincia de Manabí ocupa el primer lugar en existencia de cabezas de ganado con aproximadamente 711 011 animales vivos. No obstante, según los datos de la Encuesta de Superficie y Producción Agropecuaria Continua (ESPAC), el rendimiento en relación con la superficie es de 1,00 res/ha, cifra que se sitúa por debajo de Guayas, Los Ríos, El Oro y Esmeraldas. Esta situación posiciona a la localidad en el decimoséptimo lugar a nivel nacional, lo que plantea la necesidad de revisar el manejo eficiente de los recursos forrajeros en el sector pecuario, lo que constituye el principal desafío para la sostenibilidad económica de la actividad ganadera (Instituto Nacional de Estadísticas y Censos - INEC, 2024).

Fierro Cordero (2018) afirma que:

En Ecuador, uno de los principales problemas que se presenta en el manejo de pastizales es el desconocimiento de las especies utilizadas, lo que genera un uso inadecuado de los pastos, impidiendo llegar a resultados óptimos de producción. A esto se añade la carencia de nutrimentos existentes a nivel de suelo, la falta de sistemas de irrigación y la utilización de especies no adaptadas a las condiciones agroecológicas, factores que inciden en la escasez de materia seca en los forrajes en ciertas épocas del año. (p. 10)

En el cantón Santa Ana, la producción ganadera depende directamente de la calidad nutricional de las pasturas; sin embargo, existe una marcada deficiencia en el monitoreo técnico

de estos recursos. Esta situación genera que el aprovechamiento del pasto Rodas (*Pennisetum sp.*) se realice sin un sustento bromatológico preciso, lo que deriva en una suplementación inadecuada y un incremento innecesario de los costos de producción por unidad de producto.

La motivación detrás de esta investigación surge de la necesidad de validar alternativas tecnológicas que faciliten la toma de decisiones en el campo. Tradicionalmente, la caracterización de forrajes se ha limitado al análisis de laboratorio que, si bien es el referente de precisión, implica una inversión económica y de tiempo que muchos productores locales no pueden asumir con frecuencia. En este escenario, la implementación de herramientas de ganadería 4.0, específicamente el software TaurusWebs, se presenta como una solución innovadora. El interés central de este estudio es determinar si la estimación digital de nutrientes puede ofrecer resultados comparables a la metodología convencional bajo las condiciones específicas de Santa Ana.

Frente a la problemática, el objetivo general de este trabajo es realizar una evaluación comparativa bromatológica del pasto Rodas (*Pennisetum sp.*), contrastando los datos generados por el software TaurusWebs con los resultados obtenidos en laboratorio. Para alcanzar esto, se han planteado objetivos específicos que complementan la cuantificación de variables clave como proteína, materia seca, energía, fibra detergente neutra, fibra detergente ácida y minerales, buscando establecer el grado de fiabilidad de la herramienta tecnológica en el entorno local.

La cuantificación de los componentes nutricionales del forraje demandó la aplicación

de protocolos analíticos específicos para cada variable evaluada. La determinación del contenido de proteína bruta se realizó mediante el método Kjeldahl, fundamentado en la destilación del nitrógeno total de la muestra. Por otro lado, se empleó la técnica de gravimetría para el cálculo de materia grasa, porcentaje de humedad y ceniza, basándose en la diferencia de pesos tras someter las muestras a tratamientos térmicos controlados. También se obtuvieron en el laboratorio los carbohidratos mediante un cálculo indirecto y este valor fue utilizado posteriormente en la estimación del aporte energético del forraje.

Con el fin de robustecer la comparación con el software TaurusWebs, se integraron análisis adicionales de fibra detergente neutra (FDN) y fibra detergente ácida (FDA). Estos parámetros, esenciales para estimar la digestibilidad del pasto Rodas, fueron procesados bajo principios de gravimetría (método de Van Soest), manteniendo así la coherencia metodológica y la rigurosidad necesaria para validar la precisión de los sistemas digitales frente a los estándares convencionales de laboratorio. Para los minerales como sodio, potasio, calcio, hierro, magnesio, cobre, zinc y manganeso, presentes en el pasto, se aplicó la técnica de “AA de llama” o espectroscopia de absorción atómica, también utilizada para la determinación de metales pesados.

La plataforma TaurusWebs integra capacidades de análisis basadas en los principios de la espectroscopia de infrarrojo cercano (NIRS) para la estimación de componentes bromatológicos. Este proceso se fundamenta en la adquisición de datos mediante sensores aerotransportados en el dron, el cual captura información espectral a tra-

vés de algoritmos RGB. Esta tecnología descompone la luz reflejada por el dosel del pasto Rodas en sus tres bandas cromáticas primarias: Rojo (Red), Verde (Green) y Azul (Blue), permitiendo que el sistema interprete las longitudes de onda vinculadas a la actividad fotosintética y el vigor vegetativo para calcular el valor nutricional del forraje. El método NIRS tiene la capacidad de dar resultados de forma confiable, como la composición nutricional de fibra detergente neutra, fibra detergente ácida, proteína, materia seca, entre otros elementos (Ariza Nieto, 2018).

La investigación se fundamenta en la hipótesis de que no existen diferencias estadísticas significativas entre los valores reportados por ambos métodos de evaluación. De cumplirse este supuesto, se propone al sector ganadero de Santa Ana una metodología de diagnóstico ágil y de bajo costo, permitiendo optimizar la dieta animal y mejorar la competitividad de las fincas de la zona.

Métodos

La investigación se desarrolló en el cantón Santa Ana, ubicado en la zona centro-oeste de la provincia de Manabí, República del Ecuador. El área seleccionada para el análisis del pasto Rodas se localiza geográficamente en las coordenadas 1° 12' de latitud Sur y 80° 22' de longitud Oeste, situándose a una altura aproximada de 50 m s. n. m. Este entorno presenta las condiciones agroecológicas típicas de la región, caracterizadas por un clima que influye directamente en la composición bromatológica de los forrajes evaluados en este estudio.

La zona presenta temporadas de verano e invierno. Tiene un clima tropical húmedo, con una temperatura media anual de 26 °C. Su precipitación anual oscila entre los 500 mm y los 1 000 mm. El terreno tiene una superficie de 6 hectáreas con 56 metros cuadrados.

Diseño de muestreo

Para garantizar la calidad de los datos, se realizó una calibración del balance de blancos de la cámara del dron, ajustando el valor a 5 200 K. Este ajuste es fundamental para estandarizar la captura de imágenes y debe adaptarse a las especificaciones técnicas de la aeronave utilizada según lo recomendado por el software (TaurusWebs, 2025), evitando así interferencias cromáticas durante el levantamiento.

El proceso de recolección se llevó a cabo en dos parcelas del mismo terreno, efectuando capturas de tres niveles de altitud: 20, 50 y 100 metros. Estos vuelos se realizaron en condiciones de cielo despejado y con iluminación solar estable, con el fin de prevenir la formación de sombras proyectadas que generen irregularidades o sesgos en el procesamiento bromatológico de las

imágenes.

Para determinar la ventana cronológica más adecuada para la adquisición de datos multiespectrales, se definieron tres horarios de muestreo: 10:00, 14:00 y 17:00 horas, ejecutados específicamente durante los días 30 y 45 del ciclo del cultivo. Se determinó prescindir de la evaluación al día 15 en este horario y solo se capturó una imagen por cada altura tras constatar que la densidad de la cobertura vegetal era insuficiente para un análisis representativo.

Debido a que el software generaba un volumen de datos superior a la frecuencia de los análisis químicos, se procedió a calcular promedios diarios por variable evaluada. Este procedimiento de normalización permitió alinear la gradualidad de la información digital con los reportes de laboratorio, los cuales arrojaban un valor único por jornada de muestreo. Dicho ajuste fue determinante para fortalecer la estructura del análisis estadístico y garantizar la coherencia en la comparación de las metodologías.

El análisis de las imágenes se realizó de forma individual para determinar el contenido de proteína, materia seca, energía neta de lactancia (MJ/kg), fibra detergente neutra (FDN) y fibra detergente ácida (FDA). Asimismo, se cuantificaron microminerales (Cu, Fe, Zn, Mn, B) y macrominerales (K, P, Ca, S, Mg) presentes en la materia seca de las gramíneas. Este procedimiento se llevó a cabo mediante algoritmos matemáticos que tiene el software y que son decodificados por las bandas RGB que proporcionan las imágenes tomadas por el dron.

De esta forma, se puede interpretar la reflectancia de las longitudes de onda vinculadas a la actividad fotosintética en los cloroplastos, facilitando la estimación indirecta de la concentra-

ción de nutrientes y minerales en el tejido vegetal. Pesantez (2024) indica que las imágenes espectrales captadas por cámaras RGB convencionales han permitido el monitoreo sobre el estado de la vegetación, el análisis de la cobertura terrestre y la identificación de distintos tipos de estrés, tanto hídrico como nutricional (p. 17).

Obtención de muestras para laboratorio

Para el muestreo de laboratorio se establecieron coordenadas GPS dentro de las dos parcelas de pasto Rodas, que fueron georreferenciadas mediante el uso de un dron. Este procedimiento se realizó con el fin de garantizar una comparación precisa y confiable de los resultados obtenidos entre ambas metodologías de análisis.

Previo a la toma de muestra de pasto, se efectuó un procesamiento inicial de la imagen capturada a una altura de 100 metros, utilizando el software correspondiente. Dicho procesamiento permitió identificar el área del cultivo que presentaba mejores condiciones. En el software, la imagen se visualiza mediante bandas de colores, donde las zonas con mayor vigor vegetativo se representan con un color verde intenso; no obstante, se verificó que dichas áreas correspondieran efectivamente al cultivo objeto de estudio.

Una vez seleccionada el área más representativa del pasto, se procedió a la recolección de las muestras. En total, se obtuvieron seis muestras, las cuales fueron mezcladas de manera homogénea para conformar una muestra compuesta. Posteriormente, esta se almacenó en una bolsa de poliestireno con cierre hermético para su envío y análisis en el laboratorio.

Cada muestra fue debidamente etiquetada con la coordenada exacta del punto de recolección y recibió el tratamiento correspondiente, conforme a los requerimientos establecidos por el laboratorio. La cantidad de muestra recolectada dependió de las especificaciones del laboratorio CESECCA, que solicitó un total de 200 gramos de muestra por parcela.

Este procedimiento se llevó a cabo en las tres tomas de muestra correspondientes a los dos días establecidos. En estas ocasiones se omitió el análisis previo en el software en las tomas 2 y 3, con el fin de mantener un registro continuo y minimizar posibles errores durante la recolección. Además, se definió un único sector fijo para la toma de muestras.

Para los análisis de minerales, FDA y FDN, se recolectó un kilogramo de biomasa por parcela, cumpliendo con las normativas de ingreso de los laboratorios de Agrocalidad en Tumbaco. Las muestras fueron selladas herméticamente y trasladadas en condiciones de refrigeración. Este proceso se realizó solamente en la fase final del estudio para complementar la comparación de datos con las funciones avanzadas del software, dado que estos análisis específicos no estaban disponibles en el laboratorio base CESECCA.

Para obtener los resultados, se emplearon diversos métodos de análisis. El porcentaje de proteína bruta se determinó mediante el método de Kjeldahl, un proceso de análisis químico que cuantifica el contenido total de nitrógeno en la muestra. Como explica la Universidad de Zaragoza (2024), en esta técnica “se digieren las proteínas y otros componentes orgánicos de los alimentos en una mezcla con ácido sulfúrico en presencia de catalizadores” (p. 2). De esta manera, el contenido de nitrógeno del pasto permite calcular su contenido de proteína bruta.

La determinación cuantitativa de la fracción del extracto etéreo (materia grasa) y el contenido hídrico (humedad) del forraje se fundamentó en el análisis gravimétrico. Para este propósito, se aplicó específicamente el método de volatilización, que consiste en medir con precisión la variación de la masa de la muestra tras la eliminación de sus componentes volátiles mediante tratamientos térmicos controlados en mufla y estufa. Este procedimiento permitió aislar y cuantificar cada residuo con el rigor necesario para su posterior contraste estadístico con las estimaciones digitales. Montero (2021) afirma que “la estrategia se modificará en caso de que volatilizemos el analito y midamos la acumulación después de la volatilización; posteriormente, la reducción de peso soportada se relaciona con el analito que se ha volatilizado” (p. 20).

La obtención de la materia seca se realizó mediante el método gravimétrico clásico, procedimiento de química analítica estandarizado por la AOAC (Asociación de Químicos Analíticos Oficiales). El cálculo se efectuó restando el porcentaje de humedad del total de la muestra (100 %), lo cual representa la suma de los componentes sólidos del pasto: carbohidratos, materia seca, ceniza y proteína bruta, siguiendo los protocolos del laboratorio CESECCA.

Para estimar el contenido energético del forraje, el laboratorio empleó la fórmula desarrollada por Wilbur Olin Atwater, quien fue un pionero en la nutrición en Estados Unidos y quien se destacó por enfocarse en el interés ganadero y agrícola (Farías Reyes, 2025, p. 2). Dicho modelo matemático se basa en el principio de conservación de la energía y utiliza los porcentajes de proteína, grasa y carbohidratos como variables principales. La expresión matemática utilizada es Energía =

$4(\%P) + 9(\%G) + 4(\%C)$. Para la determinación de FDA y FDN, se utilizó el método detergente de Van Soest. Este proceso de fraccionamiento emplea soluciones detergentes específicas para cuantificar los componentes estructurales de la pared celular (Sniffen, 1992, como se citó en Lery, 2016, p. 3).

Según Lery (2016), el procesamiento de las muestras inició con su registro, secado y molienda, tras lo cual fueron transferidas a sobres de papel filtro vegetal. Para la determinación de FDN, se añadió la solución detergente neutra (SDN), compuesta por agua destilada, lauril, sulfato de sodio, fosfato disódico y 2-etoxietanol. La mezcla se sometió a una ebullición durante una hora en una plancha de calentamiento, manteniendo un volumen constante mediante la adición de agua destilada. Posteriormente, las muestras se secaron en una estufa para la cuantificación de los residuos finales. Un método análogo se empleó para la obtención de FDA, sustituyendo el reactivo por la solución detergente ácida (SDA), la cual contiene ácido sulfúrico 1N y bromuro de cetiltrimetilamonio (Lery, 2016).

Con el propósito de ampliar las comparaciones entre las variables analizadas por el software y los datos empíricos, se realizaron análisis minerales complementarios en el laboratorio de Agrocalidad utilizando las muestras del día 45. Allende Céspedes (2024) indica que, para la determinación de nitrógeno, se empleó el método DUMAS, fundamentado en la combustión completa de la muestra. Este proceso se ejecutó en un horno a 950 °C durante 2,8 minutos, seguido de una transferencia a una cámara de purga sellada. La combustión genera una mezcla gaseosa que se homogeniza en un balasto, desde donde se extrae una porción representativa para su detección final en el analizador.

En cuanto a la cuantificación del fósforo, se utilizó la metodología de colorimetría (Páez Ordóñez & Ortiz Burbano, 2015) que indica:

Según la literatura, el método estándar para la determinación de fosfato se basa en la reacción del fósforo con iones de molibdeno y antimonio para formar un complejo, el cual puede ser reducido utilizando cloruro de estaño o ácido ascórbico, resultando una coloración azul característica que puede ser detectada mediante colorimetría. (p. 41)

En cuanto a los demás elementos (K, Ca, Mg, Fe, Mn, Cu, Zn), se determinaron mediante espectroscopia de absorción atómica. Según Peñaloza (2023), este procedimiento consiste en conducir la materia líquida hacia el nebulizador del equipo para ser llevada a la llama, donde se transforma en átomos libres. La combustión de aire-acetileno alcanza aproximadamente los 2 300 °C, temperatura suficiente para la atomización de diversos elementos. No obstante, para alcanzar una mayor energía térmica, se puede emplear una mezcla de óxido nitroso y acetileno, capaz de producir temperaturas cercanas a los 2 900 °C. Una vez que los átomos libres se encuentran en estado gaseoso, son expuestos a la radiación térmica emitida por la lámpara de cátodo hueco (construida con un tubo de vidrio que contiene un gas inerte de neón o argón).

La fracción de la radiación que no es absorbida continúa su trayectoria hasta el detector. Durante este proceso, los electrones absorben energía y pasan a un nivel energético superior de forma transitoria. Al medir la diferencia entre la energía emitida y la detectada a una longitud de onda específica, se cuantifica la radiación absorbi-

da mediante la ley de Lambert-Beer, estableciendo así una relación directa entre la señal obtenida y la concentración del elemento analizado (Peñaloza, 2023).

Diseño experimental

El presente estudio se fundamentó en la comparación de dos sistemas de análisis aplicados sobre las mismas unidades experimentales, con el propósito de evaluar la concordancia o diferencias entre los métodos. Esta configuración técnica facilitó una contrastación directa entre las estimaciones digitales de TaurusWebs y los reportes químicos de laboratorio, con el propósito de determinar la eficiencia de cada herramienta y su impacto real en la optimización de los recursos económicos del productor ganadero en el cantón Santa Ana.

Para el procesamiento, el contraste entre ambos métodos se ejecutó mediante la prueba *t* de Student para muestras relacionadas. Esta herramienta estadística permitió determinar la existencia o ausencia de diferencias significativas entre los resultados obtenidos por ambos métodos, facilitando así una valoración bromatológica precisa del forraje al identificar posibles discrepancias entre las mediciones.

Las variables que se presentan por parte de la investigación son las siguientes:

- Variable dependiente: resultado del análisis bromatológico del forraje Rodas (*Pennisetum* sp.) manifestado en los porcentajes de proteína, materia seca y energía neta de lactancia.
- Variable independiente: Análisis bromatológico de laboratorio y software TaurusWebs.

Resultados

Tabla 1

Comparativa de parámetros bromatológicos promedio en la parcela 1

Día	Método	Proteína (%)	FDN (%)	FDA (%)	Materia seca (%)	Energía (ENL) MJ/kg
15	TaurusWebs	7,25	64,96	35,20	18	3,95
30	TaurusWebs	10,74	61,42	33,59	18	4,39
45	TaurusWebs	19,11	51,59	22,65	18	5,42
15	Laboratorio	2,56			12,12	0,18
30	Laboratorio	2,20			10,91	0,15
45	Laboratorio	2,51	91,31	56,07	19,96	0,29

Los resultados bromatológicos comparativos presentados en la Tabla 1 exponen discrepancias sustanciales entre las estimaciones del software TaurusWebs y las determinaciones analíticas de laboratorio. En cuanto a la fracción proteica, el software proyectó un incremento atípico hasta alcanzar un 19,11 % al día 45, mientras que el análisis químico reportó valores significativamente inferiores y estables (media 2,42 %), evidenciando una sobreestimación teórica por parte del modelo digital.

Esta tendencia se acentúa en los componentes estructurales de la pared celular. Al día 45, el método gravimétrico de laboratorio registró niveles críticos de 91,31 % para FDN y 56,07 % para FDA, contrastando con la reducción del

contenido fibroso que el software predijo (51,59 % y 22,65 % respectivamente). Esta divergencia se fundamenta en la diferencia metodológica: TaurusWebs opera mediante modelos matemáticos predictivos que, en este estudio, demostraron limitaciones para extrapolar la cinética de lignificación real en condiciones de campo. Por el contrario, el método de laboratorio (Van Soest) es de naturaleza gravimétrica, permitiendo la cuantificación física de los componentes estructurales de la pared celular.

Un punto crítico de variación se observa en la materia seca, donde el software mantuvo un valor paramétrico constante de 18 %. Esta homogeneidad responde al uso de valores pre-configurados o por defecto basados en promedios

de tablas nutricionales estándar. No obstante, el análisis químico identificó fluctuaciones de humedad, para el día 15 (12,12 %) y para el día 45 (19,96 %). Estas diferencias analíticas impactaron directamente en el cálculo de la energía neta de lactancia (ENL); mientras que el software proyec-

tó un progresivo aumento de 3,95 MJ/kg a 5,42 MJ/kg basado en la estimación de fibra baja, el laboratorio determinó un incremento que va desde 0,18 MJ/kg a 0,29 MJ/kg, debido a que la FDA (lignina) penaliza matemáticamente la digestibilidad y el aporte energético.

Tabla 2

Prueba t de Student de proteína de ambas metodologías, parcela 1

Día	Anal. del soft. (A)	Anal. del lab. (B)	A-B	(A-B) ²
15	7,25	2,56	4,69	22
30	10,74	2,20	8,54	72,93
45	19,11	2,51	16,60	275,56
Σ	32,1	7,27	29,83	370,49
$\bar{x}$	12,37	2,42	9,94	123,50
S^2	$\sqrt{S^2}$	GL	Datos de Tukey	t
12,31	3,51	2	0,05 = 4,303 0,01 = 9,925	2,83

Con el objetivo de determinar la fiabilidad de las herramientas de ganadería 4.0 frente a los métodos convencionales, se aplicó una prueba t de Student para muestras pareadas. Se comparó el contenido de proteína obtenido mediante el software (A) y el laboratorio (B). Para este análisis, se promediaron los valores registrados por el software en los días 15, 30 y 45, consolidando un valor representativo por etapa para una comparación directa con los resultados del análisis de laboratorio.

Los resultados estadísticos mostraron un valor de t calculado (2,83) inferior a los valores críticos establecidos para ambos niveles de significancia del 5 % (4,303) y 1 % (9,925). Por consiguiente, se acepta la hipótesis de similitud entre las estimaciones del software y los análisis de laboratorio para el parámetro evaluado.

Tabla 3

Prueba t de Student de materia seca de ambas metodologías, parcela 1

Día	Anal. del soft. (A)	Anal. del lab. (B)	A-B	(A-B) ²
15	18	12,12	5,88	34,57
30	18	10,91	7,09	50,27
45	18	19,96	-1,96	3,84
Σ	54	42,99	11,01	88,68
$\bar{x}$	18	14,33	3,67	29,56
S^2	$\sqrt{S^2}$	GL	Datos de Tukey	t
8,04	2,84	2	0,05 = 4,303 0,01 = 9,925	1,29

El análisis del software (A) muestra una estabilidad absoluta, ya que durante los tres días mantiene un valor constante de 18, mientras que el análisis de laboratorio (B) presenta una fluctuación importante, con una media

de 14,33. Pese a que se presenta diferencia aritmética, los datos indican que no hay evidencia estadística para afirmar que un método sea superior al otro o que entreguen resultados distintos de forma sistemática.

Tabla 4

Prueba t de Student de energía (MJ/kg) de ambas metodologías, parcela 1

Día	Anal. del soft. (A)	Anal. del lab. (B)	A-B	(A-B) ²
15	3,9	0,18	3,72	13,84
30	4,4	0,15	4,25	18,06
45	5,40	0,29	5,11	26,11
Σ	13,7	0,62	13,08	58,01
$\bar{x}$	4,57	0,21	4,36	19,34
S^2	$\sqrt{S^2}$	GL	Datos de Tukey	t
0,16	0,41	2	0,05 = 4,303 0,01 = 9,925	10,77

Al contrastar el rendimiento energético mediante las dos metodologías propuestas, se determinó que el software y el laboratorio no arrojan resultados equivalentes. El valor de t calculado (10,77) superó los valores de referencia críticos para los niveles de confiabilidad de Tukey

para el rigor estadístico del 5 % y 1 %. En consecuencia, se rechaza la hipótesis de igualdad y se concluye que existe diferencia estadísticamente significativa entre ambos métodos analíticos durante las fases de 15, 30 y 45 días.

Tabla 5

Resultados de comparación del día 45 de FDA y FDN, parcela 1

Día	Método	FDN	FDA
45	TaurusWebs	51,60	22,70
45	Laboratorio	91,31	56,07

De manera complementaria, se efectuó la determinación de fibra detergente neutra (FDN) y fibra detergente ácida (FDA) durante la fase final del periodo de muestreo (día 45).

Al contrastar ambas metodologías en la tabla 5, se identificó una discrepancia sustancial en los valores absolutos obtenidos.

Tabla 6

Comparativa de parámetros minerales promedio en la parcela 1 en el día 45

Día	Método	Ca (%)	P (%)	Mg (%)	K (%)	Cu (%)	Fe (mg/kg)	Zn (mg/kg)	Mn (mg/kg)	N (%)
45	TaurusWebs	0,32	0,40	0,16	4,28	6,35	164	29,11	50,56	3,06
45	Laboratorio	0,22	0,17	0,15	2,62	9	170	28	51,50	2,13

El análisis de minerales en la finca de Santa Ana permitió identificar la composición elemental del pasto Rodas, factor crucial para el balance metabólico del ganado. Se observó una estabilidad relativa en los macronutrientes, destacando niveles promedio de calcio (0,32 %), fósforo (0,40 %), magnesio (0,16 %), potasio (4,28 %) y nitrógeno (3,06 %). Asimismo, se identificó la presencia de micronutrientes como hierro (164 mg/kg), zinc (29,11 mg/

kg) y manganeso (50,56 mg/kg) por parte del software; en comparación con los resultados de laboratorio, se identificó que las cantidades no son muy alejadas de la realidad. Para esto tenemos calcio (0,22 %), fósforo (0,17 %), magnesio (0,15 %), potasio (2,62 %) y nitrógeno (2,13 %) y, por parte de los micronutrientes, se identificó la presencia de hierro (170 mg/kg), zinc (28 mg/kg) y manganeso (51,50 mg/kg).

Parcela 2

En la parcela 2, la evaluación del pasto Rodas mediante el software TaurusWebs mostró una tendencia incremental en la concentración de nutrientes a medida que avanzaba el ciclo fenológico. Al día 15, se registró un promedio inicial de proteína bruta de 4,20 %, el cual ascendió significativamente hasta alcanzar el 16,61 % al finalizar el periodo de 45 días.

Al igual que en la parcela 1, existe una brecha notable al contrastar estos datos con los análisis de laboratorio, especialmente en las etapas finales del cultivo. Mientras que el software estimó niveles de proteína superiores al 16 %, el método químico reportó una concentración de 2,85 % al día 45. Una discrepancia similar se observó en los niveles de energía neta de lactancia (ENL), donde el sistema digital proyectó 5,11 MJ/kg frente a los 0,33 MJ/kg validados en el laboratorio.

Tabla 7
Comparativa de parámetros bromatológicos promedio en la parcela 2

Día	Método	Proteína (%)	FDN (%)	FDA (%)	Materia seca	Energía (ENL MJ/kg)
15	TaurusWebs	4,20	68,41	35,14	18	3,57
30	TaurusWebs	10,89	60,86	33,54	18	4,40
45	TaurusWebs	16,61	54,41	26,98	18	5,11
15	Laboratorio	2,91			9,66	0,14
30	Laboratorio	2,03			16,57	0,24
45	Laboratorio	2,85	92,61	56,57	22,37	0,33

Con relación a la fracción fibrosa, el laboratorio determinó valores de 92,61 % para FDN y 56,57 % para FDA. Estas cifras superan am-

pliamente las estimaciones del software, lo que refuerza la hipótesis de la interpretación espectral del algoritmo RGB.

Tabla 8

Prueba t de Student de proteína de ambas metodologías, parcela 2

Día	Anal. del soft. (A)	Anal. del lab. (B)	A-B	(A-B) ²
15	4,20	2,91	1,29	1,66
30	10,89	2,03	8,86	78,50
45	16,61	2,85	13,76	189,34
	31,7	7,79	23,76	269,50
$\bar{x}$	10,57	2,60	7,97	89,83
S ²	$\sqrt{S^2}$	GL	Datos de Tukey	t
13,15	3,63	2	0,05 = 4,303 0,01 = 9,925	2,20

La evaluación de la proteína en la parcela 2 no mostró discrepancia crítica entre el método digital y el laboratorio. Tras ejecutar el balance estadístico, se obtuvo un coeficiente de contraste de 2,20. Al situarse este valor por debajo de los

umbrales de significancia, se determina que las variaciones entre ambos métodos carecen de relevancia estadística, evidenciando una paridad entre los resultados reportados.

Tabla 9

Prueba t de Student de materia seca de ambas metodologías, parcela 2

Día	Anal. del soft. (A)	Anal. del lab. (B)	A-B	$(A-B)^2$
15	18	9,66	8,34	69,56
30	18	16,57	1,43	2,04
45	18	22,37	-4,37	19,10
	54	48,6	5,40	90,70
$\bar{x}$	18	16,20	1,80	30,23
S^2	$\sqrt{S^2}$	GL	Datos de Tukey	t
13,49	3,67	2	0,05 = 4,303	0,49
			0,01 = 9,925	

Con el mismo método, se evaluó el contenido de materia seca entre ambas técnicas de diagnóstico, siendo el valor de t (0,49) drásticamente

inferior al valor crítico mínimo (4,303); el análisis cae plenamente en la zona de aceptación de la hipótesis nula.

Tabla 10

Prueba t de Student de energía (MJ/kg) de ambas metodologías, parcela 2

Día	Anal. del soft. (A)	Anal. del lab. (B)	A-B	(A-B) ²
15	3,57	0,14	3,43	11,76
30	4,4	0,24	4,16	17,31
45	5,11	0,33	4,78	22,85
Σ	13,08	0,71	12,37	51,92
$\bar{x}$	4,36	0,24	4,12	17,31
s^2	$\sqrt{s^2}$	GL	Datos de Tukey	T
0,15	0,39	2	0,05 = 4,303 0,01 = 9,925	10,57

Los resultados referentes a la densidad energética (MJ/kg) muestran una divergencia crítica en la evolución. El coeficiente de contraste

alcanzado (10,57) se posiciona muy por encima de los valores tabulados por Tukey, lo que obliga a rechazar la hipótesis de igualdad.

Tabla 11

Resultados de comparación del día 45 de FDA y FDN parcela 2

Día	Método	FDN	FDA
45	TaurusWebs	54,41	26,98
45	Laboratorio	92,61	56,57

Se llevó a cabo la evaluación de las fracciones estructurales fibra detergente neutra y ácida (FDN, FDA) en la etapa final del proceso de muestreo. La comparación evidenció un sesgo

importante entre los valores obtenidos, denotando una escasa concordancia entre los resultados de las determinaciones de laboratorio y las estimaciones del software.

Tabla 12

Comparativa de parámetros minerales promedio en la parcela 2 en el día 45

Día	Método	Ca (%)	P (%)	Mg (%)	K (%)	Cu (%)	Fe (mg/kg)	Zn (mg/kg)	Mn (mg/kg)	N (%)
45	TaurusWebs	0,33	0,36	0,19	3,46	5,66	138	28,44	55,89	2,66
45	Laboratorio	0,19	0,18	0,14	2,38	8,5	127	36,49	12,15	1,87

El estudio de los componentes inorgánicos en la parcela 2 permitió establecer un perfil de nutrientes esenciales para el ganado bovino. Se determinaron concentraciones promedio de calcio (0,33 %), fósforo (0,36 %), magnesio (0,19 %), potasio (3,46 %) y nitrógeno (2,66 %). Asimismo, se identificó la presencia de micronutrientes como hierro (138 mg/kg), zinc (28,44 mg/kg) y manganeso (55,89 mg/kg) por parte del software. En

comparación con los resultados de laboratorio, se identificó que las cantidades no son muy alejadas de la realidad; para esto tenemos calcio (0,19 %), fósforo (0,18 %), magnesio (0,14 %), potasio (2,38 %) y nitrógeno (1,87 %) y, por parte de los micronutrientes, se identificó la presencia de hierro (127 mg/kg), zinc (36,49 mg/kg) y manganeso (12,15 mg/kg).

Figuras




Figura 1

Polígono de la finca de Hernán Mieles Moreira.

Nota. Para la ejecución del análisis bromatológico del pasto Rodas, se seleccionaron unidades de muestreo representadas dentro de la superficie total de la finca (Figura 1). La recolección de la biomasa se centró específicamente en la parcela 1, con una extensión de 1,98 hectáreas, y en la parcela 2, que comprende 1,00 hectárea.

Esta sectorización de la finca ubicada dentro del cantón Santa Ana permitió capturar la variabilidad del forraje en condiciones de campo reales, facilitando la correlación entre la gestión espacial del predio y los indicadores nutricionales obtenidos en el laboratorio y en el software.

Parcela 1




Figura 2

Análisis bromatológico a 100 metros de altura

Nota. La secuencia conformada por las Figuras 2 a 9 ilustra el proceso de teledetección y procesamiento digital aplicado en el estudio. Estas figuras exponen la morfología del terreno y la densidad del follaje mediante capturas aéreas obtenidas a altitudes de 100 m, 50 m y 20 m. La

progresión gráfica permite constatar la integración de estas imágenes en el software TaurusWebs, plataforma en la cual se ejecutó la interpretación de los datos para la estimación de los parámetros bromatológicos y minerales del pasto Rodas dentro del cantón Santa Ana.




Figura 3

Análisis bromatológico a 50 metros de altura

Nota. Imagen obtenida a una altura media para evaluar la resolución de la biomasa y su impacto en la precisión de las estimaciones digitales.

El procesamiento se realizó mediante la plataforma TaurusWebs, siguiendo los lineamientos metodológicos descritos anteriormente.




Figura 4

Análisis bromatológico a 20 metros

Nota. Captura de alta resolución que permite una inspección detallada de la densidad y calidad del forraje en las parcelas de estudio.




Figura 5

Análisis mineral

Nota. Imagen procesada para la identificación de concentraciones minerales específicas.




Figura 6

Análisis bromatológico a 100 metros de altura en la parcela 2

Nota. Captura aérea de zona seleccionada utilizada para la validación del perfil bromatológico en el software TaurusWebs.




Figura 8

Análisis bromatológico a 20 metros de altura.

Nota. Imagen utilizada para validar parámetros nutricionales del pasto Rodas en TaurusWebs.




Figura 9

Análisis mineral.

Nota. Fotografía empleada para complementar el estudio del parámetro mineral del pasto Rodas.




Figura 10

Comparación de los niveles de proteína en la parcela 1: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 11

Comparación de los niveles de materia seca en la parcela 1: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 12

Comparación de los niveles de energía en la parcela 1: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 13

Comparación de los niveles de FDN y FDA en la parcela 1: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 14
Comparación de los niveles de los minerales en la parcela 1: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 15

Comparación de los niveles de proteína en la parcela 2: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 16

Comparación de los niveles de materia seca en la parcela 2: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 17

Comparación de los niveles de energía en la parcela 2: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 18

Comparación de los niveles de FDN y FDA en la parcela 2: estimaciones digitales del software TaurusWebs vs. análisis instrumental de laboratorio.

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.




Figura 19

Nota. Los valores representados en las barras corresponden a los resultados obtenidos en los muestreos dentro de la misma unidad de manejo en Santa Ana. La diferencia visual entre

el software y el laboratorio permite contrastar la hipótesis de investigación sobre la precisión de las herramientas digitales para el análisis del pasto Rodas.

Ecuaciones

Hipótesis nula

$$H_o = VA = VB$$

Hipótesis afirmativa

$$H_a = VA \neq VB$$

Varianza

$$S^2 = \frac{\Sigma D^2 - \frac{(\Sigma D)^2}{n}}{n(n-1)}$$

Desviación estándar

$$\sqrt{S^2}$$

Grado de libertad

$$gl = n_r - 1$$

Prueba de t student

$$t = \frac{\bar{X} D}{S}$$

Discusión

El estudio comparativo de la aplicación de las técnicas de determinación de proteína cruda (PC), materia seca (MS) y energía neta de lactancia demostró que existen diferencias entre los valores obtenidos por los análisis realizados en ambas metodologías, de las columnas A y B, como se muestra en las tablas (2, 3 y 4) de la parcela 1 y de la parcela 2 en las tablas (8, 9 y 10). En efecto, esto se debe a la naturaleza propia de los procedimientos analíticos convencionales, que se realizaron en el laboratorio: método Kjeldahl y gravimetría. Mientras que el programa TaurusWebs se apega a algoritmos de procesamiento de imágenes de RGB.

A pesar de la divergencia en los procedimientos analíticos, la aplicación de la prueba estadística *t* de Student permitió determinar, mediante la rigurosa comparativa de Tukey (0,05 y 0,01), que no existen diferencias significativas entre ambos resultados tomados en los tres días correspondientes a las variables de proteína y materia seca, lo que indica que, a pesar de la variación de principios fisicoquímicos y algorítmicos, existe una coincidencia en las estimaciones en el caso del pasto Rodas (*Pennisetum* sp.).

Los resultados guardan consistencia con lo reportado por Ospina (2020), quien evaluó la correlación entre técnicas de teledetección y análisis del laboratorio (NIRS). En dicho estudio, mediante la aplicación de pruebas no paramétricas como

las correlaciones de Kendall, Spearman y el test de Kruskal-Wallis (0,05), se demostró una alta correlación y ausencia de diferencias significativas en la determinación de parámetros proteicos. Lo anterior valida que los métodos indirectos basados en sensores ópticos o algoritmos de imagen poseen una fortaleza comparativa frente a los métodos químicos de referencia (p. 4).

En lo que respecta a la determinación de la materia seca, los resultados exhibieron una variabilidad entre las metodologías empleadas. No obstante, el análisis estadístico evidenció la ausencia de diferencias significativas, tal como se detalla en las tablas 3 y 9. Resulta pertinente señalar que los valores arrojados por el software mantuvieron una notable constancia entre las tres fases de muestreo; esto se debe a que la herramienta no cuantifica la humedad de forma dinámica, sino que opera con un parámetro preestablecido.

Dado que la humedad es un factor determinante para el cálculo de materia seca por método gravimétrico, esta particularidad del algoritmo podría sugerir una limitación teórica. Sin embargo, la evidencia estadística ratifica que el procesamiento de imágenes mediante el software ofrece una precisión comparable a los métodos convencionales bajo condiciones controladas. Estos hallazgos concuerdan con lo reportado por Oliveira y otros (2021), quienes señalan que las imágenes RGB de alta

resolución representan técnicas altamente prometedoras para la estimación del rendimiento de materia seca en pastos.

Los coeficientes de contraste detallados en las tablas de energía (4 y 10) se sitúan por encima de los valores tabulados por Tukey. Esta discrepancia se fundamenta en que el software se encarga de identificar la cantidad real de energía que el animal aprovecha para producir leche y mantenerse (energía neta de lactancia), mientras que el análisis de laboratorio proporciona la energía total (o bruta) contenida en el alimento (pasto).

Al respecto, Ospina Rivera (2021) reporta la existencia de una correlación entre los resultados del laboratorio y los obtenidos mediante algoritmo de TaurusWebs; dicha relación fue validada mediante una prueba t de Student, en la cual no se evidenciaron diferencias significativas en la energía neta de lactancia (ENL). Estos antecedentes confirman que ambas metodologías de estudio son complementarias y respaldan la eficiencia del software en la estimación de parámetros nutricionales del pasto.

Aunque no se dispuso de datos completos de laboratorio para fibra detergente neutra (FDN), fibra detergente ácida (FDA) y minerales del pasto Rodas (*Pennisetum* sp.), estos parámetros fueron considerados en la última evaluación, lo que permitió realizar una comparación básica entre ambas metodologías, como se ob-

serva en las tablas (5, 6, 11 y 12). En el caso de FDN y FDA, se aprecia un alejamiento entre los valores; no obstante, Ospina (2021) indicó que “hay una alta correlación entre los resultados de la fibra detergente neutra (FDN) calculados por espectroscopia de infrarrojo cercano (NIRS) y el análisis de imágenes RGB” (p. 5). Estas conclusiones provienen de investigaciones orientadas a evaluar la similitud entre valores generados por software y los resultados de laboratorio calibrados mediante NIRS, lo que respalda los resultados obtenidos en la investigación.

Respecto a la fibra detergente ácida (FDA), Ospina (2020) establece, a partir de un estudio comparativo entre las metodologías del software y del laboratorio que utilizan NIRS como fuente de análisis, que “hay una fuerte correlación entre los resultados de la FDA calculados por NIRS versus los del análisis de imágenes RGB” (p. 7), reforzando la confiabilidad de las estimaciones obtenidas mediante herramientas basadas en imágenes.

El perfil mineral del pasto Rodas evaluado en la zona de Santa Ana muestra correlación estrecha entre las estimaciones del software y las determinaciones de laboratorio, especialmente en minerales como el magnesio y el zinc. Esta precisión sugiere que las bases de datos de ganadería 4.0 son herramientas confiables para el diagnóstico de estos parámetros en la región.

No obstante, las variaciones observadas

en los niveles de potasio y nitrógeno entre ambos métodos subrayan la influencia directa de las características edáficas locales y el manejo de la fertilización en la parcela. La identificación de estos indicadores es vital para el sector ganadero local, ya que permite transitar de una suplementación mineral genérica a una específica. Por ejemplo, los niveles de calcio y fósforo detectados sirven como base para diseñar correctores minerales que optimicen el balance electrolítico del ganado bovino en Santa Ana, minimizando desperdicios económicos y mejorando la eficiencia metabólica del hato.

La estabilidad observada en los niveles de minerales entre ambos métodos puede atribuirse a que el laboratorio de Agrocalidad empleó técnicas como la colorimetría y la espectroscopia de absorción atómica, las cuales, al igual que el software, se fundamentan en la interacción de la luz, ya sea a partir de la composición química y energética o mediante el análisis de imágenes.

El algoritmo 2ARGB® y la espectroscopia de inducción de plasma (EIP) producen resultados estadísticamente equivalentes en la estimación de macrominerales (K, P, Ca, Mg y S) en la materia seca de gramíneas. Este hallazgo, demostrado por Ospina Rivera y Baracaldo Martínez (2024), valida el análisis digital de imágenes con una alternativa precisa, no destructiva y la implementación de tecnologías de análisis de imágenes sobre las metodologías tradicionales

de laboratorio. En consecuencia, estos resultados refuerzan la utilidad del software para agilizar el diagnóstico nutricional y estructurar planes de suplementación mineral o fertilización, siempre que se calibren los datos según el tipo de aeronave empleado y las condiciones de luminosidad del área.

Conclusiones

La presente investigación demuestra que las herramientas de ganadería 4.0, específicamente aquellas basadas en algoritmos de procesamiento de imágenes como TaurusWebs, constituyen una alternativa viable para el monitoreo nutricional. Tras el análisis estadístico mediante la prueba *t* de Student, se concluye lo siguiente:

- Parámetros de alta concordancia (proteína y minerales): Se confirmó la ausencia de diferencias estadísticamente significativas entre el modelo digital y la determinación analítica química para la proteína bruta y el perfil mineral. La estabilidad observada en estos indicadores refuerza la fiabilidad del software para diagnósticos rápidos en el campo, permitiendo una toma de decisiones informada sobre el estado del pasto Rodas (*Pennisetum sp.*).
- Materia seca y variabilidad biológica: Aunque el software operó bajo valores paramétricos constantes (18 %), el análisis estadístico ratificó su similitud con los promedios de laboratorio. No obstante, se identificó que el método gravimétrico es superior para captar las fluctuaciones causadas por factores ambientales y el estado fenológico, especialmente hacia el día 45 de muestreo.
- Discrepancia en energía y fracciones fibrosas (FDN/FDA): En los parámetros de energía (ENL) y fibra, se identificaron diferencias estadísticamente significativas que superaron los valores críticos de referencia. Estas discrepancias estadísticas no obedecen a una inconsistencia metodológica, sino más bien a la naturaleza intrínseca del parámetro evaluado en cada escenario.

- Fortalezas del modelo óptico: La estabilidad en la determinación de minerales refuerza la teoría de que los métodos basados en la interacción de la luz poseen una alta fortaleza comparativa, posicionándolos como un complemento de valor en el monitoreo de la ganadería moderna.

Para futuras investigaciones, se recomienda que los análisis bromatológicos se realicen en centros especializados que garanticen la calibración rigurosa de sus instrumentos, priorizando el uso de la espectroscopia de infrarrojo cercano (NIRS). Esta tecnología permite una transición fluida entre la química y los modelos digitales, ya que, al emplear longitudes de onda para identificar enlaces químicos específicos, reduce las discrepancias metodológicas entre el laboratorio y los algoritmos del software como TaurusWebs.

Asimismo, es fundamental estandarizar las condiciones ambientales de recolección para minimizar el error experimental y optimizar la respuesta de los sensores ópticos. Se aconseja realizar las mediciones en días despejados y en la ventana horaria de 09:00 a 16:00 horas, período en el cual la estabilidad y el ángulo cenital favorecen una reflectancia uniforme del dosel del pasto. Esta precisión lumínica es crucial para que el software procese la información sin las interferencias causadas por la nubosidad o la luz difusa, permitiendo que los indicadores de calidad nutricional obtenidos posean un alto grado de confiabilidad, lo que favorece la toma de decisiones informadas.

Declaración de conflictos de interés

Quienes firman este artículo declaran no tener conflictos de interés.

Fuentes de financiación

Quienes firman este artículo declaran que esta investigación no recibió financiamiento ex-

terno de ninguna agencia de financiamiento del sector público, comercial o sin fines de lucro.

Contribución de autoría (CRediT)

Victoria Anais Delgado Tejena: Conceptualización; metodología; software; validación; análisis formal; investigación; recursos; gestión de datos; redacción - borrador original; redacción - revisión y edición; visualización; supervisión; administración del proyecto.

Denzel Andrés Chevez Paredes: Conceptualización; metodología; software; validación; análisis formal; investigación; recursos; gestión de datos; redacción - borrador original; redacción - revisión y edición; visualización; supervisión; administración del proyecto.

Diego Javier Nevárez Pérez: Conceptualización; metodología; software; validación; análisis formal; investigación; recursos; gestión de datos; redacción - borrador original; redacción - revisión y edición; visualización; supervisión; administración del proyecto.

Referencias

- Allende, E. E. B. (2024). *Funciones desempeñadas como analista de laboratorio instrumental en la empresa Société Générale De Surveillance S.A.* – Lima, optimizando métodos para la caracterización eficiente de matrices de harina de pescado y otros [Trabajo de titulación, Universidad Nacional Pedro Ruiz Gallo].
<https://repositorio.unprg.edu.pe/handle/20.500.12893/12801>
- Ariza Nieto, C., Mayorga, O. L., Mojica, B., Parra, D., & Afanador-Tellez, G. (2018). Use of LOCAL algorithm with near infrared spectroscopy in forage resources for grazing systems in Colombia. *Journal of Near Infrared Spectroscopy*, 26(1), 44–52.
<https://doi.org/10.1177/0967033517746900>
- de Oliveira, G. S., Junior, J. M., Polidoro, C., Osco, L. P., Siqueira, H., Rodrigues, L., Jank, L., Barrios, S., Valle, C., Simeão, R., Carromeu, C., Silveira, E., Jorge, L. A. de C., Gonçalves, W., Santos, M., & Matsubara, E. (2021). Convolutional neural networks to estimate dry matter yield in a guineagrass breeding program using UAV remote sensing. *Sensors*, 21(12).
<https://doi.org/10.3390/s21123971>
- Farías Reyes, J. C. (2025). Joel Vargas Domínguez, Cuerpos anormales. Metabolismo y alimentación en el México posrevolucionario [Reseña de libro]. Oficio. *Revista de Historia e Interdisciplina*, 2.
<https://doi.org/10.15174/orhi.vi21.16>
- Fierro Cordero, J. C. (2018). *Evaluación de la producción y valor nutricional del pasto Mombaza (Panicum maximum c.v) en diferentes edades y alturas de corte en la zona de Babahoyo*. [Trabajo de titulación, Universidad Técnica de Babahoyo].
<https://dspace.utb.edu.ec/server/api/core/bitstreams/bf22cc62-d059-41dc-93ea-efc-2c54ae1c3/content>
- Instituto Nacional de Estadística y Censos. (2024). Encuesta de Superficie y Producción Agropecuaria Continua (ESPAC) 2024. INEC.
- Lery, E. L. (2016). *Entrenamiento en técnicas de laboratorio para la determinación de fibra detergente ácida y fibra detergente neutra*. [Material de capacitación, Universidad Nacional del Nordeste].
<https://repositorio.unne.edu.ar/server/api/core/bitstreams/c05c8b4d-2a5a-423b-b0e7-711da-8fb1bca/content>

- Montero, C. W. D. (2021). *Análisis gravimétrico* [Material académico, Universidad Nacional de Educación Enrique Guzmán y Valle].
<https://repositorio.une.edu.pe/server/api/core/bitstreams/85b5038d-6e75-45e7-a459-12ed8e190273/content>
- Ospina, O., Anzola, H., Ayala, O., Baracaldo, A., Arévalo, J., & Lozada, P. (2021). Comparison between red, green and blue images and near-infrared spectroscopy methods in the neutral detergent fiber (NDF) analysis. *Revista de Investigaciones Veterinarias del Perú*, 32(1), 5.
<https://doi.org/10.15381/RIVEP.V32I1.17498>
- Ospina, O., Anzola Vásquez, H., Duarte, O. A., & Baracaldo Martínez, A. (2020). Validation of an algorithm for processing red green blue (RGB) images for the estimation of crude protein in grasses vs. near infrared reflectance spectroscopy technology (NIRS). *Revista de Investigaciones Veterinarias del Perú*, 31(2), 4.
<http://www.scielo.org.pe/pdf/rivep/v31n2/1609-9117-rivep-31-02-e17940.pdf>
- Ospina Rivera, O. F., Anzola Vásquez, H. J., Ayala Duarte, O. A., Baracaldo Martínez, A., Arévalo Cantor, J. S., Benavides Arciniegas, I., Benavides Perez, D. E., & Galvis Enriquez, G. A. (2021). Producción de leche real vs la calculada a partir de la enl estimada por el algoritmo de análisis de imágenes red-green-blue de gramíneas. *Ciencia Rural*, 51(2), 1–6.
<https://doi.org/10.1590/0103-8478cr20200551>
- Ospina Rivera, O. F., Baracaldo Martínez, A., & Anzola Vásquez, H. J. (2024). Validación de la estimación porcentual de K, P, Ca, Mg y S en la materia seca de gramíneas calculadas mediante un algoritmo de análisis de imágenes rojo, verde y azul RGB. *Revista de Investigaciones Veterinarias del Perú*, 35(3), e25341.
http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S1609-91172024000300002
- Páez Ordóñez, P. A., & Ortiz Burbano, Y. D. (2015). *Evaluación de los métodos analíticos usados en el laboratorio de análisis químico y aguas de la Universidad de Nariño para determinar fósforo total en aguas y lixiviados con base en la NTC-ISO/IEC 17025 : 2005*. [Trabajo de grado, Universidad de Nariño].
<https://sired.udenar.edu.co/2818/1/91352.pdf>
- Peñaloza, D. J., Barúa, M. G., Escalada, J. P., & Pajares, A. M. (2023). Técnica espectroscópica de absorción atómica para determinaciones en química ambiental. *Informes Científicos Técnicos - UNPA*, 15(3), 157–176.
<https://doi.org/10.22305/ict-unpa.v15.n3.987>

Pesantez Muñoz Edu Beбето. (2024). Identificación de deficiencias nutricionales en pasto *Brachiaria* sp., mediante fotografía espectral [Trabajo de titulación, Universidad Laica Eloy Alfaro de Manabí Extensión El Carmen].

<https://repositorio.ulearn.edu.ec/handle/123456789/6391>

TaurusWebs. (2025). *Calibración de cámaras de drones*. <https://tauruswebswp.com/soporte/>

Universidad de Zaragoza. (2024). *Protocolo de análisis físico - químico*.

https://ocw.unizar.es/ocw/pluginfile.php/6377/mod_folder/content/0/An%C3%A1lisis%20composici%C3%B3n/Determinacion%20de%20proteinas.pdf

Comparison between TaurusWebs and a laboratory

for the bromatological analysis of Rodas grass (Pennisetum sp.): A case study in Santa Ana

Victoria Delgado Tejena¹

Denzel Chevez Paredes²

Diego Nevárez Pérez³

¹Universidad Laica Eloy Alfaro de Manabí, Facultad Ciencias de la Vida Tecnológicas, Manta, Ecuador,
<https://orcid.org/0009-0002-6610-1237>
victoriadelte2002@gmail.com

²Universidad Laica Eloy Alfaro de Manabí, Facultad Ciencias de la Vida Tecnológicas, Manta, Ecuador,
<https://orcid.org/0009-0006-9491-8876>
chevezparedesdenzelandres@gmail.com

³Universidad Laica Eloy Alfaro de Manabí, Facultad Ciencias de la Vida Tecnológicas, Manta, Ecuador,
<https://orcid.org/0000-0002-0336-2862>
diego.nevarez@uleam.edu.ec

DOI: 10.61854/rccedia.v1n1.003

Sent: February 16, 2026

Approved: April 27, 2026

Published: Tuesday, July 14, 2026



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

Abstract

The purpose of this study is to compare the results of the Rodas grass (*Pennisetum* sp.) trial, utilizing TaurusWebs software, with those obtained using traditional laboratory methods, emphasizing on the variables protein, dry matter, net lactation energy, neutral detergent fiber, acid detergent fiber, and minerals. The research was conducted in two defined grassland areas in the Santa Ana canton, Manabí province, where an experimental design based on three samplings during periods of 15, 30, and 45 days was applied. The study considered various light conditions and three capture altitudes (20, 50, and 100 m a.s.l.) to evaluate the accuracy of the response to environmental variability.

According to statistical runs, it is concluded that image analysis software is a viable and efficient tool for estimating protein, dry matter, and minerals in Rodas grass. However, limitations were identified in the prediction of energy and fiber fractions. These discrepancies do not invalidate the tool but rather stem from intrinsic differences between spectroscopy and laboratory chemical methods. On the other hand, its use should be seen as a support to the traditional method, especially when measuring fiber, because the values can vary greatly due to the way the processing algorithms work. These findings underscore the importance of promoting the use of digital technologies in local livestock management, optimizing nutritional decision-making in an agile and economical manner.

Keywords:

comparative analysis, near-infrared spectroscopy, detergent fiber, forages, crude protein, nutritional value.

Introduction

In Ecuador, the province of Manabí ranks first in terms of cattle population, with approximately 711,011 live animals. However, according to data from the Continuous Agricultural Area and Production Survey (ESPAC), productivity in relation to land area is 1.00 head/ha, a figure that is lower than those reported for Guayas, Los Ríos, El Oro, and Esmeraldas. This places the province seventeenth nationwide, highlighting the need to improve the efficient management of forage resources in the livestock sector, which remains the main challenge for the economic sustainability of cattle production (National Institute of Statistics and Census - INEC, 2024).

Fierro Cordero (2018) states:

In Ecuador, one of the main problems in pasture management is the lack of knowledge regarding the species being used, which leads to inappropriate pasture utilization and prevents the achievement of optimal production results. This is compounded by deficiencies in soil nutrients, the lack of irrigation systems, and the use of species that are not adapted to local agroecological conditions, all of which contribute to the shortage of forage dry matter during certain times of the year (p. 10).

In the Santa Ana canton, livestock production depends directly on the nutritional quality of pastures; however, there is a marked deficiency in the technical monitoring of these resources. As a result, Rodas grass (*Pennisetum* sp.) is utilized without accurate bromatological support, leading

to inadequate supplementation and unnecessary increases in production costs per unit of output.

The motivation for this research arises from the need to validate technological alternatives that facilitate decision-making in the field. Traditionally, forage characterization has relied on laboratory analysis, which, although considered the reference method for accuracy, requires financial and time investments that many local producers cannot afford on a regular basis. In this context, the implementation of Livestock 4.0 tools, specifically the TaurusWebs software, represents an innovative solution. The central objective of this study is to determine whether digital nutrient estimation can provide results comparable to those obtained through conventional laboratory methods under the specific conditions of Santa Ana.

To address this issue, the general objective of this study is to conduct a comparative bromatological evaluation of Rodas grass (*Pennisetum* sp.) by comparing data generated by the TaurusWebs software with laboratory results. To achieve this objective, specific goals were established to complement the quantification of key variables, including crude protein, dry matter, energy, neutral detergent fiber, acid detergent fiber, and minerals, with the aim of determining the reliability of this technological tool under local conditions.

The quantification of the forage nutritional components required the application of specific analytical protocols for each variable evaluated. Crude protein content was determined using the Kjeldahl method, based on the distillation of total nitrogen in the sample. Gravimetric techniques were used to determine crude fat, moisture con-

tent, and ash percentage by measuring weight differences after subjecting the samples to controlled thermal treatments. Carbohydrates were also determined in the laboratory through indirect calculation, and this value was subsequently used to estimate the forage's energy contribution.

To strengthen the comparison with the TaurusWebs software, additional analyses of neutral detergent fiber (NDF) and acid detergent fiber (ADF) were incorporated. These parameters, which are essential for estimating the digestibility of Rodas grass (*Pennisetum* sp.), were processed according to gravimetric principles (Van Soest method), thereby maintaining methodological consistency and the rigor required to validate the accuracy of digital systems against conventional laboratory standards. For minerals present in the grass, including sodium, potassium, calcium, iron, magnesium, copper, zinc, and manganese, the flame atomic absorption (AA) spectroscopy technique, also used for heavy metal determination, was applied.

The TaurusWebs platform integrates analytical capabilities based on the principles of near-infrared spectroscopy (NIRS) for the estimation of bromatological components. This process is based on data acquisition through airborne sensors mounted on the drone, which captures spectral information using RGB algorithms. This technology decomposes the light reflected by the Rodas grass canopy into its three primary color bands—Red, Green, and Blue—allowing the system to interpret wavelengths associated with photosynthetic activity and vegetative vigor in order to estimate the nutritional value of the forage. The NIRS method is capable of providing reliable estimates of nutritional composition, including neutral detergent fiber, acid detergent fiber, protein, dry matter, and other components (Ariza Nieto, 2018).

This research is based on the hypothesis that there are no statistically significant differences between the values reported by the two evaluation methods. If this assumption is confirmed, a rapid and low-cost diagnostic methodology is proposed for the livestock sector in Santa Ana, enabling the optimization of animal diets and improving the competitiveness of local farms.

Methods

The study was conducted in the Santa Ana canton, located in the central-western area of the province of Manabí, Republic of Ecuador. The area selected for the analysis of Rodas grass is geographically located at 1°12' South latitude and 80°22' West longitude, at an approximate elevation of 50 m above sea level. This environment presents the typical agroecological conditions of the region, characterized by a climate that directly influences the bromatological composition of the forages evaluated in this study.

The area has distinct dry and rainy seasons. It has a humid tropical climate with a mean annual temperature of 26°C. Annual precipitation ranges from 500 mm to 1,000 mm. The study site covers an area of 6 hectares and 56 square meters.

Sampling design

To ensure data quality, the drone camera's white balance was calibrated by setting the value to 5,200 K. This adjustment is essential for standardizing image acquisition and must be adapted to the technical specifications of the aircraft used, as recommended by the software (TaurusWebs, 2025), thereby avoiding chromatic interference during image acquisition.

Data collection was carried out in two plots within the same field by capturing images at three altitude levels: 20, 50, and 100 meters. These flights were conducted under clear-sky conditions and stable solar illumination in order to prevent the formation of cast shadows that could introduce irregularities or bias into the bromatological image processing.

To determine the most appropriate time window for multispectral data acquisition, three sampling times were established: 10:00, 14:00,

and 17:00 hours, specifically on days 30 and 45 of the crop cycle. The evaluation at day 15 was omitted for this schedule, and only one image was captured at each altitude after determining that vegetation cover density was insufficient for a representative analysis.

Because the software generated a greater volume of data than the frequency of the chemical analyses, daily averages were calculated for each evaluated variable. This normalization procedure aligned the granularity of the digital information with the laboratory reports, which provided a single value for each sampling day. This adjustment was essential to strengthen the statistical analysis framework and ensure consistency in the comparison between the two methodologies.

Image analysis was performed individually to determine protein content, dry matter, net energy for lactation (MJ/kg), neutral detergent fiber (NDF), and acid detergent fiber (ADF). In addition, microminerals (Cu, Fe, Zn, Mn, B) and macrominerals (K, P, Ca, S, Mg) present in the dry matter of the grasses were quantified. This procedure was carried out using mathematical algorithms incorporated into the software, which are decoded through the RGB bands provided by the images captured by the drone.

This approach enables the interpretation of the reflectance of wavelengths associated with photosynthetic activity in chloroplasts, facilitating the indirect estimation of nutrient and mineral concentrations in plant tissue. Pesantez (2024) indicates that spectral images captured by conventional RGB cameras have enabled the monitoring of vegetation status, land cover analysis, and the identification of different types of stress, including both water and nutritional stress (p. 17).

Laboratory sample collection

For laboratory sampling, GPS coordinates were established within the two Rodas grass plots, which were georeferenced using a drone. This procedure was carried out to ensure a precise and reliable comparison between the results obtained from both analytical methodologies.

Before collecting the grass samples, the image captured at an altitude of 100 meters was initially processed using the corresponding software. This processing made it possible to identify the area of the crop with the best conditions. Within the software, the image is displayed using color bands, where areas with greater vegetative vigor are represented by an intense green color; however, these areas were verified to ensure that they actually corresponded to the crop under study.

Once the most representative area of the pasture had been selected, sample collection was carried out. A total of six samples were collected and then thoroughly mixed to form a composite sample. This composite sample was subsequently stored in a hermetically sealed polystyrene bag for shipment and laboratory analysis.

Each sample was properly labeled with the exact coordinates of the collection point and received the appropriate treatment in accordance with the laboratory's requirements. The amount of material collected depended on the specifications established by the CESECCA laboratory, which required a total of 200 grams of sample per plot.

This procedure was carried out during the three sampling events corresponding to the two scheduled days. On these occasions, the preliminary software analysis was omitted for sampling events 2 and 3 in order to maintain a continuous record and minimize potential errors during sam-

ple collection. In addition, a single fixed sector was defined for sample collection.

For the mineral, ADF, and NDF analyses, one kilogram of biomass was collected per plot, complying with the sample submission requirements of the Agrocalidad laboratories in Tumbaco. The samples were hermetically sealed and transported under refrigerated conditions. This procedure was performed only during the final phase of the study to complement the comparison of data with the advanced functions of the software, since these specific analyses were not available at the CESECCA laboratory.

To obtain the results, several analytical methods were used. The percentage of crude protein was determined using the Kjeldahl method, a chemical analytical procedure that quantifies the total nitrogen content of the sample. As explained by the University of Zaragoza (2024), this technique involves "digesting the proteins and other organic components of food in a mixture with sulfuric acid in the presence of catalysts" (p. 2). In this way, the nitrogen content of the grass allows the calculation of its crude protein content.

The quantitative determination of the ether extract fraction (crude fat) and the moisture content of the forage was based on gravimetric analysis. Specifically, the volatilization method was applied, which consists of accurately measuring the variation in sample mass after the removal of volatile components through controlled thermal treatments in a muffle furnace and drying oven. This procedure made it possible to isolate and quantify each residue with the rigor required for subsequent statistical comparison with the digital estimates. Montero (2021) states that "the strategy is modified if the analyte is volatilized and its accumulation after volatilization is measured; sub-

sequently, the weight loss is related to the analyte that has been volatilized" (p. 20).

Dry matter was determined using the classical gravimetric method, an analytical chemistry procedure standardized by the AOAC (Association of Official Analytical Chemists). The calculation was performed by subtracting the moisture percentage from the total sample (100%), representing the sum of the solid components of the grass: carbohydrates, dry matter, ash, and crude protein, following the protocols established by the CESECA laboratory.

To estimate the energy content of the forage, the laboratory used the formula developed by Wilbur Olin Atwater, a pioneer in nutrition in the United States who focused on livestock and agricultural research (Fariás Reyes, 2025, p. 2). This mathematical model is based on the principle of energy conservation and uses the percentages of protein, fat, and carbohydrates as the main variables. The equation used was: $\text{Energy} = 4(\%P) + 9(\%G) + 4(\%C)$. For the determination of ADF and NDF, the Van Soest detergent method was used. This fractionation process employs specific detergent solutions to quantify the structural components of the cell wall (Sniffen, 1992, as cited in Lery, 2016, p. 3).

According to Lery (2016), sample processing began with registration, drying, and grinding, after which the samples were transferred to vegetable filter paper bags. For the determination of NDF, a neutral detergent solution (NDS), composed of distilled water, lauryl sulfate, sodium sulfate, disodium phosphate, and 2-ethoxyethanol, was added. The mixture was boiled for one hour on a heating plate while maintaining a constant volume by adding distilled water. Subsequently, the samples were dried in an oven to quantify the final residues. An analogous method was used to determine ADF, replacing the reagent with an acid detergent solution (ADS), which contains 1N

sulfuric acid and cetyltrimethylammonium bromide (Lery, 2016).

To broaden the comparison between the variables analyzed by the software and the empirical data, complementary mineral analyses were performed at the Agrocalidad laboratory using samples collected on day 45. Allende Céspedes (2024) indicates that the DUMAS method, based on the complete combustion of the sample, was used to determine nitrogen. This process was carried out in a furnace at 950 °C for 2.8 minutes, followed by transfer to a sealed purge chamber. Combustion generates a gaseous mixture that is homogenized in a ballast chamber, from which a representative portion is extracted for final detection by the analyzer.

For phosphorus quantification, the colorimetric method was used (Páez Ordóñez & Ortiz Burbano, 2015) that states:

According to the literature, the standard method for phosphate determination is based on the reaction of phosphorus with molybdenum and antimony ions to form a complex, which can be reduced using stannous chloride or ascorbic acid, producing a characteristic blue color that can be detected by colorimetry (p. 41)

The remaining elements (K, Ca, Mg, Fe, Mn, Cu, and Zn) were determined by atomic absorption spectroscopy. According to Peñaloza (2023), this procedure consists of introducing the liquid sample into the instrument's nebulizer, where it is carried to the flame and transformed into free atoms. The air-acetylene flame reaches approximately 2,300 °C, a temperature sufficient for the atomization of various elements. However, to achieve higher thermal energy, a nitrous oxide-acetylene mixture may be used, capable of producing temperatures close to 2,900 °C. Once the free atoms are in the gaseous state,

they are exposed to the thermal radiation emitted by the hollow cathode lamp (constructed from a glass tube containing an inert gas such as neon or argon).

The fraction of radiation that is not absorbed continues its path to the detector. During this process, electrons absorb energy and temporarily move to a higher energy level. By measuring the difference between the emitted and detected energy at a specific wavelength, the absorbed radiation is quantified using the Lambert–Beer law, thereby establishing a direct relationship between the measured signal and the concentration of the analyzed element (Peñaloza, 2023).

Experimental design

The present study was based on the comparison of two analytical systems applied to the same experimental units, with the aim of evaluating the agreement or differences between the methods. This technical design enabled a direct comparison between the digital estimates generated by TaurusWebs and the laboratory chemical reports, with the objective of determining the efficiency of each tool and its actual impact on optimizing the economic resources of livestock producers in the Santa Ana canton.

For data processing, the comparison between both methods was performed using Student's t-test for paired samples. This statistical tool made it possible to determine the presence or absence of significant differences between the results obtained by the two methods, thereby providing a precise bromatological assessment of the forage by identifying possible discrepancies between the measurements.

The variables included in the study were as follows:

- Dependent variable: bromatological analysis results of Rodas grass (*Pennisetum* sp.), expressed as percentages of crude protein, dry matter, and net energy for lactation.
- Independent variable: bromatological analysis performed by laboratory methods and by the TaurusWebs software.

Results

Table 1

Comparison of average bromatological parameters in Plot 1

Day	Method	Protein (%)	NDF (%)	ADF (%)	Dry matter (%)	Energy (NEL) MJ/kg
15	TaurusWebs	7,25	64,96	35,20	18	3,95
30	TaurusWebs	10,74	61,42	33,59	18	4,39
45	TaurusWebs	19,11	51,59	22,65	18	5,42
15	Laboratory	2,56			12,12	0,18
30	Laboratory	2,20			10,91	0,15
45	Laboratory	2,51	91,31	56,07	19,96	0,29

The comparative bromatological results presented in Table 1 reveal substantial discrepancies between the estimates generated by the TaurusWebs software and the analytical laboratory determinations. Regarding the protein fraction, the software projected an atypical increase, reaching 19.11% on day 45, whereas the chemical analysis reported significantly lower and more stable values (mean 2.42%), indicating a theoretical overestimation by the digital model.

This trend becomes even more pronounced in the structural components of the cell wall. On day 45, the gravimetric laboratory method recorded critical values of 91.31% for NDF and 56.07% for ADF, in contrast to the lower fiber contents predicted by the software (51.59% and 22.65%,

respectively). This divergence is explained by methodological differences: TaurusWebs operates using predictive mathematical models that, in this study, demonstrated limitations in extrapolating the actual lignification kinetics under field conditions. In contrast, the laboratory method (Van Soest) is gravimetric in nature, enabling the physical quantification of the structural components of the cell wall.

A critical point of variation was observed in dry matter, where the software maintained a constant parametric value of 18%. This homogeneity reflects the use of preconfigured or default values based on averages from standard nutritional tables. However, the chemical analysis identified moisture fluctuations, with dry matter values of

12.12% on day 15 and 19.96% on day 45. These analytical differences directly affected the calculation of net energy for lactation (NEL); whereas the software projected a progressive increase from 3.95 MJ/kg to 5.42 MJ/kg based on its estimate of

lower fiber content, the laboratory determined an increase from 0.18 MJ/kg to 0.29 MJ/kg, because ADF (lignin) mathematically penalizes digestibility and energy availability.

Table 2

Student's t-test for protein determined by both methodologies, Plot 1

Day	Software analysis (A)	Laboratory analysis (B)	A-B	(A-B) ²
15	7,25	2,56	4,69	22
30	10,74	2,20	8,54	72,93
45	19,11	2,51	16,60	275,56
Σ	32,1	7,27	29,83	370,49
$\bar{x}$	12,37	2,42	9,94	123,50
S ²	√S ²	DF	Tukey values	t
12,31	3,51	2	0,05 = 4,303 0,01 = 9,925	2,83

To determine the reliability of Livestock 4.0 tools compared with conventional methods, a Student's t-test for paired samples was applied. The protein content obtained using the software (A) was compared with that obtained by laboratory analysis (B). For this analysis, the values recorded by the software on days 15, 30, and 45 were averaged to obtain a representative value for each stage, allowing direct comparison with the laboratory results.

The statistical results showed a calculated t value (2.83) lower than the critical values established for the 5% (4.303) and 1% (9.925) significance levels. Consequently, the hypothesis of similarity between the software estimates and the laboratory analyses was accepted for the evaluated parameter.

Table 3
Student's t-test for dry matter determined by both methodologies, Plot 1

Day	Software analysis (A)	Laboratory analysis (B)	A-B	(A-B) ²
15	18	12,12	5,88	34,57
30	18	10,91	7,09	50,27
45	18	19,96	-1,96	3,84
Σ	54	42,99	11,01	88,68
$\bar{x}$	18	14,33	3,67	29,56
S^2	$\sqrt{S^2}$	DF	Tukey values	t
8,04	2,84	2	0,05 = 4,303 0,01 = 9,925	1,29

The software analysis (A) showed complete stability, maintaining a constant value of 18 throughout the three sampling days, whereas the laboratory analysis (B) exhibited substantial variation, with a mean value of 14.33. Although

an arithmetic difference was observed, the data indicate that there is no statistical evidence to conclude that one method is superior to the other or that they systematically produce different results.

Table 4

Student's t-test for energy (MJ/kg) determined by both methodologies, Plot 1

Day	Software analysis (A)	Laboratory analysis (B)	A-B	(A-B) ²
15	3,9	0,18	3,72	13,84
30	4,4	0,15	4,25	18,06
45	5,40	0,29	5,11	26,11
Σ	13,7	0,62	13,08	58,01
$\bar{x}$	4,57	0,21	4,36	19,34
S^2	$\sqrt{S^2}$	GL	Tukey values	t
0,16	0,41	2	0,05 = 4,303 0,01 = 9,925	10,77

When comparing energy yield using the two proposed methodologies, it was determined that the software and laboratory did not produce equivalent results. The calculated t value (10.77) exceeded the critical reference values for the 5% and 1% Tukey confidence

levels. Consequently, the hypothesis of equality was rejected, and it was concluded that there is a statistically significant difference between the two analytical methods during the 15-, 30-, and 45-day evaluation periods.

Table 5
Comparison of ADF and NDF results on day 45, Plot 1

Day	Method	NDF	ADF
45	TaurusWebs	51,60	22,70
45	Laboratory	91,31	56,07

Additionally, neutral detergent fiber (NDF) and acid detergent fiber (ADF) were determined during the final sampling stage (day 45). When

both methodologies were compared in Table 5, a substantial discrepancy was identified in the absolute values obtained.

Table 6
Comparison of average mineral parameters in Plot 1 on day 45

Day	Method	Ca (%)	P (%)	Mg (%)	K (%)	Cu (%)	Fe (mg/kg)	Zn (mg/kg)	Mn (mg/kg)	N (%)
45	TaurusWebs	0,32	0,40	0,16	4,28	6,35	164	29,11	50,56	3,06
45	Laboratory	0,22	0,17	0,15	2,62	9	170	28	51,50	2,13

The mineral analysis conducted on the farm in Santa Ana made it possible to identify the elemental composition of Rodas grass, a key factor in the metabolic balance of livestock. Relative stability was observed among the macronutrients, with average levels of calcium (0.32%), phosphorus (0.40%), magnesium (0.16%), potassium (4.28%), and nitrogen (3.06%). Likewise, the software identified the presence of micronutrients such as iron (164

mg/kg), zinc (29.11 mg/kg), and manganese (50.56 mg/kg). Compared with the laboratory results, it was found that the estimated values were not substantially different from the measured values. The laboratory reported calcium (0.22%), phosphorus (0.17%), magnesium (0.15%), potassium (2.62%), and nitrogen (2.13%), while the micronutrient analysis identified iron (170 mg/kg), zinc (28 mg/kg), and manganese (51.50 mg/kg).

Plot 2

In Plot 2, the evaluation of Rodas grass using the TaurusWebs software showed an increasing trend in nutrient concentration as the phenological cycle progressed. On day 15, an initial average crude protein content of 4.20% was recorded, which increased significantly to 16.61% by the end of the 45-day period.

As in Plot 1, a marked discrepancy was observed when these data were compared with the laboratory analyses, particularly during the final stages of crop development. While the software estimated protein levels above 16%, the chemical method reported a concentration of 2.85% on day 45. A similar discrepancy was observed for net energy for lactation (NEL), where the digital system projected 5.11 MJ/kg compared with the 0.33 MJ/kg validated by laboratory analysis.

Table 7
Comparison of average bromatological parameters in Plot 2

Day	Method	Protein (%)	NDF (%)	ADF (%)	Dry matter	Energy (NEL) MJ/kg
15	TaurusWebs	4,20	68,41	35,14	18	3,57
30	TaurusWebs	10,89	60,86	33,54	18	4,40
45	TaurusWebs	16,61	54,41	26,98	18	5,11
15	Laboratory	2,91			9,66	0,14
30	Laboratory	2,03			16,57	0,24
45	Laboratory	2,85	92,61	56,57	22,37	0,33

With respect to the fiber fraction, the laboratory determined values of 92.61% for NDF and 56.57% for ADF. These values greatly exceeded

the software estimates, reinforcing the hypothesis regarding the spectral interpretation performed by the RGB algorithm.

Table 8

Student's t-test for protein determined by both methodologies, Plot 2

Day	Software analysis (A)	Laboratory analysis (B)	A-B	(A-B) ²
15	4,20	2,91	1,29	1,66
30	10,89	2,03	8,86	78,50
45	16,61	2,85	13,76	189,34
Σ	31,7	7,79	23,76	269,50
$\bar{x}$	10,57	2,60	7,97	89,83
S^2	$\sqrt{S^2}$	DF	Tukey values	T
13,15	3,63	2	0,05 = 4,303 0,01 = 9,925	2,20

The evaluation of protein content in Plot 2 did not show a critical discrepancy between the digital method and the laboratory analysis. After performing the statistical comparison, a test statistic of 2.20 was obtained. Since this value was below

the significance thresholds, it was concluded that the differences between the two methods were not statistically significant, indicating agreement between the reported results.

Table 9

Student's t-test for dry matter using both methodologies, plot 2

Day	Software analysis (A)	Laboratory analysis (B)	A-B	(A-B) ²
15	18	9,66	8,34	69,56
30	18	16,57	1,43	2,04
45	18	22,37	-4,37	19,10
Σ	54	48,6	5,40	90,70
$\bar{x}$	18	16,20	1,80	30,23
S ²	$\sqrt{S^2}$	DF	Tukey values	t
13,49	3,67	2	0,05 = 4,303 0,01 = 9,925	0,49

Using the same method, the dry matter content obtained by both diagnostic techniques was evaluated. The calculated t value (0.49) was

substantially lower than the minimum critical value (4.303); therefore, the analysis falls entirely within the acceptance region of the null hypothesis.

Table 10

Student's t-test for energy (MJ/kg) determined by both methodologies, Plot 2

Day	Software analysis (A)	Laboratory analysis (B)	A-B	(A-B) ²
15	3,57	0,14	3,43	11,76
30	4,4	0,24	4,16	17,31
45	5,11	0,33	4,78	22,85
Σ	13,08	0,71	12,37	51,92
$\bar{x}$	4,36	0,24	4,12	17,31
S ²	$\sqrt{S^2}$	DF	Tukey values	T
0,15	0,39	2	0,05 = 4,303 0,01 = 9,925	10,57

The results for energy density (MJ/kg) show a critical divergence between the two methods. The calculated test statistic (10.57) is well above

the Tukey critical values, requiring rejection of the null hypothesis of equality.

Table 11

Comparison of ADF and NDF results on day 45, Plot 2

Day	Method	NDF	ADF
45	TaurusWebs	54,41	26,98
45	Laboratory	92,61	56,57

Neutral detergent fiber (NDF) and acid detergent fiber (ADF) were evaluated during the final stage of the sampling process. The comparison revealed a substantial bias between the values

obtained, indicating poor agreement between the laboratory determinations and the software estimates.

Table 12

Comparison of average mineral parameters in Plot 2 on day 45

Day	Method	Ca (%)	P (%)	Mg (%)	K (%)	Cu (%)	Fe (mg/kg)	Zn (mg/kg)	Mn (mg/kg)	N (%)
45	TaurusWebs	0,33	0,36	0,19	3,46	5,66	138	28,44	55,89	2,66
45	Laboratory	0,19	0,18	0,14	2,38	8,5	127	36,49	12,15	1,87

The analysis of inorganic components in Plot 2 established a profile of essential nutrients for cattle. Average concentrations of calcium (0.33%), phosphorus (0.36%), magnesium (0.19%), potassium (3.46%), and nitrogen (2.66%) were determined. The software also identified the presence of micronutrients such as iron (138 mg/kg), zinc (28.44 mg/kg), and manganese (55.89 mg/kg). Compared with the laboratory results, the estimated values were found to be reasonably close to the measured values. The laboratory repor-

ted calcium (0.19%), phosphorus (0.18%), magnesium (0.14%), potassium (2.38%), and nitrogen (1.87%), while the micronutrient analysis identified iron (127 mg/kg), zinc (36.49 mg/kg), and manganese (12.15 mg/kg).

These indicators are essential for livestock producers in Santa Ana, as they make it possible to correlate soil quality with the nutritional value of Rodas grass, facilitating the design of site-specific fertilization or mineral supplementation plans.

Figures



Figure 1

Farm polygon of Hernán Mieles Moreira.

Note. To perform the bromatological analysis of Rodas grass, sampling units were selected within the total area of the farm (Figure 1). Biomass collection was specifically conducted in Plot 1, covering 1.98 hectares, and Plot 2, covering 1.00 hectare. This subdivision of the farm, located in Santa Ana canton, made it possible to capture

forage variability under real field conditions, facilitating the correlation between the farm's spatial management and the nutritional indicators obtained from laboratory analyses and the software.

Plot 1




Figure 2

Bromatological analysis at 100 m altitude

Note. The sequence comprising Figures 2 to 9 illustrates the remote sensing and digital processing workflow applied in the study. These figures show the terrain morphology and foliage density through aerial images captured at altitudes of 100 m, 50 m, and 20 m. The graphical

sequence demonstrates the integration of these images into the TaurusWebs software, where data interpretation was performed to estimate the bromatological and mineral parameters of Rodas grass in Santa Ana canton.




Figure 3

Bromatological analysis at 50 m altitude

Note. Image captured at an intermediate altitude to evaluate biomass resolution and its impact on the accuracy of digital estimates. Pro-

cessing was performed using the TaurusWebs platform, following the methodological procedures described above.




Figure 4

Bromatological analysis at 20 m altitude

Note. High-resolution image allowing a detailed assessment of forage density and quality in the study plots.




Figure 5

Mineral analysis

Note. Processed image used to identify specific mineral concentrations.




Figure 6

Bromatological analysis at 100 m altitude in Plot 2

Note. Aerial image of the selected area used to validate the bromatological profile in the TaurusWebs software.




Figure 7

Bromatological analysis at 50 m altitude.

Note. Multispectral image used to compare the nutritional levels of Rodas grass.




Figure 8

Bromatological analysis at 20 m altitude.

Note. Image used to validate the nutritional parameters of Rodas grass in TaurusWebs.




Figure 9

Mineral analysis.

Note. Image used to complement the study of the mineral parameter of Rodas grass.




Figure 10

Comparison of protein levels in Plot 1: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 11

Comparison of dry matter levels in Plot 1: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 12

Comparison of energy levels in Plot 1: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 13

Comparison of NDF and ADF levels in Plot 1: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 14

Comparison of mineral levels in Plot 1: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 15

Comparison of protein levels in Plot 2: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 16

Comparison of dry matter levels in Plot 2: digital estimates from TaurusWebs software vs. instrumental laboratory analysis

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 17

Comparison of energy levels in Plot 2: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas Grass.




Figure 18

Comparison of NDF and ADF levels in Plot 2: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.




Figure 19

Comparison of mineral levels in Plot 2: digital estimates from TaurusWebs software vs. instrumental laboratory analysis.

Note. The values shown in the bars correspond to the results obtained from the sampling conducted within the same management unit in Santa Ana. The visual difference between

the software and the laboratory makes it possible to evaluate the research hypothesis regarding the accuracy of digital tools for the analysis of Rodas grass.

Equations

Null Hypothesis

$$H_o = V_A = V_B$$

Alternative Hypothesis

$$H_a = V_A \neq V_B$$

Variance

$$S^2 = \frac{\Sigma D^2 - \frac{(\Sigma D)^2}{n}}{n(n-1)}$$

Standard Deviation

$$\sqrt{S^2}$$

Degrees of Freedom

$$df = n_r - 1$$

Student's t-Test

$$t = \frac{\bar{X} D}{S}$$

Discussion

The comparative study of the application of crude protein (CP), dry matter (DM), and net energy for lactation determination techniques demonstrated that there are differences between the values obtained from the analyses performed using both methodologies, columns A and B, as shown in Tables 2, 3, and 4 for Plot 1 and Tables 8, 9, and 10 for Plot 2. This is due to the inherent nature of the conventional analytical procedures performed in the laboratory, namely the Kjeldahl method and gravimetry, whereas the TaurusWebs software relies on RGB image processing algorithms.

Despite the differences in the analytical procedures, the application of Student's t-test made it possible to determine, through the rigorous Tukey comparison (0.05 and 0.01), that there were no significant differences between the results obtained on the three sampling days for the protein and dry matter variables. This indicates that, despite the differences in physicochemical and algorithmic principles, there is agreement between the estimates in the case of Rodas grass (*Pennisetum* sp.).

These results are consistent with those reported by Ospina (2020), who evaluated the correlation between remote sensing techniques and laboratory (NIRS) analysis. In that study, using non-parametric tests such as Kendall's correlation, Spearman's correlation, and the Kruskal-Wallis test (0.05), a high correlation and the absence of significant differences were demonstrated in the determination of protein parameters. This validates that indirect methods based on optical sensors or image-processing algorithms have comparative strengths relative to reference chemical methods (p. 4).

With respect to the determination of dry matter, the results exhibited variability between the methodologies employed. However, the statistical analysis showed the absence of significant differences, as detailed in Tables 3 and 9. It is worth noting that the values generated by the software remained remarkably constant throughout the three sampling phases; this is because the tool does not quantify moisture dynamically but instead operates using a preset parameter.

Since moisture is a determining factor for the calculation of dry matter by the gravimetric method, this characteristic of the algorithm could suggest a theoretical limitation. Nevertheless, the statistical evidence confirms that image processing using the software provides precision comparable to conventional methods under controlled conditions. These findings are consistent with those reported by de Oliveira et al. (2021), who indicate that high-resolution RGB images represent highly promising techniques for estimating dry matter yield in pastures.

The contrast coefficients detailed in the energy tables (4 and 10) are above the critical values established by Tukey. This discrepancy is based on the fact that the software identifies the actual amount of energy that the animal utilizes for milk production and maintenance (net energy for lactation), whereas the laboratory analysis provides the total (or gross) energy contained in the feed (grass).

In this regard, Ospina Rivera (2021) reported the existence of a correlation between laboratory results and those obtained through the TaurusWebs algorithm; this relationship was validated using Student's t-test, in which no significant differences were observed in net energy for

lactation (NEL). These previous findings confirm that both study methodologies are complementary and support the efficiency of the software in estimating the nutritional parameters of grass.

Although complete laboratory data were not available for neutral detergent fiber (NDF), acid detergent fiber (ADF), and the mineral composition of Rodas grass (*Pennisetum* sp.), these parameters were included in the final evaluation, allowing a basic comparison between both methodologies, as shown in Tables 5, 6, 11, and 12. In the case of NDF and ADF, differences between the values can be observed; however, Ospina (2021) indicated that “there is a high correlation between neutral detergent fiber (NDF) results calculated by near-infrared spectroscopy (NIRS) and RGB image analysis” (p. 5). These conclusions derive from studies aimed at evaluating the similarity between software-generated values and laboratory results calibrated using NIRS, supporting the findings obtained in this research.

Regarding acid detergent fiber (ADF), Ospina (2020), based on a comparative study between software and laboratory methodologies using NIRS as the analytical reference, states that “there is a strong correlation between ADF results calculated by NIRS and those obtained from RGB image analysis” (p. 7), reinforcing the reliability of estimates obtained through image-based tools.

The mineral profile of Rodas grass evaluated in the Santa Ana area shows a close correlation between the software estimates and laboratory determinations, particularly for minerals such as magnesium and zinc. This level of precision suggests that Livestock 4.0 databases are reliable tools for diagnosing these parameters in the region.

However, the variations observed in potassium and nitrogen levels between the two methods highlight the direct influence of local soil characteristics and fertilization management within the plot. The identification of these indicators is essential for the local livestock sector, as it enables a transition from generic to site-specific mineral supplementation. For example, the calcium and phosphorus levels detected provide a basis for designing mineral supplements that optimize the electrolyte balance of cattle in Santa Ana, minimizing economic losses and improving herd metabolic efficiency.

The stability observed in mineral levels between both methods can be attributed to the fact that the Agrocalidad laboratory employed techniques such as colorimetry and atomic absorption spectroscopy, which, like the software, are based on the interaction of light, either through chemical and energy composition or through image analysis.

The 2ARGB® algorithm and plasma induction spectroscopy (PIS) produce statistically equivalent results in the estimation of macrominerals (K, P, Ca, Mg, and S) in the dry matter of grasses. This finding, demonstrated by Ospina Rivera and Baracaldo Martínez (2024), validates digital image analysis as a precise, non-destructive alternative and supports the implementation of image analysis technologies alongside traditional laboratory methodologies. Consequently, these results reinforce the usefulness of the software for accelerating nutritional diagnosis and designing mineral supplementation or fertilization plans, provided that the data are calibrated according to the type of aircraft used and the lighting conditions of the study area.

Conclusions

The present study demonstrates that Livestock 4.0 tools, specifically those based on image processing algorithms such as TaurusWebs, constitute a viable alternative for nutritional monitoring. Following statistical analysis using Student's t-test, the following conclusions were reached:

- High-agreement parameters (protein and minerals): The absence of statistically significant differences between the digital model and the analytical chemical determination of crude protein and the mineral profile was confirmed. The stability observed in these indicators reinforces the reliability of the software for rapid field diagnosis, enabling informed decision-making regarding the nutritional status of Rodas grass (*Pennisetum* sp).
- Dry matter and biological variability: Although the software operated using constant parametric values (18%), the statistical analysis confirmed its similarity to the laboratory averages. Nevertheless, the gravimetric method was found to be superior in capturing fluctuations caused by environmental factors and the phenological stage, particularly by day 45 of sampling.
- Discrepancies in energy and fiber fractions (NDF/ADF): Statistically significant differences exceeding the critical reference values were identified for energy (NEL) and fiber parameters. These statistical discrepancies do not result from methodological inconsistency but rather from the intrinsic nature of the parameter evaluated in each case.

- Strengths of the optical model: The stability observed in mineral determination reinforces the theory that light interaction-based methods possess high comparative strength, positioning them as a valuable complement for monitoring in modern livestock production.

For future research, it is recommended that bromatological analyses be conducted in specialized centers that ensure rigorous instrument calibration, prioritizing the use of near-infrared spectroscopy (NIRS). This technology enables a smooth transition between chemical analyses and digital models because, by using wavelengths to identify specific chemical bonds, it reduces methodological discrepancies between laboratory analyses and software algorithms such as TaurusWebs.

Likewise, it is essential to standardize environmental conditions during data collection to minimize experimental error and optimize the performance of optical sensors. Measurements should be carried out on clear days between 09:00 and 16:00 hours, when solar stability and the zenith angle promote uniform canopy reflectance. This lighting precision is crucial for the software to process the information without interference caused by cloud cover or diffuse light, allowing the resulting nutritional quality indicators to achieve a high degree of reliability and thereby support informed decision-making.

Conflict of Interest Statement

The authors declare that they have no conflicts of interest.

Funding Statement

The authors declare that this research received no external funding from any public, commercial,

or non-profit funding agency.

Author Contributions (CRediT)

Victoria Anais Delgado Tejena: Conceptualization; methodology; software; validation; formal analysis; investigation; resources; data curation; writing – original draft; writing – review & editing; visualization; supervision; project administration.

Denzel Andrés Chevez Paredes: Conceptualization; methodology; software; validation; formal analysis; investigation; resources; data curation; writing – original draft; writing – review & editing; visualization; supervision; project administration.

Diego Javier Nevárez Pérez: Conceptualization; methodology; software; validation; formal analysis; investigation; resources; data curation; writing – original draft; writing – review & editing; visualization; supervision; project administration.

References

- Allende, E. E. B. (2024). *Funciones desempeñadas como analista de laboratorio instrumental en la empresa Société Générale De Surveillance S.A.* – Lima, optimizando métodos para la caracterización eficiente de matrices de harina de pescado y otros [Trabajo de titulación, Universidad Nacional Pedro Ruiz Gallo].
<https://repositorio.unprg.edu.pe/handle/20.500.12893/12801>
- Ariza Nieto, C., Mayorga, O. L., Mojica, B., Parra, D., & Afanador-Tellez, G. (2018). Use of LOCAL algorithm with near infrared spectroscopy in forage resources for grazing systems in Colombia. *Journal of Near Infrared Spectroscopy*, 26(1), 44–52.
<https://doi.org/10.1177/0967033517746900>
- de Oliveira, G. S., Junior, J. M., Polidoro, C., Osco, L. P., Siqueira, H., Rodrigues, L., Jank, L., Barrios, S., Valle, C., Simeão, R., Carromeu, C., Silveira, E., Jorge, L. A. de C., Gonçalves, W., Santos, M., & Matsubara, E. (2021). Convolutional neural networks to estimate dry matter yield in a guineagrass breeding program using UAV remote sensing. *Sensors*, 21(12).
<https://doi.org/10.3390/s21123971>
- Farías Reyes, J. C. (2025). Joel Vargas Domínguez, Cuerpos anormales. Metabolismo y alimentación en el México posrevolucionario [Reseña de libro]. Oficio. *Revista de Historia e Interdisciplina*, 2.
<https://doi.org/10.15174/orhi.vi21.16>
- Fierro Cordero, J. C. (2018). *Evaluación de la producción y valor nutricional del pasto Mombaza (Panicum maximum c.v) en diferentes edades y alturas de corte en la zona de Babahoyo*. [Trabajo de titulación, Universidad Técnica de Babahoyo].
<https://dspace.utb.edu.ec/server/api/core/bitstreams/bf22cc62-d059-41dc-93ea-efc-2c54ae1c3/content>
- Instituto Nacional de Estadística y Censos. (2024). Encuesta de Superficie y Producción Agropecuaria Continua (ESPAC) 2024. INEC.
- Lery, E. L. (2016). *Entrenamiento en técnicas de laboratorio para la determinación de fibra detergente ácida y fibra detergente neutra*. [Material de capacitación, Universidad Nacional del Nordeste].
<https://repositorio.unne.edu.ar/server/api/core/bitstreams/c05c8b4d-2a5a-423b-b0e7-711da-8fb1bca/content>

- Montero, C. W. D. (2021). *Análisis gravimétrico* [Material académico, Universidad Nacional de Educación Enrique Guzmán y Valle].
<https://repositorio.une.edu.pe/server/api/core/bitstreams/85b5038d-6e75-45e7-a459-12ed8e190273/content>
- Ospina, O., Anzola, H., Ayala, O., Baracaldo, A., Arévalo, J., & Lozada, P. (2021). Comparison between red, green and blue images and near-infrared spectroscopy methods in the neutral detergent fiber (NDF) analysis. *Revista de Investigaciones Veterinarias del Perú*, 32(1), 5.
<https://doi.org/10.15381/RIVEP.V32I1.17498>
- Ospina, O., Anzola Vásquez, H., Duarte, O. A., & Baracaldo Martínez, A. (2020). Validation of an algorithm for processing red green blue (RGB) images for the estimation of crude protein in grasses vs. near infrared reflectance spectroscopy technology (NIRS). *Revista de Investigaciones Veterinarias del Perú*, 31(2), 4.
<http://www.scielo.org.pe/pdf/rivep/v31n2/1609-9117-rivep-31-02-e17940.pdf>
- Ospina Rivera, O. F., Anzola Vásquez, H. J., Ayala Duarte, O. A., Baracaldo Martínez, A., Arévalo Cantor, J. S., Benavides Arciniegas, I., Benavides Perez, D. E., & Galvis Enriquez, G. A. (2021). Producción de leche real vs la calculada a partir de la enl estimada por el algoritmo de análisis de imágenes red-green-blue de gramíneas. *Ciencia Rural*, 51(2), 1–6.
<https://doi.org/10.1590/0103-8478cr20200551>
- Ospina Rivera, O. F., Baracaldo Martínez, A., & Anzola Vásquez, H. J. (2024). Validación de la estimación porcentual de K, P, Ca, Mg y S en la materia seca de gramíneas calculadas mediante un algoritmo de análisis de imágenes rojo, verde y azul RGB. *Revista de Investigaciones Veterinarias del Perú*, 35(3), e25341.
http://www.scielo.org.pe/scielo.php?script=sci_arttext&pid=S1609-91172024000300002
- Páez Ordóñez, P. A., & Ortiz Burbano, Y. D. (2015). *Evaluación de los métodos analíticos usados en el laboratorio de análisis químico y aguas de la Universidad de Nariño para determinar fósforo total en aguas y lixiviados con base en la NTC-ISO/IEC 17025 : 2005*. [Trabajo de grado, Universidad de Nariño].
<https://sired.udenar.edu.co/2818/1/91352.pdf>
- Peñaloza, D. J., Barúa, M. G., Escalada, J. P., & Pajares, A. M. (2023). Técnica espectroscópica de absorción atómica para determinaciones en química ambiental. *Informes Científicos Técnicos - UNPA*, 15(3), 157–176.
<https://doi.org/10.22305/ict-unpa.v15.n3.987>

Pesantez Muñoz Edu Beбето. (2024). Identificación de deficiencias nutricionales en pasto *Brachiaria* sp., mediante fotografía espectral [Trabajo de titulación, Universidad Laica Eloy Alfaro de Manabí Extensión El Carmen].

<https://repositorio.ulead.edu.ec/handle/123456789/6391>

TaurusWebs. (2025). *Calibración de cámaras de drones*.

<https://tauruswebswp.com/soporte/>

Universidad de Zaragoza. (2024). *Protocolo de análisis físico - químico*.

https://ocw.unizar.es/ocw/pluginfile.php/6377/mod_folder/content/0/An%C3%A1lisis%20composici%C3%B3n/Determinaci%C3%B3n%20de%20proteinas.pdf

Innovación en agricultura de precisión: panorama de patentes

*Gabriela Valarezo Álvarez*¹
*Gisselle Soto Minchalo*²
*Francisco Álvarez Arévalo*³

¹CEDIA, Unidad de Vigilancia Tecnológica, Cuenca, Ecuador,
<https://orcid.org/0009-0005-9629-203X>
gabriela.valarezo@cedia.org.ec

²CEDIA, Unidad de Vigilancia Tecnológica, Cuenca, Ecuador,
<https://orcid.org/0000-0001-8210-4089>
gisselle.soto@cedia.org.ec

³CEDIA, Unidad de Vigilancia Tecnológica, Cuenca, Ecuador,
<https://orcid.org/0009-0000-1526-8307>
*francisco.alvarez@cedia.org.ec

DOI: 10.61854/rccedia.v1n1.004

Enviado: 5 de marzo de 2026

Aprobado: 06 de abril de 2026

Publicado: martes 14 de julio de 2026



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Resumen

El objetivo de este estudio fue caracterizar, mediante patentometría, la dinámica tecnológica asociada a la agricultura de precisión a partir de solicitudes internacionales, identificando tendencias temporales, jurisdicciones de protección, solicitantes líderes y áreas técnicas dominantes. Se realizó un estudio observacional de corte transversal (2025) siguiendo las directrices de la OMPI para informes de panorama de patentes. Se consultó Espacenet y se aplicó una estrategia amplia basada en códigos IPC/CPC y filtros textuales en el título o el resumen, con restricción a solicitudes PCT y una ventana entre 2005 y 2025. La depuración redujo 39 996 registros iniciales a 1 497 documentos PCT y a 1 367 documentos posteriores a 2005, lo que sugiere que gran parte del estado de la técnica circula por rutas nacionales y que el subconjunto PCT concentra invenciones con aspiración global. La serie temporal mostró aceleración desde 2013 y un punto de inflexión en 2017; el crecimiento tendencial se respaldó con un CAGR de 7,29 % (de 2014 a 2024), aunque los modelos de pronóstico reflejaron sensibilidad a los últimos años por el desfase de publicación. La protección se concentró en Estados Unidos, China y la vía europea, con un liderazgo fragmentado, una convivencia de universidades y empresas y con un núcleo tecnológico centrado en gestión y soporte a decisiones, sensado remoto e inteligencia artificial y ejecución en el campo. Se concluye que el ámbito se mantiene en expansión y ofrece oportunidades de diferenciación por integración, interoperabilidad y validación operativa.

Palabras clave:

*gestión del conocimiento, interoperabilidad,
internet de las cosas, propiedad intelectual,
teledetección.*

Introducción

A lo largo de la historia, la agricultura ha sido un eje central en el desarrollo humano. La agricultura tradicional, basada en prácticas manuales, la domesticación de plantas y animales, se conoce como agricultura 1.0. Con la revolución industrial, se incorporó maquinaria a los campos y, con la revolución verde, aumentó el uso de fertilizantes químicos, pesticidas y semillas mejoradas, alcanzando la agricultura 2.0. A mediados de la década de 1990, comenzó una fuerte introducción de las primeras tecnologías de la información con el uso de sensores básicos y monitoreo satelital; además, se dieron importantes avances en biotecnología agrícola, alcanzando la agricultura 3.0 (Herrera & García-Bertrand, 2018; Viola & Mendes, 2022).

En la actualidad, continúa la incorporación entre el sector tecnológico y el análisis de datos, pero de una forma mucho más amplia, con tecnología de vanguardia y sistemas avanzados. Esto ha dado lugar a la agricultura 4.0 o de precisión, caracterizada por la integración de robótica, inteligencia artificial, internet de las cosas y automatización con el fin de obtener una producción más eficiente y sostenible (Santos Valle & Kienzle, 2020). En paralelo, estos avances presentan ciertos desafíos sin precedentes para la agricultura.

Actualmente, la agricultura enfrenta una crisis global que se ve impulsada por varios factores interrelacionados, incluyendo el crecimiento de la población, el agotamiento de los recursos naturales y los efectos del cambio climático. Según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO), se estima que la población mundial podría alcanzar los 9 700 millones de personas para el año 2050 y 10 800 millones para 2080.

Este aumento demográfico ejercerá una presión considerable sobre los sistemas de producción agrícola (FAO, 2018).

Ante este panorama desafiante, la agricultura de precisión se presenta como una innovación transformadora en la gestión de los recursos agrícolas. La agricultura de precisión o agricultura 4.0 involucra un análisis exhaustivo de datos y la aplicación de herramientas tecnológicas avanzadas, cuyo objetivo es maximizar la productividad agrícola, reducir el impacto ambiental y fomentar la sostenibilidad (Getahun y otros, 2024). Su implementación ha demostrado beneficios concretos en múltiples frentes. La agricultura de precisión no solo optimiza la eficiencia de los sistemas agrícolas, sino que también aborda desafíos globales críticos, tales como la seguridad alimentaria, la conservación de los recursos naturales y la resiliencia ante el cambio climático.

Al integrar tecnologías como sensores, drones y sistemas de información geográfica, los datos generados permiten a los agricultores tomar decisiones informadas que mejoran tanto el rendimiento de los cultivos como la salud del ecosistema. Así, la agricultura de precisión se posiciona como una solución vital para garantizar un futuro agrícola sostenible y responsable (Sanyaolu & Sadowski, 2024). Más allá de las tecnologías específicas que integra, lo relevante para este trabajo es que la masificación de estas soluciones ha generado un corpus creciente de invenciones protegibles, lo que abre la posibilidad de estudiar la dinámica del campo desde la evidencia patentaria.

En este contexto de digitalización acelerada, a medida que se masifican sensores, plataformas de datos y sistemas automatizados, se genera un volumen creciente de soluciones técnicas, mode-

los de negocio y actores que compiten, colaboran o se especializan en nichos concretos. Esto crea una necesidad metodológica clara: enfoques que permitan observar la evolución del campo con evidencia, identificar hacia dónde se mueve la innovación y distinguir qué desarrollos están más cerca de convertirse en aplicaciones productivas a gran escala.

Para abordar esa necesidad, se utilizan distintos indicadores que ayudan a aproximarse al progreso tecnológico y a su dinámica de adopción. Entre estos, el análisis de patentes ocupa un lugar relevante porque captura, de forma estructurada, información técnica y jurídica sobre invenciones, permite reconocer titulares de derechos, territorios donde se busca protección y trayectorias temporales de actividad innovadora (Moscatelli y otros, 2024). Además, debido a que patentar suele implicar costos, tiempo y un esfuerzo deliberado por proteger una ventaja, los registros de patentes pueden funcionar como señales tempranas de expectativas de explotación económica, especialmente cuando se observan patrones sostenidos de crecimiento en determinados subcampos o familias tecnológicas (Moscatelli y otros, 2024; Trippe, 2015).

Más allá de servir como termómetro de actividad inventiva, las patentes permiten construir lecturas estratégicas. Por un lado, facilitan comparaciones entre países, regiones o sectores en términos de intensidad de innovación, prioridades tecnológicas y orientación del desarrollo. Por otro, ayudan a mapear el ecosistema de actores, empresas, universidades, centros de investigación y agencias públicas, que están impulsando soluciones, así como a detectar posibles redes de colaboración o concentración de capacidades. En política pública o de planificación institucional,

estas evidencias pueden apoyar la definición de agendas tecnológicas, prioridades de inversión en investigación y desarrollo y enfoques de transferencia tecnológica más realistas (Trippe, 2015).

Concretamente, un análisis patentométrico en agricultura de precisión puede contribuir a, al menos, cuatro objetivos analíticos. Primero, caracterizar la evolución temporal del campo y sus subdominios, por ejemplo, monitoreo remoto, diagnóstico agronómico, dosificación variable, riego inteligente, gestión de datos, plataformas de apoyo a decisiones, maquinaria autónoma y sistemas de trazabilidad. Segundo, comparar dinámicas de protección por jurisdicción para inferir dónde se está intentando capturar valor y qué mercados se consideran prioritarios. Tercero, identificar actores líderes y su naturaleza institucional para entender la orientación del desarrollo, más cercana a investigación, a comercialización o a despliegue aplicado. Cuarto, aproximarse a la dimensión traslacional de la innovación, es decir, qué tan conectadas están las invenciones con implementaciones operativas, escalamiento y uso en condiciones reales de producción (World Intellectual Property Organization (WIPO), 2026).

A partir de lo anterior, el presente estudio se propone recuperar y depurar el panorama de patentes relacionado con agricultura de precisión y utilizar ese corpus para identificar madurez tecnológica, distribución geográfica, principales actores y dinámicas tecnológicas del campo. Con ello, se busca aportar una base empírica que complemente la discusión conceptual sobre agricultura 4.0 y que sirva como insumo para la toma de decisiones en investigación, desarrollo y transferencia tecnológica en el ámbito agrícola.

Métodos

Con el objetivo de garantizar el rigor técnico, la transparencia y la reproducibilidad de los resultados, el diseño metodológico (estudio observacional de corte transversal 2025) de este estudio se fundamenta estrictamente en las directrices internacionales establecidas por la Organización Mundial de la Propiedad Intelectual (OMPI).

Específicamente, se ha adoptado el marco de trabajo descrito en el manual *Guidelines for Preparing Patent Landscape Reports* (Trippe, 2015). Este estándar plantea una estructura coherente que abarca desde la definición del alcance y las estrategias de búsqueda en bases de datos especializadas hasta la normalización de datos y la generación de indicadores analíticos que permiten una toma de decisiones informada. La aplicación de esta guía internacional permite mitigar sesgos en la recuperación de información y asegura que el procesamiento de las familias de patentes cumpla con los criterios de calidad exigidos en el ámbito científico y profesional de la propiedad intelectual industrial.

Alcance

Para la recuperación de documentos, se ha establecido a la OMPI mediante Tratado de Cooperación en Materia de Patentes (PCT) como el criterio de filtrado inclusivo y eje central de la búsqueda. El sistema PCT, administrado por la OMPI, permite solicitar protección de una invención en múltiples países mediante una única solicitud internacional. Esta tiene el mismo efecto que presentar solicitudes nacionales en los estados miembros. El PCT simplifica, centraliza y hace más eficiente en cuanto al costo el proceso, además de facilitar el examen por las oficinas

nacionales y la divulgación técnica de las invenciones (OMPI, 2026).

La selección de patentes tramitadas directamente ante esta oficina internacional responde a tres fundamentos metodológicos. Primero, las patentes OMPI están sujetas a estándares de solicitud de alta exigencia técnica. Segundo, su naturaleza internacional facilita la comparación estadística al basarse en condiciones de presentación estandarizadas, mitigando los sesgos derivados de las legislaciones particulares de oficinas nacionales. Finalmente, la solicitud en oficinas internacionales sugiere una invención con un potencial económico y alcance global significativamente mayor en comparación con solicitudes puramente locales (Trippe, 2015).

Escala temporal

El análisis abarca un periodo de 20 años cumplidos, comprendido entre 2005 y 2025. Esta ventana de observación permite identificar la evolución histórica y las tendencias emergentes en el campo de estudio. Es fundamental señalar que el volumen de patentes analizadas para el cierre del periodo (de 2024 a 2025) no refleja necesariamente la totalidad de las patentes solicitadas en esos años. Debido a la estructura institucional del procesamiento de propiedad intelectual, existe un desfase estándar de aproximadamente 18 meses entre la fecha de prioridad de la solicitud y su publicación oficial.

Por lo tanto, mientras que los datos hasta 2023 ofrecen una cobertura completa de la actividad de innovación, las cifras correspondientes a los últimos 18 meses del estudio representan una muestra parcial compuesta únicamente por

aquellas invenciones que ya han superado el periodo de confidencialidad y han sido liberadas al dominio público.

Base de datos

La ejecución de las consultas se realizó a través de la base de datos abierta Espacenet, de la Oficina Europea de Patentes. Esta plataforma fue seleccionada por ser considerada una de las herramientas de acceso público más robustas y con mayor cobertura a nivel mundial (OMPI, 2022). Su capacidad de integración de datos permite acceder a una vasta colección de documentos técnicos de diversas jurisdicciones, asegurando que la vigilancia tecnológica cuente con el espectro de información más amplio disponible en el estado de la técnica.

Estrategia de búsqueda

Se aplicó una estrategia de búsqueda deliberadamente amplia con el objetivo de capturar, con alta sensibilidad, la mayor parte del panorama tecnológico asociado a la agricultura de precisión. La consulta se estructuró combinando dos criterios complementarios. Primero, se utilizó un conjunto de códigos de clasificación IPC/CPC asociados a etapas, componentes e implicaciones de la agricultura de precisión (Tabla 1). Incluyendo, entre otros, actividades agrícolas y manejo de cultivos, fertilización y control fitosanitario, biotecnología aplicada, sensorización y medición, automatización y control, tecnologías de información y comunicaciones e indicadores vinculados a sostenibilidad.

Tabla 1
Códigos de clasificación IPC/CPC utilizados

Segmentación	Código	Área tecnológica
Agricultura	A01B	Labranza y trabajo del suelo en agricultura o silvicultura y accesorios de maquinaria agrícola.
Agricultura	A01C	Plantación, siembra y fertilización.
Agricultura	A01D	Cosecha, segado, recolección, manejo de cultivos en cosecha.
Agricultura	A01F	Procesamiento y manejo postcosecha, por ejemplo: trilla, empacado, almacenamiento de productos agrícolas, equipos asociados.
Agricultura	A01G	Horticultura, cultivo de vegetales, flores, arroz, frutales, viñas, silvicultura, riego.
Agricultura	A01H	Nuevas plantas, obtención de plantas, reproducción vegetal, cultivo de tejidos.
Agricultura	A01K	Ganadería y cría, avicultura, apicultura, piscicultura, pesca, nuevas razas o manejo animal.
Agricultura	A01M	Control físico de plagas (no químico).
Agricultura	A01N	Biocidas, repelentes/atrayentes de plagas, reguladores de crecimiento vegetal, pesticidas, herbicidas, etc.
Agricultura	A01P	Actividad biocida, repelente.
Fertilizantes	C05	Fertilizantes, su composición, fabricación y uso.
Bioteología	C12N	Microorganismos o enzimas, ingeniería genética, composiciones biotecnológicas, biología molecular aplicada.
Sensores y control	G01	Medición y ensayos, sensores e instrumentación.

Sensores y control	G05	Sistemas de control o regulación automática.
Sensores y control	G06	Computación o cálculo, procesamiento de datos, algoritmos (desde software hasta IA aplicada).
Sensores y control	G07	Dispositivos y métodos de “checking”, registro, conteo, control administrativo o validación.
TIC	G16Y	Internet of Things, IoT.
TIC	G16Z	Informática para dominios de aplicación específicos, incluye agricultura.
Comunicaciones	H04B	Transmisión, sistemas de comunicación eléctrica según el medio o trayectoria de propagación, abarca distintos tipos de transmisión.
Comunicaciones	H04L	Transmisión de información digital, protocolos, comunicaciones de datos, telegráficas digitales, etc.
Sostenibilidad	Y02A	Tecnologías para adaptación al cambio climático.
Sostenibilidad	Y02D	TIC cuyo propósito es reducir su propio consumo energético.
Sostenibilidad	Y02P	Mitigación de cambio climático en procesos de producción o procesamiento de bienes; incluye agroindustria, agricultura, pesca y similares.

Segundo, para asegurar la pertinencia temática de los resultados, se incorporó un filtro textual que exigió la presencia de términos relacionados con agricultura y con enfoques de precisión en el título o resumen, utilizando palabras clave

en inglés y truncamientos para cubrir variaciones morfológicas. De esta manera, se equilibró la amplitud de cobertura con un control mínimo de relevancia, reduciendo la inclusión de documentos ajenos al dominio de agricultura de precisión.

Tabla 2*Palabras clave utilizadas por bloque temático*

Bloque	Temática	Palabras clave
Enfoque tecnológico	Precisión	preci?ion; sustainab*; smart; remote*
Aplicación	Agricultura	agricult*; farm*; crop*; soil*

Análisis de datos

Para la evaluación prospectiva y la proyección de tecnologías, se aplicaron los siguientes métodos de pronóstico: a) CAGR (Compound Annual Growth Rate): tasa compuesta de crecimiento anual que permite calcular el ritmo de crecimiento constante de una variable durante un período determinado; b) ARIMA (Autoregressive

Integrated Moving Average): modelo estadístico que combina componentes autorregresivos, de promedio móvil e integración; c) ETS (Error, Trend, Seasonality): modelo de pronóstico que descompone una serie temporal en sus componentes de error, tendencia y estacionalidad (Chatfield, 2001).

Resultados y discusión

Documentos recuperados

La Figura 1 muestra el proceso de depuración con la estrategia definida anteriormente, mediante filtros sucesivos, diseñado para reducir

ruido, acotar el alcance y conservar únicamente registros comparables y pertinentes para el análisis posterior.





Figura 1

Resultados obtenidos de Espacenet

La figura evidencia, en una primera consulta amplia, la combinación de códigos y términos que arrojó 39 996 registros al aplicar el filtro de alcance regional. Al restringir a patentes PCT, el universo se reduce a 1 497 documentos, es decir, aproximadamente el 3,74 % del total inicial. Esta caída sugiere que una parte importante del estado de la técnica se concentra en rutas nacionales, mientras que la fracción retenida tiende a representar invenciones con vocación de mercado global. Finalmente, el filtro temporal posterior a 2005 reduce el conjunto a 1 367 documentos, manteniendo cerca del 91,3 % del subconjunto PCT. Esto indica una estabilidad relativa de la actividad reciente dentro del canal PCT, alineada con ciclos actuales de innovación y con condiciones regulatorias contemporáneas.

Evolución tecnológica

La evolución y el pronóstico tecnológico analizan la trayectoria temporal del campo a partir de la actividad patentaria, entendida como un indicador observable de invención aplicada, intensidad de I+D y consolidación industrial. Se examinan patrones de crecimiento, cambios de fase y señales de estabilización o aceleración y se incorporan líneas de tendencia y modelos de pronóstico para estimar la dinámica futura. Este enfoque permite sustentar, con evidencia cuantitativa, el nivel de madurez y el margen de expansión del área tecnológica (Trippe, 2015).



*El CAGR indica la tasa de crecimiento promedio asumiendo un crecimiento acumulado.

** El modelo ARIMA proyecta valores futuros considerando patrones históricos y tendencias.

*** El modelo ETS descompone la serie para prever tendencias y nivel, adaptándose a cambios.

**** La Tasa de Crecimiento Anual Compuesta (CAGR) es de 7.29% para el período 2014-2024.

Figura 2

Evolución y pronósticos tecnológicos de agricultura de precisión

La Figura 2 sugiere un campo que pasó de una fase de exploración, con soluciones puntuales, hacia una etapa de aceleración impulsada por la convergencia de avances tecnológicos. Las fluctuaciones interanuales, lejos de indicar inestabilidad estructural por sí mismas, suelen asociarse a ciclos de inversión, cambios de enfoque tecnológico y, sobre todo, a rezagos de publicación y a la maduración de familias de patentes, por lo que los descensos recientes deben leerse con cautela antes de interpretarlos como declive.

Históricamente, la evolución tecnológica en la agricultura se ha desarrollado de manera

gradual. Desde la domesticación de plantas y animales hace aproximadamente 10 000 años hasta la mecanización del siglo XIX y la revolución verde del siglo XX, el sector ha experimentado saltos tecnológicos cruciales, aunque espaciados en el tiempo. Sin embargo, la agricultura de precisión representa una disrupción reciente de carácter exponencial. A partir de la incorporación de tecnologías digitales, sensores remotos, inteligencia artificial y sistemas automatizados, se ha desencadenado un nuevo ciclo de innovación intensiva, como lo evidencia el notable incremento en la actividad patentaria

desde la última década (Klerkx y otros, 2019).

La trayectoria histórica registrada en la gráfica muestra una transición desde una base modesta de publicaciones de patentes hacia una expansión significativa a partir de 2013, con un punto de inflexión visible en 2017. Esta trayectoria ascendente se alinea con la reducción de costos y el aumento del uso de tecnologías como sensores remotos, sistemas de información geográfica, vehículos aéreos no tripulados y modelos de análisis espacial. Este crecimiento está asociado con su amplio rango de aplicaciones en agricultura de precisión, desde el mapeo de suelos, riego o fumigación y predicción de rendimientos hasta el monitoreo en tiempo real de variables climáticas.


Las fluctuaciones interanuales recientes generan un pronóstico incierto entre estabilidad y descenso. Esta tendencia podría explicarse por las mayores exigencias regulatorias asociadas al desarrollo de productos basados en nanopartículas y organismos biológicos, así como por la necesidad de validaciones más extensas antes de alcanzar el mercado (Kah y otros, 2018; Krieger, 2015). Además, la madurez tecnológica alcanzada en este campo, con al menos 35 años de evolución, ha permitido su escalabilidad comercial, facilitando la generación de innovaciones protegibles a través de patentes (Mulla, 2013).

En términos de pronóstico, la línea CAGR (7,29 % de 2014 a 2024) respalda un crecimiento tendencial del campo, coherente con la

expansión de tecnologías habilitadoras y con el empuje regulatorio y de política pública hacia la digitalización e innovación en la agricultura (Banco Mundial, 2025). La divergencia entre modelos (ETS sugiere estabilización y ARIMA un descenso más fuerte) apunta a la sensibilidad del pronóstico en los últimos años, lo que es típico cuando el sistema entra en una fase de madurez con competencia alta.

Distribución jurisdiccional de protección

El análisis de la distribución geográfica de la producción tecnológica se realiza desde la perspectiva de las jurisdicciones de protección intelectual, más que de los países en sí mismos (Trippe, 2015). Aunque la segmentación del estudio se limita a familias tramitadas vía PCT, esta gráfica se orienta a comprender en qué jurisdicciones se nacionalizan las invenciones, es decir, dónde las personas solicitantes deciden convertir la solicitud internacional en derechos exigibles. Este enfoque resulta fundamental, dado que la elección de una jurisdicción determina el alcance legal y estratégico de la protección de una invención. Identificar en qué territorios se concentran las solicitudes de patentes permite reconocer no solo los mercados más dinámicos, sino también los espacios en los que se anticipa un mayor nivel de competencia o demanda futura.



* Ecuador # Rango 46 (Número de Patentes Publicadas en Ecuador: 4)

** "WO" indica que la publicación de la patente es internacional bajo el Tratado de Cooperación en Materia de Patentes (PCT), administrado por la OMPI.

*** "EP" indica que la publicación de la patente corresponde a la Oficina Europea de Patentes (EPO), gestionada por el Convenio sobre la Patente Europea, cubriendo protección en sus estados miembros.

Figura 3

Distribución por jurisdicciones en agricultura de precisión

La distribución por jurisdicción muestra dónde las invenciones en agricultura de precisión tienden a nacionalizarse tras la vía PCT, lo que suele reflejar tanto capacidad de I+D como expectativas de mercado y de apropiación comercial. Los liderazgos de Estados Unidos (US) y China (CN) sugieren que la frontera tecnológica se disputa en ecosistemas con alto dinamismo industrial, amplia base de adopción de tecnolo-

gías digitales y cadenas de valor agroindustriales capaces de escalamiento industrial. El peso de la EP (Oficina Europea de Patentes) refuerza que Europa se mantiene como un espacio relevante de protección, asociado a mercados exigentes y a marcos regulatorios y de estandarización que pueden elevar barreras de entrada y condicionar requisitos de interoperabilidad, trazabilidad y desempeño (Comisión Europea, 2025).

En Estados Unidos, el portafolio recuperado sugiere que la frontera tecnológica de la agricultura de precisión se está consolidando alrededor de tres ejes que se reflejan también en los CPC más frecuentes del conjunto. Primero, la toma de decisiones agronómicas basada en modelos y datos se observa en soluciones de soporte a riego que integran clima, cultivo y variables del suelo para generar recomendaciones operativas (Mewes, 2018). Segundo, la delimitación inteligente del campo y la prescripción aparece en enfoques que combinan teledetección e inteligencia artificial con inventarios edafológicos a gran escala (J. G. White y otros, 2023), en análisis multianual de rendimiento para mapas de prescripción y aplicaciones a tasa variable (Hunt, 2017). Tercero, hay una trayectoria clara hacia la automatización y la sensorización cercana, desde teledetección robótica con sistemas multispectrales para monitoreo en campo (Kumar y otros, 2019) hasta implementos modulares instrumentados para labores y captura de datos (Antle y otros, 2024).

En China, el panorama de patentes muestra una concentración fuerte en infraestructura digital para *smart agriculture*, con énfasis en conectividad, plataformas y control, además de teledetección y algoritmos, alineada con la combinación de códigos G06Q50 y bloques de visión e IA como G06V10, G06T7, G06T2207 y G06N3. Un ejemplo representativo es el control de maquinaria agrícola mediante terminales, posicionamiento satelital y arquitectura de mensajería para integrar los datos con interfaces ministeriales o plataformas de gestión (Pan y otros, 2021). También aparecen métodos de gestión que integran variables agronómicas con información meteorológica y, de forma interesante, variables económicas como precios, para apoyar decisiones como el momento de cosecha (Du, 2018). Complementariamente, se observan diseños orientados a redes de sensores y transmisión robusta en campo, como arquitec-

turas con *gateway* LoRa para monitoreo remoto y control de operaciones (Cai y otros, 2024).

La presencia de familias que han ingresado a la Oficina Europea de Patentes sugiere una estrategia de protección orientada a mercados de alto valor y competencia regulada. En conjunto, los códigos dominantes en esta jurisdicción reflejan un campo donde la frontera tecnológica se mueve por la convergencia entre software de gestión y decisión en agricultura; sensado, analítica y diagnóstico; mecanización y operación de labores, y adaptación y sostenibilidad (Y02A40, A01B79, G06Q50, A01C21, G06Q10, G01N33, A01C7). Esta combinación es consistente con la prioridad europea por digitalizar el sector agroalimentario y escalar prácticas eficientes (FAO, 2018).

Por ejemplo, se observan enfoques de apoyo a decisiones y gestión de zonas agronómicas apoyadas en teledetección e inteligencia artificial (J. White y otros, 2023), junto con componentes de operación y control en campo, como controladores de guiado para agricultura de precisión (Mortimer y otros, 2018) o el uso de dispositivos móviles como interfaz operacional para el agricultor (Ramachandran & Villela, 2022).

En un segundo bloque aparecen jurisdicciones como Australia (AU), Canadá (CA), Japón (JP) y Corea (KR), que suelen actuar como mercados tecnológicamente sofisticados y de alto valor, donde la protección puede estar vinculada a nichos de mecanización avanzada, robótica agrícola y soluciones de gestión de datos. La presencia de Brasil (BR), junto con Argentina (AR) y México (MX), sugiere interés por capturar valor en Latinoamérica, especialmente en agricultura extensiva y cadenas de exportación, aunque con una intensidad menor frente a los líderes. Ecuador no aparece entre las principales jurisdicciones del conjunto, lo que funciona como señal de baja prioridad de nacionalización en el país dentro de estas familias.


Cuando se observa la extensión hacia jurisdicciones latinoamericanas, específicamente Brasil y México, el patrón suele ser más selectivo y orientado a mercados agrícolas específicos, con fuerte peso de adaptación local, costos y protección de soluciones directamente desplegables en campo. México muestra ejemplos de sistemas productivos protegidos, enfocados en agricultura protegida y en el manejo de suelos y plantas (Eguiluz & Villegas, 2015). También se orienta a esquemas de liberación de productos para control biológico de plagas mediante dispensadores acoplados a vehículos, tripulados o no tripulados (De Oliveira Machado & Rodwell, 2022). Brasil aparece asociado a soluciones con aplicación directa en operaciones y sostenibilidad, por ejemplo, métodos de barrera perimetral para control de insectos en cultivos (Carvalho & Joelcio, 2020). Este conjunto se alinea con la distribución CPC que privilegia A01B79 y A01C21, asociadas a operación agrícola y siembra, junto con G06Q50 para gestión y soporte a decisiones, y Y02A40 para resiliencia climática.

En el ámbito de la innovación en agrotecnologías en América Latina, el Laboratorio del Banco Interamericano de Desarrollo (BID Lab) identificó, en 2020, más de 450 sembríos activos, todos iniciados en los últimos cinco años. De estos, el 51 % se concentra en Brasil, el 23 % en Argentina y el 18 % en la Subregión

Andina (Viton y otros, 2020). Entre las áreas de digitalización de la industria agrícola de América Latina han destacado: software especializado, sensores digitales, drones, robots, vehículos autónomos, sistemas de mapeo territorial, GPS, tecnologías en la nube, internet de las cosas, big data, biotecnología, agricultura de precisión y otros (Galvez & Galvez, 2024).

Principales solicitantes de patentes

Los solicitantes de patentes pueden ser personas naturales o jurídicas, que cuentan con los derechos morales y comerciales de las solicitudes de patentes. Diferenciar la naturaleza de los solicitantes, sean empresas, universidades o instituciones gubernamentales, permite comprender las dinámicas de innovación, las estrategias de protección de conocimiento y los intereses que guían el desarrollo tecnológico. Asimismo, este análisis se vincula con la distribución geográfica de la producción intelectual, ya que los solicitantes suelen concentrarse en jurisdicciones estratégicas que reflejan prioridades de mercado y de protección internacional. De esta forma, el estudio de los principales solicitantes constituye un insumo clave para mapear la competencia, detectar posibles aliados y anticipar tendencias de transferencia tecnológica (Trippe, 2015).



* Los solicitantes son quienes presentan y reclaman la protección de una invención.

** Un solicitante puede ser una persona física o jurídica que busca proteger una invención.

Figura 4

Principales solicitantes en agricultura de precisión

La Figura 4 muestra la clasificación de los 20 principales solicitantes del corpus PCT analizado, ordenados por número de patentes publicadas. La Universidad de Jiangsu encabeza el listado con 19 documentos (1,18 % del total), seguida por un bloque de cuatro actores industriales con 13 patentes cada uno (0,81 %): Climate Corp, Climate LLC, Kubota KK y Ping An Tech Shenzhen. Luego de estos, se observa una distribución descendente y relativamente continua con los demás. En conjunto, ningún solicitante supera el 1,2 % de participación y la diferencia entre el primero y el vigésimo lugar es de apenas 12 patentes, lo que

evidencia un ranking sin hegemonías. El liderazgo se distribuye entre universidades asiáticas, conglomerados agroquímicos europeos, fabricantes de maquinaria japoneses y estadounidenses y compañías de software agrícola y de datos, configurando un panorama multiactor característico de los campos tecnológicos en fase expansiva.

La clasificación de solicitantes muestra un bloque mixto de actores entre universidades y corporaciones tecnológicas, químicas y de maquinaria. El hecho de que los líderes individuales tengan una participación cercana al 1 % sugiere un ecosistema competitivo y relativamente frag-

mentado, con múltiples líneas de desarrollo en paralelo y sin una dominancia clara que cierre el acceso por sí sola.

En el frente académico, la Universidad de Zhejiang aparece asociada a desarrollos metodológicos de teledetección y analítica para variables agronómicas críticas, como salinidad del suelo, fenología y estimación de rendimiento, que fortalecen la capa de monitoreo y predicción para decisiones sitio-específicas (Lin y otros, 2023; Z. Shi y otros, 2023, 2024). La Universidad de Jiangsu refleja una agenda más aplicada a instrumentación y automatización en condiciones operativas, con plataformas móviles y dispositivos de detección para invernaderos, además de soluciones vinculadas a riego, medición y control de implementos, lo que acerca estos resultados a prototipos transferibles (Li y otros, 2019; J. Shi y otros, 2023; Zhang y otros, 2020; Zuo y otros, 2019).

En el bloque industrial, una muestra del portafolio analizado sugiere una cadena de valor completa. Kubota KK apunta a la capa de operación mecanizada y control, especialmente donde la precisión depende de la teleoperación y de sistemas de desplazamiento, lo que es crítico para llevar la recomendación al terreno con repetibilidad (Fujii, 2024; Matsuzaki, 2024). Climate LLC se posiciona en agricultura digital, combinando teledetección, modelado y generación de recomendaciones para manejo, rendimiento y propiedades del suelo, una capa clave para convertir datos en prescripciones (Baurer y otros, 2024; Casas y otros, 2022; Cisek y otros, 2025; Xu & Xu, 2021).

BASF Agro Trademarks GmbH refuerza la optimización de aplicaciones y la toma de decisiones agronómicas, con métodos y dispositivos orientados a la eficiencia y la ejecución controlada de insumos (Hoss y otros, 2024; Janssen y otros, 2022; Kiepe y otros, 2024; Peters y otros, 2023, 2025). Finalmente, Ping An Tech Shenzhen Co. Ltd. muestra la entrada de actores de datos hacia evaluación y gestión basada en

información agroclimática y de teledetección, lo que amplía el ecosistema hacia servicios digitales (Gao y otros, 2022).

La evidencia de un panorama compartido entre academia e industria es algo típico en campos tecnológicos habilitantes como la agricultura de precisión, donde la innovación avanza cuando conviven dos enfoques: la academia empuja métodos y conocimiento base y la industria los convierte en sistemas escalables, integrados y comercializables. En este caso, las universidades aportan desarrollos orientados a modelado y teledetección para estimar variables agronómicas y generar capacidades de diagnóstico y predicción. Por su parte, las empresas concentran esfuerzos en industrialización, conectando analítica y prescripción, optimización de insumos y control de maquinaria para ejecutar decisiones con precisión en el campo.

Esta combinación academia-industria es coherente con la fase de aceleración observada en la evolución temporal, donde el aumento sostenido de actividad indica consolidación de soluciones y expansión de mercados. La fragmentación del liderazgo, sumada al crecimiento reciente, sugiere margen para diferenciar tecnologías por integración, interoperabilidad y validación en el campo, más que por una sola invención aislada.


Principales áreas tecnológicas

Los códigos de clasificación CPC (Cooperative Patent Classification) e IPC (International Patent Classification) son sistemas jerárquicos que ordenan las patentes por su contenido técnico, a nivel de secciones, clases, subclases y grupos. La diferencia clave es que IPC funciona como el estándar internacional base y facilita la comparabilidad amplia entre oficinas y estudios, mientras que CPC es una extensión más granular, usada principalmente por las oficinas europeas y estadounidenses, que suele capturar con mayor

detalle matices tecnológicos y aplicaciones específicas (OMPI, 2022).

Se analizan ambas clasificaciones para obtener una lectura más robusta, combinando la cobertura y comparabilidad de los códigos IPC con la mayor granularidad y especificidad técnica de los códigos CPC. En conjunto, la distribución

de códigos permite aproximar qué áreas tecnológicas concentran mayor actividad dentro del panorama, identificar intersecciones entre agricultura, sensorización, datos y automatización y reconocer los frentes donde el desarrollo muestra mayor dinamismo y, por tanto, mayor presión competitiva (Trippe, 2015).



* Un subgrupo CPC es una clasificación para categorizar invenciones según su tecnología.

Figura 5

Principales áreas tecnológicas en agricultura de precisión

A partir de los principales códigos IPC/CPC, se observa que el campo de la agricultura de precisión se organiza en una arquitectura tecnológica con un núcleo digital (gestión y decisión), apoyado por una capa intensa de sensado y analítica y complementado por mecanización e intervenciones agronómicas. Además, aparece una capa

transversal de sostenibilidad y adaptación climática que atraviesa varios frentes de desarrollo. Se puede sintetizar en cuatro tendencias que reflejan su arquitectura.

Primero, núcleo en gestión y soporte a decisiones agrícolas. El mayor peso recae en soluciones tipo plataforma para administración y

operación del agro, desde planificación, asignación de recursos y monitoreo, hasta recomendaciones accionables. Esto se refleja en códigos orientados a aplicaciones administrativas en agricultura (G06Q50/02) y a pronóstico u optimización para fines de gestión (G06Q10/04). En términos competitivos, este núcleo sugiere que la “zona de competencia” se está moviendo hacia software, modelos de decisión y orquestación de datos, más que a dispositivos aislados.

Segundo, un núcleo habilitador, sensor, teledetección y analítica basada en IA. Aquí convergen visión por computador aplicada a vegetación y escenas agrícolas (G06V20/188), esquemas de análisis de imagen asociados a vegetación (G06T2207/30188) y analítica de suelos o muestras agrícolas (G01N33/24), reforzado por métodos de aprendizaje automático (G06N20/00) y redes neuronales (G06N3/08). Este bloque indica que gran parte de la diferenciación ocurre en cómo se capturan variables biofísicas, cómo se interpretan y cómo se transforman en predicciones robustas a escala de parcela.

En tercer lugar, observamos la ejecución en campo y manejo del cultivo. Se agrupan tecnologías para agricultura de precisión y sus implementos (A01B79/005), aplicación controlada de insumos, especialmente fertilización con control y dosificación (A01C21/005 y A01C21/007) y equipos de pulverización (A01M7/0089). También se conectan soluciones para ambientes controlados o invernaderos (A01G9/24). Esta tendencia traduce la analítica en acción y es donde suele concentrarse el estado de la técnica más cercano cuando el proyecto involucra intervención física directa en el cultivo.

Una cuarta tendencia transversal abarca consideraciones de sostenibilidad y adaptación climática. Los códigos Y02A40/10 y Y02A40/25 apuntan a adaptación al cambio climático en agricultura y gestión hídrica, señalando que la eficiencia de agua, la resiliencia y la mitigación de riesgos ambientales son criterios de diseño que se integran al núcleo digital y a la capa de aplicación de insumos.

Conclusiones

La depuración sucesiva de resultados confirma que una estrategia amplia basada en códigos IPC/CPC y filtros textuales puede capturar el campo con alta sensibilidad y que la restricción a solicitudes PCT selecciona una fracción comparativamente pequeña del universo inicial. La reducción desde 39 996 registros a 1 497 documentos PCT, y luego a 1 367 documentos posteriores a 2005, sugiere que una parte significativa del estado de la técnica circula por rutas nacionales, mientras que el subconjunto PCT concentra invenciones con aspiración de mercado global y comparabilidad metodológica más robusta dentro del alcance definido.

La evolución temporal observada describe una transición desde una fase de exploración hacia una etapa de aceleración, con crecimiento marcado a partir de 2013 y un punto de inflexión visible en 2017. Aunque se registran fluctuaciones interanuales recientes, su lectura debe considerar el desfase aproximado de 18 meses entre prioridad y publicación, por lo que los descensos cercanos al cierre del periodo no deben interpretarse como declive. La tasa compuesta de crecimiento anual de 7,29 % para el periodo de 2014 a 2024 respalda una tendencia en crecimiento, mientras que la divergencia entre modelos de pronóstico, con señales de estabilización o descenso según el método, sugiere sensibilidad a los años más recientes y compatibilidad con un escenario de maduración y competencia más alta.

En términos de implicaciones prácticas, el panorama evidencia que la zona competitiva se desplaza hacia un núcleo digital de gestión y soporte a decisiones, reforzado por sensado, teledetección y analítica basada en inteligencia artificial y articulado con la ejecución en el campo mediante mecanización e intervención agronómica. La concentración de protección en Estados Unidos, China y la vía europea muestra que la apropiación de valor se disputa en ecosistemas con fuerte capacidad industrial y digital y que marcos de estandarización, interoperabilidad, trazabilidad y desempeño pueden elevar las barreras de entrada en mercados exigentes. La fragmentación del liderazgo, junto con la convivencia de universidades y empresas, sugiere que las invenciones se asocian más a integración, interoperabilidad y validación en condiciones operativas que a una sola invención aislada.

A partir de las limitaciones y de los patrones observados, futuras investigaciones deberían ampliar la cobertura hacia rutas nacionales para estimar diferencias entre innovación global y local y actualizar el análisis cuando se consolide la publicación de los últimos 18 meses del periodo. También conviene complementar la lectura patentométrica con aproximaciones que capturen innovación no visible en patentes, como artículos científicos o información de mercado, manteniendo la claridad sobre el alcance de cada evidencia.

Limitaciones

A pesar del rigor metodológico fundamentado en las directrices de la OMPI, este estudio presenta limitaciones intrínsecas que deben considerarse al interpretar los resultados. La restricción más relevante es el desfase temporal entre la solicitud y la publicación oficial de las patentes. Asimismo, al emplear las solicitudes vía PCT como filtro principal, se priorizan invenciones con alto potencial global, pudiendo

subestimar innovaciones de escala puramente nacional. Es preciso señalar que el análisis de patentes no abarca la totalidad del ecosistema de innovación, excluyendo desarrollos protegidos bajo secreto industrial o derechos de autor. En consecuencia, estos hallazgos constituyen indicadores de tendencias tecnológicas y no una representación exhaustiva del mercado total (Moscatelli y otros, 2024; Trippe, 2015).

Declaración de conflictos de interés

Quienes firman este artículo declaran no tener conflictos de interés.

Fuentes de financiación

Quienes firman este artículo declaran que esta investigación no recibió financiamiento ex-

terno de ninguna agencia de financiamiento del sector público, comercial o sin fines de lucro.

Declaración de uso de inteligencia artificial

Durante la preparación de este manuscrito se utilizaron herramientas de inteligencia artificial, específicamente ChatGPT y Google Gemini (versiones disponibles al momento de uso), únicamente como apoyo técnico para la estructuración de sentencias de búsqueda empleadas en procesos de recuperación de información y para la generación de scripts destinados a la producción de imágenes.

Todo el contenido generado con apoyo de inteligencia artificial fue posteriormente sometido a un proceso de revisión, validación, adaptación y edición manual por parte de los autores, quienes verificaron su pertinencia, exactitud y coherencia con los objetivos del estudio. En consecuencia, la responsabilidad final sobre el contenido, su interpretación y las conclusiones presentadas recae íntegramente en los autores.

Declaración de uso de inteligencia artificial

Gabriela Valarezo: Conceptualización; metodología; investigación; recursos; redacción - borrador original; supervisión; administración del proyecto.

Gisselle Soto: Validación; recursos; redacción - revisión y edición.

Francisco Álvarez: Software; análisis formal; recursos; gestión de datos; visualización.

Referencias

- Antle, J. L., Snyder, S. T., & Larick, A. J. (2024). *Modular smart implement for precision agriculture* (Patent US12048300B2).
- Banco Mundial. (2025). *Agriculture and Food*.
<https://www.worldbank.org/en/topic/agriculture/overview#2>
- Baurer, P., Koch, J., Sauder, D., & Stoller, B. (2024). *Systems and methods for image capture and analysis of agricultural fields* (Patent US11944043B2).
- Cai, Y., Liu, L., Gao, X., Zhao, X., Wu, P., Song, X., Li, C., Chen, W., Ning, S., Yu, J., & Yang, M. (2024). *Intelligent agricultural control system* (Patent WO2024007559A1).
- Carvalho, C., & Joelcio, E. (2020). *Method for controlling lepidopterous insects by using a perimeter ultrasonic barrier in agricultural crops* (Patent WO2020028961A1).
- Casas, A., Yang, X., & Ward, S. (2022). *Mapping soil properties with satellite data using machine learning approaches* (Patent US11468669B2).
- Chatfield, C. (2001). *TIME-SERIES FORECASTING*. Chapman & Hall.
- Cisek, N., Koshnick, N., Xiang, H., & Yang, X. (2025). *Estimating soil properties within a field using hyperspectral remote sensing* (Patent US12366678B2).
- Comisión Europea. (2025). *New Study Highlights State of play in Digitalisation in EU Agriculture*.
https://agriculture.ec.europa.eu/media/news/new-study-highlights-state-play-digitalisation-eu-agriculture-2025-09-19_en
- De Oliveira Machado, R. A., & Rodwell, M. N. (2022). *System and method for releasing loose or wrapped solid products for biological pest control in agriculture using dispensers coupled to or incorporated into manned or unmanned vehicles* (Patent MX2022000673A).
- Du, G. (2018). *Smart agriculture management method and system* (Patent WO2018232845A1).
- Eguiluz, J. M. G., & Villegas, J. (2015). *Protected soil-plant agriculture production system and method for low-height crops*. (Patent MX2013008823A).
- FAO. (2018). *The future of food and agriculture – Alternative pathways to 2050*. Licence: CC BY-NC-SA 3.0 IGO

- Fujii, T. (2024). *Travel control system for agricultural machine capable of performing remotely-manipulated traveling* (Patent US2024345603A1).
- Galvez, D. P. C., & Galvez, W. P. C. (2024). Digital technologies in agricultural development: The experience of Latin American countries. *E3S Web of Conferences*, 537.
<https://doi.org/10.1051/e3sconf/202453708014>
- Gao, Y., Wang, W., Ren, C., & Zhao, Q. (2022). Agricultural danger data assessment method and apparatus, computer device, and storage medium (Patent WO2022198744A1).
- Getahun, S., Kefale, H., & Gelaye, Y. (2024). Application of Precision Agriculture Technologies for Sustainable Crop Production and Environmental Sustainability: A Systematic Review. In *TheScientificWorldJournal* (Vol. 2024, p. 2126734).
<https://doi.org/10.1155/2024/2126734>
- Herrera, R. J., & Garcia-Bertrand, R. (2018). The Agricultural Revolutions. In *Ancestral DNA, Human Origins, and Migrations* (pp. 475–509). Elsevier.
<https://doi.org/10.1016/B978-0-12-804124-6.00013-6>
- Hoss, M. J., Kerkhoff, C., Johnen, A., & Schaefer, F. J. (2024). *Decision system for seed product and/or crop nutrition product application using remote sensing based soil parameters* (Patent US2024099184A1).
- Hunt, A. D. (2017). *Weighted multi-year yield analysis for prescription mapping in site-specific variable rate applications in precision agriculture* (Patent US9563848B1).
- Janssen, O., Schaefer, F. J., Kerkhoff, C., & Johnen, A. (2022). *Decision system for crop efficiency product application using remote sensing based soil parameters* (Patent US2022361473A1).
- Kah, M., Kookana, R. S., Gogos, A., & Bucheli, T. D. (2018). A critical evaluation of nanopesticides and nanofertilizers against their conventional analogues. *Nature Nanotechnology*, 13(8), 677–684.
<https://doi.org/10.1038/s41565-018-0131-1>
- Kiepe, B., Delatree, C. C., & Wahabzada, M. (2024). *Reduced residual for smart spray* (Patent US2024000002A1).
- Kim, M. Y., & Lee, K. H. (2022). Electrochemical Sensors for Sustainable Precision Agriculture—A Review. In *Frontiers in Chemistry*, 10, 848320.
<https://doi.org/10.3389/fchem.2022.848320>

- Klerkx, L., Jakku, E., & Labarthe, P. (2019). A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. *NJAS - Wageningen Journal of Life Sciences*, 90–91, 100315.
<https://doi.org/10.1016/j.njas.2019.100315>
- Krieger, E. (2015). New trends in intellectual property protection for plant innovations. In *24th Int. Eucarpia Symp. Section Ornamentals "Ornamental Breeding Worldwide"*.
- Kumar, R. V., Cross, G. B., Qu, C., Das, J., Makinenl, A., & Mulgaonkar, Y. S. (2019). *Systems, devices, and methods for robotic remote sensing for precision agriculture* (Patent US10395115B2). United States Patent and Trademark Office.
- Li, J., Xu, J., Wei, X., & Sun, H. (2019). *System and method for real-time measurement of height of spray boom relative to crop canopy* (Patent WO2019218446A1). World Intellectual Property Organization.
- Lin, T., Lin, Z., Jiang, H., & Ying, Y. (2023). *Large-scale crop phenology extraction method based on shape model fitting method* (Patent US11734925B2). United States Patent and Trademark Office.
- Matsuzaki, Y. (2024). *Agricultural machine, sensing system, sensing method, remote operation system, and control method* (Patent US2024341215A1). United States Patent and Trademark Office.
- Mewes, J. J. H. R. C. (2018). *Customized land surface modeling in a soil-crop system for irrigation decision support in precision agriculture* (Patent US10139797B2). United States Patent and Trademark Office.
- Mortimer, R., Miller, S. R., Ganz, B., Hutchings, J., & Syverson, C. D. (2018). *Steering controller for precision farming* (Patent EP3365220A1). European Patent Office.
- Moscatelli, F., C. Chacua, S. Gadgin Matha, H. Hartog, E. Hernandez Rodriguez, J.D. Raffo and M.A. Yildirim (2024). *Can we map innovation capabilities? WIPO Economic Research Working Paper No. 81*. World Intellectual Property Organization.
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering* 114(4), 358–371.
<https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- OMPI. (2022). *The WIPO manual on open source patent analytics*.
<https://wipo-analytics.github.io/manual/>

OMPI. (2026). *PCT – The international patent system*.

<https://www.wipo.int/en/web/pct-system>

Pan, D., Chen, S., Ding, H., Gan, W., Wang, H., & Ye, Z. (2021). *Agricultural machine precision control method applied to smart agriculture* (Patent WO2021248678A1). World Intellectual Property Organization.

Peters, O., Hoffmann, H., Zhao, G., & Das, S. (2023). *Planning and implementing agricultural measures* (Patent US11818975B2). United States Patent and Trademark Office.

Peters, O., Selinger, S., Rommel, T., & Andree-Labsch, S. (2025). *Apparatus for determining agricultural relevant information* (Patent US12270966B2). United States Patent and Trademark Office.

Ramachandran, S., & Villela, M. A. (2022). *Using smart-phones and other hand-held mobile devices in precision agriculture* (Patent EP4002980A1). European Patent Office.

Santos Valle, S., & Kienzle, J. (2020). Agriculture 4.0: Agricultural robotics and automated equipment for sustainable crop production. *Integrated Crop Management*, Vol. 24. FAO.

Sanyaolu, M., & Sadowski, A. (2024). The role of precision agriculture technologies in enhancing sustainable agriculture. *Sustainability* 16(15), 6668.

<https://doi.org/10.3390/su16156668>

Shi, J., Shi, Y., Zou, X., Huang, X., Li, Z., Guo, Z., & Qiao, C. (2023). *Small-grain agricultural product color selection method combining area scan and line scan photoelectric features* (Patent WO2023065396A1). World Intellectual Property Organization.

Shi, Z., Wang, N., Peng, J., & Xue, J. (2024). *Method for jointly estimating soil profile salinity by using time-series remote sensing image* (Patent US2024288602A1). United States Patent and Trademark Office.

Shi, Z., Wang, N., Xue, J., & Peng, J. (2023). *Method for estimating soil salinity of straw residue farmland by using remote sensing construction index* (Patent WO2023087630A1). World Intellectual Property Organization.

Trippe, A. (2015). *Guidelines for preparing patent landscape reports: guidelines prepared for the world intellectual property organization (WIPO)*.

<http://www.wipo.int/tisc/en/>

- Viola, E. & Mendes, V. (2022). Agricultura 4.0 e mudanças climáticas no Brasil. *Ambiente & Sociedade*, 25. <https://doi.org/https://doi.org/10.1590/1809-4422>
- Viton, R., Castillo, A., & Lopes Teixeira, T. (2020). *Mapa de la innovación Agtech en América Latina y el Caribe*. Banco Internacional de Desarrollo
- White, J. G., Miller, B. A., & Bielski, J. (2023). *Enhanced management zones for precision agriculture* (Patent US11744168B2). United States Patent and Trademark Office.
- World Intellectual Property Organization (WIPO). (2026). *World intellectual property report 2026: Technology on the move*.
<https://doi.org/10.34667/tind.59025>
- Xu, L., & Xu, Y. (2021). *Forecasting field level crop yield during a growing season* (Patent US11062223B2). United States Patent and Trademark Office.
- Zhang, X., Mao, H., Gao, H., Zuo, Z., Qiu, B., Zhang, H., & Zhang, Y. (2020). *Smart mobile detection platform for greenhouse* (Patent US10591927B2). United States Patent and Trademark Office.
- Zuo, Z., Qin, L., Mao, H., Zhang, X., Ni, J., Li, Q., & Lv, T. (2019). *Testing device for integrated irrigation and disinfection* (Patent US10317326B2). United States Patent and Trademark Office.

Innovation in precision agriculture: patent landscape

*Gabriela Valarezo Álvarez*¹
*Gisselle Soto Minchalo*²
*Francisco Álvarez Arévalo*³

¹CEDIA, Unidad de Vigilancia Tecnológica, Cuenca, Ecuador,
<https://orcid.org/0009-0005-9629-203X>
gabriela.valarezo@cedia.org.ec

²CEDIA, Unidad de Vigilancia Tecnológica, Cuenca, Ecuador,
<https://orcid.org/0000-0001-8010-4089>
gisselle.soto@cedia.org.ec

³CEDIA, Unidad de Vigilancia Tecnológica, Cuenca, Ecuador,
<https://orcid.org/0009-0000-1526-8307>
francisco.alvarez@cedia.org.ec

DOI: 10.61854/rccedia.v1n1.004

Sent: March 5, 2026

Approved: April 6, 2026

Published: Tuesday, July 14, 2026



This work is licensed under a Creative Commons
Attribution-NonCommercial 4.0 International License.

Abstract

The aim of this study was to characterize, through patentometrics, the technological dynamics associated with precision agriculture based on international filings, identifying temporal trends, protection jurisdictions, leading applicants, and dominant technical areas. An observational cross-sectional study (2025) was conducted following WIPO guidelines for patent landscape reports. Espacenet was queried using a deliberately broad strategy combining IPC/CPC codes with title or abstract text filters, restricted to PCT applications and the 2005–2025 window. Data cleaning reduced 39 996 initial records to 1 497 PCT documents and to 1 367 documents published after 2005, suggesting that much prior art follows national routes and that the PCT subset concentrates inventions with global market ambition. The time series showed acceleration from 2013, and an inflection point in 2017; trend growth was supported by a 7.29% CAGR (2014–2024), although forecasting models were sensitive to the most recent years due to publication lag. The protection is concentrated in the United States, China, and the European route, with fragmented leadership and the coexistence of universities and firms and with a technological core focused on farm management and decision support, remote sensing and AI, and in-field execution. It is concluded that the field remains in expansion and offers differentiation opportunities through integration, interoperability, and operational validation.

Keywords:

knowledge management, intellectual property, interoperability, Internet of Things, remote sensing.

Introduction

Throughout history, agriculture has been a central pillar of human development. Traditional agriculture, based on manual practices and the domestication of plants and animals, is known as Agriculture 1.0. With the Industrial Revolution, machinery was incorporated into farming, and with the Green Revolution, the use of chemical fertilizers, pesticides, and improved seeds increased, leading to Agriculture 2.0. In the mid-1990s, the first information technologies began to be widely introduced through the use of basic sensors and satellite monitoring; in addition, significant advances were made in agricultural biotechnology, giving rise to Agriculture 3.0 (Herrera & García-Bertrand, 2018; Viola & Mendes, 2022).

At present, the integration of the technological sector and data analysis continues, but on a much broader scale, with cutting-edge technologies and advanced systems. This has given rise to Agriculture 4.0, or precision agriculture, characterized by the integration of robotics, artificial intelligence, the Internet of Things, and automation with the aim of achieving more efficient and sustainable production (Santos Valle & Kienzle, 2020). At the same time, these advances present unprecedented challenges for agriculture.

Agriculture is currently facing a global crisis driven by several interrelated factors, including population growth, the depletion of natural resources, and the effects of climate change. According to the Food and Agriculture Organization of the United Nations (FAO), the world population is projected to reach 9.7 billion people by 2050 and 10.8 billion by 2080. This demographic growth will place considerable

pressure on agricultural production systems (FAO, 2018).

Against this challenging backdrop, precision agriculture emerges as a transformative innovation in agricultural resource management. Precision agriculture, or Agriculture 4.0, involves comprehensive data analysis and the application of advanced technological tools aimed at maximizing agricultural productivity, reducing environmental impact, and promoting sustainability (Getahun et al., 2024). Its implementation has demonstrated tangible benefits on multiple fronts. Precision agriculture not only optimizes the efficiency of agricultural systems but also addresses critical global challenges such as food security, the conservation of natural resources, and resilience to climate change.

By integrating technologies such as sensors, drones, and geographic information systems, the generated data enable farmers to make informed decisions that improve both crop performance and ecosystem health. Thus, precision agriculture is positioned as a vital solution for ensuring a sustainable and responsible agricultural future (Sanyaolu & Sadowski, 2024). Beyond the specific technologies it incorporates, what is relevant for this study is that the widespread adoption of these solutions has generated a growing body of patentable inventions, opening the possibility of studying the dynamics of the field through patent evidence.

In this context of accelerated digitalization, as sensors, data platforms, and automated systems become increasingly widespread, a growing volume of technical solutions, business

models, and actors are emerging, competing, collaborating, or specializing in specific niches. This creates a clear methodological need: approaches that make it possible to observe the evolution of the field through evidence, identify the directions of innovation, and distinguish which developments are closest to becoming large-scale productive applications.

To address this need, various indicators are used to assess technological progress and its adoption dynamics. Among these, patent analysis occupies a prominent place because it captures, in a structured manner, technical and legal information on inventions, makes it possible to identify rights holders, territories where protection is sought, and temporal trajectories of innovative activity (Moscatelli et al., 2024). Furthermore, because patenting typically involves costs, time, and a deliberate effort to protect a competitive advantage, patent records can function as early signals of expectations for economic exploitation, particularly when sustained growth patterns are observed in specific subfields or technological families (Moscatelli et al., 2024; Trippe, 2015).

Beyond serving as a measure of inventive activity, patents make it possible to develop strategic insights. On the one hand, they facilitate comparisons among countries, regions, or sectors in terms of innovation intensity, technological priorities, and development orientation. On the other hand, they help map the ecosystem of actors—including companies, universities, research centers, and public agencies—that are driving solutions, as well as identify potential collaboration networks or concentrations of capabilities. In public policy and institutional planning, such evidence can support the definition of technologi-

cal agendas, research and development investment priorities, and more realistic approaches to technology transfer (Trippe, 2015).

Specifically, a patentometric analysis of precision agriculture can contribute to at least four analytical objectives. First, it can characterize the temporal evolution of the field and its subdomains, such as remote monitoring, agronomic diagnostics, variable-rate application, smart irrigation, data management, decision-support platforms, autonomous machinery, and traceability systems. Second, it can compare protection dynamics across jurisdictions to infer where value capture is being pursued, and which markets are considered priorities. Third, it can identify leading actors and their institutional nature to understand the orientation of development, whether closer to research, commercialization, or applied deployment. Fourth, it can provide insights into the translational dimension of innovation, that is, the extent to which inventions are connected to operational implementation, scaling, and use under real production conditions (World Intellectual Property Organization (WIPO), 2026).

Based on the above, the present study aims to retrieve and refine the patent landscape related to precision agriculture and use this corpus to identify technological maturity, geographic distribution, leading actors, and technological dynamics within the field. In doing so, it seeks to provide an empirical foundation that complements the conceptual discussion on Agriculture 4.0 and serves as an input for decision-making in research, development, and technology transfer in the agricultural sector.

Methods

To ensure technical rigor, transparency, and reproducibility of the results, the methodological design (a 2025 cross-sectional observational study) of this research is strictly based on the international guidelines established by the World Intellectual Property Organization (WIPO).

Specifically, the framework described in the manual Guidelines for Preparing Patent Landscape Reports (Trippe, 2015) was adopted. This standard proposes a coherent structure that encompasses the definition of scope and search strategies in specialized databases, data normalization, and the generation of analytical indicators that support informed decision-making. The application of this international guideline helps mitigate information retrieval bias and ensures that the processing of patent families meets the quality criteria required in the scientific and professional field of industrial intellectual property.

Scope

For document retrieval, WIPO Patent Cooperation Treaty (PCT) applications were established as the inclusive filtering criterion and the central axis of the search strategy. The PCT system, administered by WIPO, enables applicants to seek protection for an invention in multiple countries through a single international application. Such an application has the same effect as filing national applications in member states. The PCT simplifies, centralizes, and increases the cost-efficiency of the process, while also facilitating examination by national offices and the technical disclosure of inventions (WIPO, 2026).

The selection of patents filed directly through this international office is based on three methodological considerations. First, WIPO patent applications are subject to highly demanding technical filing standards. Second, their international nature facilitates statistical comparison by relying on standardized filing conditions, thereby mitigating biases derived from the specific legislation of national patent offices. Finally, filing through international offices suggests an invention with significantly greater economic potential and global reach compared with purely local applications (Trippe, 2015).

Time frame

The analysis covers a complete 20-year period, from 2005 to 2025. This observation window makes it possible to identify the historical evolution and emerging trends within the field of study. It is important to note that the patent volume analyzed at the end of the period (2024–2025) does not necessarily reflect the total number of patents filed during those years. Due to the institutional structure of intellectual property processing, there is a standard delay of approximately 18 months between the priority filing date and the official publication date.

Therefore, while data up to 2023 provide complete coverage of innovation activity, the figures corresponding to the final 18 months of the study represent only a partial sample composed of inventions that have already completed the confidentiality period and have been released into the public domain.

Data base

The searches were conducted using Espacenet, the open-access database of the European Patent Office. This platform was selected because it is considered one of the most robust publicly accessible tools with the broadest global coverage (WIPO, 2022). Its data integration capabilities provide access to a vast collection of technical documents from multiple jurisdictions, ensuring that the technology surveillance process is supported by the widest possible spectrum of information available within the state of the art.

Search strategy

A deliberately broad search strategy was applied with the objective of capturing, with high sensitivity, the largest possible share of the technological landscape related to precision agriculture. The query was structured by combining two complementary criteria. First, a set of IPC/CPC classification codes associated with the stages, components, and implications of precision agriculture was used (Table 1). These included, among others, agricultural activities and crop management, fertilization and phytosanitary control, applied biotechnology, sensing and measurement technologies, automation and control systems, information and communication technologies, and indicators related to sustainability.

Table 1
IPC/CPC classification codes used

Segmentation	Code	Technological Area
Agriculture	A01B	Tillage and soil cultivation in agriculture or forestry, and agricultural machinery accessories.
Agriculture	A01C	Planting, sowing, and fertilization.
Agriculture	A01D	Harvesting, mowing, crop collection, and crop handling during harvest.
Agriculture	A01F	Post-harvest processing and handling, for example: threshing, packaging, storage of agricultural products, and associated equipment.
Agriculture	A01G	Horticulture, cultivation of vegetables, flowers, rice, fruit trees, vineyards, forestry, and irrigation.
Agriculture	A01H	New plants, plant breeding, plant reproduction, and tissue culture.
Agriculture	A01K	Livestock farming and breeding, poultry farming, beekeeping, aquaculture, fisheries, new breeds, or animal management.
Agriculture	A01M	Physical pest control (non-chemical).
Agriculture	A01N	Biocides, pest repellents/attractants, plant growth regulators, pesticides, herbicides, etc.
Agriculture	A01P	Biocidal and repellent activity.
Fertilizers	C05	Fertilizers, their composition, manufacture, and use.
Biotechnology	C12N	Microorganisms or enzymes, genetic engineering, biotechnological compositions, and applied molecular biology.
Sensors and control	G01	Measurement and testing, sensors, and instrumentation.
Sensors and control	G05	Automatic control or regulation systems.

Sensors and control	G06	Computing or calculation, data processing, algorithms (from software to applied AI).
Sensors and control	G07	Checking devices and methods, recording, counting, administrative control, or validation.
ICT	G16Y	Internet of Things, IoT.
ICT	G16Z	Information technology for specific application domains, including agriculture.
Communications	H04B	Transmission and electrical communication systems according to the medium or propagation path; covers different types of transmission.
Communications	H04L	Digital information transmission, protocols, data communications, digital telegraphy, etc.
Sustainability	Y02A	Technologies for climate change adaptation.
Sustainability	Y02D	ICT whose purpose is to reduce its own energy consumption.
Sustainability	Y02P	Climate change mitigation in production or goods-processing processes; includes agribusiness, agriculture, fisheries, and related sectors.

Second, to ensure the thematic relevance of the results, a textual filter was incorporated requiring the presence of terms related to agriculture and precision-based approaches in the title or abstract, using English keywords and truncation

operators to capture morphological variations. In this way, broad coverage was balanced with a minimum level of relevance control, reducing the inclusion of documents unrelated to the domain of precision agriculture.

Table 2*Keywords used by thematic block*

Block	Theme	Keywords
Technological Approach	Precision	preci?ion; sustainab*; smart; remote*
Application	Agriculture	agricult*; farm*; crop*; soil*

Data analysis

For prospective assessment and technology forecasting, the following forecasting methods were applied: (a) CAGR (Compound Annual Growth Rate), which calculates the constant growth rate of a variable over a given period; (b) ARIMA (Autoregressive Integrated

Moving Average), a statistical model that combines autoregressive, moving average, and integration components; and (c) ETS (Error, Trend, Seasonality), a forecasting model that decomposes a time series into its error, trend, and seasonal components (Chatfield, 2001).

Results and discussion

Retrieved documents

Figure 1 shows the refinement process based on the previously defined search strategy, using successive filters designed to reduce noise,

narrow the scope, and retain only comparable and relevant records for subsequent analysis.





Figure 1

Results obtained from Espacenet

Figure 1 illustrates the refinement process. In the initial broad search, the combination of classification codes and keywords yielded 39,996 records after applying the regional scope filter. When restricted to PCT patent applications, the dataset was reduced to 1,497 documents, representing approximately 3.74% of the initial total. This decline suggests that a substantial portion of the prior art is concentrated in national filing routes, whereas the retained fraction tends to represent inventions with global market potential. Finally, applying the temporal filter for documents filed after 2005 reduced the dataset to 1,367 documents, retaining approximately 91.3% of the PCT subset. This indicates a relative stability of recent activity within the PCT route, consistent with current innovation cycles and contemporary regulatory conditions.

Technological evolution

Technological evolution and forecasting analyze the temporal trajectory of the field based on patent activity, understood as an observable indicator of applied invention, R&D intensity, and industrial consolidation. Growth patterns, phase transitions, and signals of stabilization or acceleration are examined, and trend lines and forecasting models are incorporated to estimate future dynamics. This approach provides quantitative evidence to support assessments of the technological maturity and expansion potential of the field (Trippe, 2015).



* CAGR indicates the average growth rate assuming accumulated growth.

** The ETS model decomposes the series to forecast trends and level, adapting to changes.

*** The ARIMA model projects future values considering historical patterns and trends.

**** The Compound Annual Growth Rate (CAGR) is 7.29% for the period 2014–2024.

Figure 2

Technological evolution and forecasts in precision agriculture

Figure 2 suggests a field that has evolved from an exploratory phase, characterized by isolated solutions, to a stage of accelerated growth driven by the convergence of technological advances. Year-to-year fluctuations, rather than indicating structural instability per se, are generally associated with investment cycles, shifts in technological focus, and, above all, publication delays and the maturation of patent families. Therefore, recent declines should be interpreted with caution before being viewed as evidence of technological decline.

Historically, technological evolution in agriculture has occurred gradually. From the domestication of plants and animals approximately 10,000 years ago to nineteenth-century mechanization and the Green Revolution of the twentieth century, the sector has undergone crucial technological leaps, although these have been widely spaced over time. Precision agriculture, however, represents a recent exponential disruption. The incorporation of digital technologies, remote sensing, artificial intelligence, and automated systems has triggered a new cycle of intensive innovation, as evidenced by the

substantial increase in patenting activity over the past decade (Klerkx et al., 2019).


The historical trajectory shown in the figure illustrates a transition from a modest baseline of patent publications to significant expansion beginning in 2013, with a visible inflection point in 2017. This upward trend is consistent with declining costs and increased adoption of technologies such as remote sensing, geographic information systems, unmanned aerial vehicles, and spatial analysis models. This growth is associated with their broad range of applications in precision agriculture, including soil mapping, irrigation, spraying, yield prediction, and real-time monitoring of climatic variables.

Recent year-to-year fluctuations generate an uncertain outlook between stabilization and decline. This trend may be explained by the increasingly stringent regulatory requirements associated with the development of products based on nanoparticles and biological organisms, as well as the need for more extensive validation before commercialization (Kah et al., 2018; Krieger, 2015). In addition, the technological maturity achieved in this field, with at least 35 years of development, has enabled commercial scalability, facilitating the generation of patentable innovations (Mulla, 2013).

From a forecasting perspective, the CAGR trend line (7.29% for the period 2014–2024) supports continued long-term growth in the field, consistent with the expansion of enabling technologies and with regulatory and public policy initiatives promoting agricultural digitalization and innovation (World Bank, 2025). The divergence among forecasting models (ETS suggesting stabilization and ARIMA indicating a steeper

Jurisdictional distribution of patent protection

The geographical distribution of technological output is analyzed from the perspective of intellectual property jurisdictions rather than countries themselves (Trippe, 2015). Although this study is limited to patent families filed through the PCT route, this figure focuses on identifying the jurisdictions in which inventions enter the national phase, that is, where applicants decide to convert an international application into enforceable rights. This perspective is essential because the choice of jurisdiction determines the legal and strategic scope of patent protection. Identifying the jurisdictions where patent applications are concentrated provides insight not only into the most dynamic markets but also into those in which higher levels of competition or future demand are anticipated.



* Ecuador: Rank 46 (Number of Published Patent Families in Ecuador: 4).

** "WO" indicates that the patent publication is international under the Patent Cooperation Treaty (PCT), administered by WIPO.

*** "EP" indicates that the patent publication corresponds to the European Patent Office (EPO),

Figure 3

Jurisdictional distribution in precision agriculture

The jurisdictional distribution shows where precision agriculture inventions tend to enter the national phase after the PCT route, which generally reflects both R&D capacity and expectations regarding market opportunities and commercial appropriation. The leadership of the United States (US) and China (CN) suggests that the technological frontier is being shaped within ecosystems characterized by strong industrial dynamism,

broad adoption of digital technologies, and agribusiness value chains capable of industrial-scale deployment. The prominence of the European Patent Office (EP) reinforces Europe's role as a major protection jurisdiction, associated with demanding markets and regulatory and standardization frameworks that may increase entry barriers and impose interoperability, traceability, and performance requirements (European Commission, 2025).

In the United States, the retrieved patent portfolio suggests that the technological frontier of precision agriculture is consolidating around three major axes, which are also reflected in the most frequent CPC classifications. First, agronomic decision-making based on models and data is represented by irrigation support solutions that integrate climate, crop, and soil variables to generate operational recommendations (Mewes, 2018). Second, intelligent field delineation and prescription are reflected in approaches combining remote sensing and artificial intelligence with large-scale soil inventories (J. G. White et al., 2023), as well as multi-year yield analyses for prescription mapping and variable-rate applications (Hunt, 2017). Third, there is a clear trajectory toward automation and proximal sensing, ranging from robotic remote sensing using multispectral systems for field monitoring (Kumar et al., 2019) to modular instrumented implements for agricultural operations and data acquisition (Antle et al., 2024).

In China, the patent landscape reveals a strong concentration on digital infrastructure for smart agriculture, emphasizing connectivity, platforms, and control, together with remote sensing and algorithms, in line with the combination of G06Q50 and computer vision and AI classifications such as G06V10, G06T7, G06T2207, and G06N3. A representative example is the control of agricultural machinery through terminal devices, satellite positioning, and messaging architectures that integrate data with ministerial interfaces or farm management platforms (Pan et al., 2021). The portfolio also includes management methods that integrate agronomic variables with meteorological information and, notably, economic variables such as market prices to support decisions such as harvest timing (Du, 2018). In addition, solutions focused on sensor networks and robust field communications are observed, including LoRa

gateway architectures for remote monitoring and operational control (Cai et al., 2024).

The presence of patent families entering the European Patent Office suggests a protection strategy targeting high-value and highly regulated markets. Overall, the dominant classifications in this jurisdiction reflect a technological field driven by the convergence of agricultural management and decision-support software; sensing, analytics, and diagnostics; mechanization and field operations; and climate adaptation and sustainability (Y02A40, A01B79, G06Q50, A01C21, G06Q10, G01N33, A01C7). This combination is consistent with the European priority of digitalizing the agri-food sector and scaling efficient agricultural practices (FAO, 2018).

For example, decision-support approaches and agronomic zone management based on remote sensing and artificial intelligence are observed (J. White et al., 2023), together with field operation and control components such as guidance controllers for precision agriculture (Mortimer et al., 2018) and the use of mobile devices as operational interfaces for farmers (Ramachandran & Villela, 2022).

A second group comprises jurisdictions such as Australia (AU), Canada (CA), Japan (JP), and South Korea (KR), which typically function as technologically sophisticated, high-value markets where patent protection is associated with advanced mechanization, agricultural robotics, and data management solutions. The presence of Brazil (BR), together with Argentina (AR) and Mexico (MX), suggests an interest in capturing value in Latin America, particularly in large-scale agriculture and export-oriented value chains, although at a lower intensity than the leading jurisdictions. Ecuador does not appear among the principal jurisdictions in the dataset, indicating that national-pha-


se entry into the country is a low priority within these patent families.

When expansion into Latin American jurisdictions, particularly Brazil and Mexico, is examined, the pattern appears to be more selective and oriented toward specific agricultural markets, with a strong emphasis on local adaptation, costs, and the protection of solutions that can be directly deployed in the field. Mexico provides examples of protected production systems focused on protected agriculture and soil and plant management (Eguiluz & Villegas, 2015). It also includes technologies for the release of biological pest control products using dispensers mounted on manned or unmanned vehicles (De Oliveira Machado & Rodwell, 2022). Brazil is associated with solutions directly applicable to field operations and sustainability, such as perimeter barrier methods for insect control in crops (Carvalho & Joelcio, 2020). This portfolio aligns with the CPC distribution emphasizing A01B79 and A01C21, related to agricultural operations and planting, together with G06Q50 for management and decision support, and Y02A40 for climate resilience.

Regarding innovation in agricultural technologies in Latin America, the Inter-American Development Bank's innovation laboratory (IDB Lab) identified more than 450 active agtech startups in 2020, all established within the previous five years. Of these, 51% were located in Brazil, 23% in Argentina, and 18% in the Andean subregion (Viton et al., 2020). Among the main areas driving the digitalization of Latin America's agricultural sector are specialized software, digital sensors, drones, robots, autonomous vehicles, territorial mapping systems, GPS, cloud technologies, the Internet of Things, big data, biotechnology, precision agriculture, and related technologies (Galvez & Galvez, 2024).

Leading patent applicants

Patent applicants may be either natural persons or legal entities that hold the legal and commercial rights associated with patent applications. Distinguishing the nature of applicants, whether companies, universities, or government institutions, provides insight into innovation dynamics, knowledge protection strategies, and the interests driving technological development. Furthermore, this analysis is closely related to the geographical distribution of intellectual output, as applicants tend to concentrate their filings in strategic jurisdictions that reflect market priorities and international protection strategies. Accordingly, the analysis of leading patent applicants provides essential information for mapping the competitive landscape, identifying potential collaborators, and anticipating technology transfer trends (Trippe, 2015).



* Applicants are those who file for and claim protection of an invention.

** An applicant may be a natural person or a legal entity seeking to protect an invention.

Figure 4

Main applicants in precision agriculture

Figure 4 presents the ranking of the top 20 applicants within the analyzed PCT corpus, ordered by the number of published patents. Jiangsu University leads the list with 19 documents (1.18% of the total), followed by a group of four industrial actors with 13 patents each (0.81%): Climate Corp, Climate LLC, Kubota KK, and Ping An Tech Shenzhen. These are followed by a relatively continuous descending distribution among the remaining applicants. Overall, no applicant exceeds a 1.2% share, and the difference between the first and the twentieth-ranked applicant is only 12 patents, revealing a ranking with no clear

dominance. Leadership is distributed among Asian universities, European agrochemical conglomerates, Japanese and U.S. machinery manufacturers, and agricultural software and data companies, configuring a multi-actor landscape characteristic of technological fields in an expansion phase.

The applicant ranking reveals a mixed group of actors composed of universities and technology, chemical, and machinery corporations. The fact that the leading individual applicants each account for approximately 1% of the total suggests a competitive and relatively fragmented ecosystem, with multiple parallel lines of development and no

clear dominance capable of independently limiting market access.

On the academic front, Zhejiang University is associated with methodological developments in remote sensing and analytics for critical agronomic variables, such as soil salinity, phenology, and yield estimation, strengthening the monitoring and prediction layer for site-specific decision-making (Lin et al., 2023; Z. Shi et al., 2023, 2024). Jiangsu University reflects an agenda more closely focused on instrumentation and automation under operational conditions, including mobile platforms and detection devices for greenhouses, as well as solutions related to irrigation, measurement, and implement control, bringing these developments closer to transferable prototypes (Li et al., 2019; J. Shi et al., 2023; Zhang et al., 2020; Zuo et al., 2019).

Within the industrial sector, a sample of the analyzed portfolio suggests a complete value chain. Kubota KK focuses on mechanized operations and control, particularly where precision depends on teleoperation and navigation systems, which are critical for implementing recommendations in the field with repeatability (Fujii, 2024; Matsuzaki, 2024). Climate LLC is positioned in digital agriculture, combining remote sensing, modeling, and recommendation generation for crop management, yield, and soil properties, providing a key layer for converting data into prescriptions (Baurer et al., 2024; Casas et al., 2022; Cisek et al., 2025; Xu & Xu, 2021).

BASF Agro Trademarks GmbH reinforces the optimization of application practices and agronomic decision-making through methods and devices aimed at improving efficiency and the controlled application of inputs (Hoss et al., 2024; Janssen et al., 2022; Kiepe et al., 2024; Peters et al., 2023, 2025). Finally, Ping An Tech Shenzhen Co. Ltd. illustrates the entry of data-driven actors into agricultural assessment and management based on agroclimatic and remote sensing infor-


mation, thereby expanding the ecosystem toward digital services (Gao et al., 2022).

This academia–industry combination is consistent with the acceleration phase observed in the temporal evolution, where sustained growth in activity indicates the consolidation of solutions and market expansion. The fragmented leadership, together with recent growth, suggests room for technological differentiation through integration, interoperability, and field validation rather than through a single isolated invention.

Main technological areas

The Cooperative Patent Classification (CPC) and International Patent Classification (IPC) systems are hierarchical classification systems that organize patents according to their technical content at the section, class, subclass, and group levels. The key difference is that the IPC serves as the international baseline standard, facilitating broad comparability across patent offices and studies, whereas the CPC is a more granular extension used primarily by the European and U.S. patent offices, which typically captures technological nuances and specific applications in greater detail (WIPO, 2022).

Both classification systems are analyzed to obtain a more robust interpretation by combining the broad coverage and comparability of IPC codes with the greater technical granularity and specificity of CPC codes. Together, the distribution of classification codes makes it possible to identify the technological areas concentrating the greatest activity within the landscape, identify intersections among agriculture, sensing, data, and automation, and recognize the fronts where development shows the greatest dynamism and, consequently, the highest competitive pressure (Trippe, 2015).



* A CPC subgroup is a classification used to categorize inventions according to their technology.

Figure 5

Main technological areas in precision agriculture

Based on the leading IPC/CPC codes, the field of precision agriculture is organized around a technological architecture with a digital core (management and decision-making), supported by an intensive sensing and analytics layer and complemented by mechanization and agronomic interventions. In addition, a cross-cutting layer of

sustainability and climate adaptation spans multiple areas of development. This architecture can be summarized into four trends.

First, a core centered on agricultural management and decision support. The greatest emphasis is placed on platform-type solutions for agricultural management and operations, ranging

from planning, resource allocation, and monitoring to actionable recommendations. This is reflected in codes related to administrative applications in agriculture (G06Q50/02) and forecasting or optimization for management purposes (G06Q10/04). From a competitive perspective, this core suggests that the “competitive space” is shifting toward software, decision models, and data orchestration rather than isolated devices.

Second, an enabling core based on sensing, remote sensing, and AI-driven analytics. This area brings together computer vision applied to vegetation and agricultural scenes (G06V20/188), image analysis schemes associated with vegetation (G06T2207/30188), and soil or agricultural sample analytics (G01N33/24), reinforced by machine learning methods (G06N20/00) and neural networks (G06N3/08). This cluster indicates that much of the differentiation occurs in how biophysical variables are captured, interpreted, and transformed into robust predictions at the field scale.

Third, field execution and crop management. This category includes technologies for precision agriculture and its implements (A01B79/005), controlled application of inputs, particularly fertilization with controlled application and dosing (A01C21/005 and A01C21/007), and spraying equipment (A01M7/0089). It also encompasses solutions for controlled environments or greenhouses (A01G9/24). This trend translates analytics into action and typically represents the segment of the state of the art closest to practical implementation when a project involves direct physical intervention in crop production.

A fourth cross-cutting trend encompasses sustainability and climate adaptation considerations. Codes Y02A40/10 and Y02A40/25 refer to climate change adaptation in agriculture and water management, indicating that water-use efficiency, resilience, and environmental risk mitigation have become design criteria integrated into both the digital core and the input application layer.

Conclusions

The successive refinement of search results confirms that a broad search strategy based on IPC/CPC codes and text filters can capture the field with high sensitivity and that restricting the search to PCT applications selects a comparatively small fraction of the initial universe. The reduction from 39,996 records to 1,497 PCT documents, and subsequently to 1,367 documents published after 2005, suggests that a significant portion of the state of the art circulates through national filing routes, whereas the PCT subset concentrates inventions with global market aspirations and provides greater methodological comparability within the defined scope.

The observed temporal evolution describes a transition from an exploratory phase to a stage of acceleration, with marked growth beginning in 2013 and a visible inflection point in 2017. Although recent year-to-year fluctuations are observed, they should be interpreted in light of the approximately 18-month lag between priority filing and publication; therefore, declines near the end of the study period should not be interpreted as evidence of decline. The compound annual growth rate (CAGR) of 7.29% for the 2014–2024 period supports an overall upward trend, while the divergence among forecasting models, indicating either stabilization or decline depending on the method, suggests sensitivity to the most recent years and is consistent with a scenario of technological maturity and increased competition.

In practical terms, the patent landscape shows that the competitive space is shifting toward a digital core focused on management and decision support, reinforced by sensing, remote sensing, and artificial intelligence-based analytics, and integrated with field execution through mechanization and agronomic intervention. The concentration of protection in the United States, China, and the European route indicates that value capture is being contested in ecosystems with strong industrial and digital capabilities and that standardization, interoperability, traceability, and performance frameworks may raise barriers to entry in demanding markets. The fragmented leadership, together with the coexistence of universities and companies, suggests that inventions are increasingly associated with integration, interoperability, and validation under operational conditions rather than with a single isolated invention.

Based on the observed patterns and the study limitations, future research should expand coverage to include national filing routes to estimate differences between global and local innovation and update the analysis once publication of the final 18 months of the study period has been completed. It would also be advisable to complement the patentometric analysis with approaches that capture innovation not reflected in patents, such as scientific publications or market information, while maintaining clarity regarding the scope of each source of evidence.

Limitations

Despite the methodological rigor based on WIPO guidelines, this study has inherent limitations that should be considered when interpreting the results. The most significant limitation is the time lag between patent application and official publication. In addition, by using PCT applications as the primary filter, the analysis prioritizes inventions with high global potential, potentially underestimating innovations devel-

oped exclusively for national markets. It should also be noted that patent analysis does not capture the entire innovation ecosystem, excluding developments protected through trade secrets or copyright. Consequently, these findings should be interpreted as indicators of technological trends rather than as a comprehensive representation of the overall market (Moscatelli et al., 2024; Trippe, 2015).

Conflict of interest statement

The authors declare that they have no conflicts of interest.

Funding statement

The authors declare that this research received no external funding from any public, commercial, or non-profit funding agency.

Declaration on the use of artificial intelligence

During the preparation of this manuscript, artificial intelligence tools, specifically ChatGPT and Google Gemini (versions available at the time of use), were used exclusively as technical support for structuring search queries employed in information retrieval processes and for generating scripts used to produce figures.

All content generated with the assistance of artificial intelligence was subsequently reviewed,

validated, adapted, and manually edited by the authors, who verified its relevance, accuracy, and consistency with the objectives of the study. Consequently, the authors assume full responsibility for the content, its interpretation, and the conclusions presented.

Author contributions (CRediT):

Gabriela Valarezo: Conceptualization; methodology; investigation; resources; writing – original draft; supervision; project administration.

Gisselle Soto: Validation; resources; writing – review & editing.

Francisco Álvarez: Software; formal analysis; resources; data curation; visualization.

References

- Antle, J. L., Snyder, S. T., & Larick, A. J. (2024). *Modular smart implement for precision agriculture* (Patent US12048300B2).
- Banco Mundial. (2025). *Agriculture and Food*.
<https://www.worldbank.org/en/topic/agriculture/overview#2>
- Baurer, P., Koch, J., Sauder, D., & Stoller, B. (2024). *Systems and methods for image capture and analysis of agricultural fields* (Patent US11944043B2).
- Cai, Y., Liu, L., Gao, X., Zhao, X., Wu, P., Song, X., Li, C., Chen, W., Ning, S., Yu, J., & Yang, M. (2024). *Intelligent agricultural control system* (Patent WO2024007559A1).
- Carvalho, C., & Joelcio, E. (2020). *Method for controlling lepidopterous insects by using a perimeter ultrasonic barrier in agricultural crops* (Patent WO2020028961A1).
- Casas, A., Yang, X., & Ward, S. (2022). *Mapping soil properties with satellite data using machine learning approaches* (Patent US11468669B2).
- Chatfield, C. (2001). *TIME-SERIES FORECASTING*. Chapman & Hall.
- Cisek, N., Koshnick, N., Xiang, H., & Yang, X. (2025). *Estimating soil properties within a field using hyperspectral remote sensing* (Patent US12366678B2).
- Comisión Europea. (2025). *New Study Highlights State of play in Digitalisation in EU Agriculture*.
https://agriculture.ec.europa.eu/media/news/new-study-highlights-state-play-digitalisation-eu-agriculture-2025-09-19_en
- De Oliveira Machado, R. A., & Rodwell, M. N. (2022). *System and method for releasing loose or wrapped solid products for biological pest control in agriculture using dispensers coupled to or incorporated into manned or unmanned vehicles* (Patent MX2022000673A).
- Du, G. (2018). *Smart agriculture management method and system* (Patent WO2018232845A1).
- Eguiluz, J. M. G., & Villegas, J. (2015). *Protected soil-plant agriculture production system and method for low-height crops*. (Patent MX2013008823A).
- FAO. (2018). *The future of food and agriculture – Alternative pathways to 2050*. Licence: CC BY-NC-SA 3.0 IGO

- Fujii, T. (2024). *Travel control system for agricultural machine capable of performing remotely-manipulated traveling* (Patent US2024345603A1).
- Galvez, D. P. C., & Galvez, W. P. C. (2024). Digital technologies in agricultural development: The experience of Latin American countries. *E3S Web of Conferences*, 537.
<https://doi.org/10.1051/e3sconf/202453708014>
- Gao, Y., Wang, W., Ren, C., & Zhao, Q. (2022). Agricultural danger data assessment method and apparatus, computer device, and storage medium (Patent WO2022198744A1).
- Getahun, S., Kefale, H., & Gelaye, Y. (2024). Application of Precision Agriculture Technologies for Sustainable Crop Production and Environmental Sustainability: A Systematic Review. *In TheScientificWorldJournal* (Vol. 2024, p. 2126734).
<https://doi.org/10.1155/2024/2126734>
- Herrera, R. J., & Garcia-Bertrand, R. (2018). The Agricultural Revolutions. In *Ancestral DNA, Human Origins, and Migrations* (pp. 475–509). Elsevier.
<https://doi.org/10.1016/B978-0-12-804124-6.00013-6>
- Hoss, M. J., Kerkhoff, C., Johnen, A., & Schaefer, F. J. (2024). *Decision system for seed product and/or crop nutrition product application using remote sensing based soil parameters* (Patent US2024099184A1).
- Hunt, A. D. (2017). *Weighted multi-year yield analysis for prescription mapping in site-specific variable rate applications in precision agriculture* (Patent US9563848B1).
- Janssen, O., Schaefer, F. J., Kerkhoff, C., & Johnen, A. (2022). *Decision system for crop efficiency product application using remote sensing based soil parameters* (Patent US2022361473A1).
- Kah, M., Kookana, R. S., Gogos, A., & Bucheli, T. D. (2018). A critical evaluation of nanopesticides and nanofertilizers against their conventional analogues. *Nature Nanotechnology*, 13(8), 677–684.
<https://doi.org/10.1038/s41565-018-0131-1>
- Kiepe, B., Delatree, C. C., & Wahabzada, M. (2024). *Reduced residual for smart spray* (Patent US2024000002A1).
- Kim, M. Y., & Lee, K. H. (2022). Electrochemical Sensors for Sustainable Precision Agriculture—A Review. In *Frontiers in Chemistry*, 10, 848320.
<https://doi.org/10.3389/fchem.2022.848320>

- Klerkx, L., Jakku, E., & Labarthe, P. (2019). A review of social science on digital agriculture, smart farming and agriculture 4.0: New contributions and a future research agenda. *NJAS - Wageningen Journal of Life Sciences*, 90–91, 100315.
<https://doi.org/10.1016/j.njas.2019.100315>
- Krieger, E. (2015). New trends in intellectual property protection for plant innovations. In *24th Int. Eucarpia Symp. Section Ornamentals "Ornamental Breeding Worldwide"*.
- Kumar, R. V., Cross, G. B., Qu, C., Das, J., MakinenI, A., & Mulgaonkar, Y. S. (2019). *Systems, devices, and methods for robotic remote sensing for precision agriculture* (Patent US10395115B2). United States Patent and Trademark Office.
- Li, J., Xu, J., Wei, X., & Sun, H. (2019). *System and method for real-time measurement of height of spray boom relative to crop canopy* (Patent WO2019218446A1). World Intellectual Property Organization.
- Lin, T., Lin, Z., Jiang, H., & Ying, Y. (2023). *Large-scale crop phenology extraction method based on shape model fitting method* (Patent US11734925B2). United States Patent and Trademark Office.
- Matsuzaki, Y. (2024). *Agricultural machine, sensing system, sensing method, remote operation system, and control method* (Patent US2024341215A1). United States Patent and Trademark Office.
- Mewes, J. J. H. R. C. (2018). *Customized land surface modeling in a soil-crop system for irrigation decision support in precision agriculture* (Patent US10139797B2). United States Patent and Trademark Office.
- Mortimer, R., Miller, S. R., Ganz, B., Hutchings, J., & Syverson, C. D. (2018). *Steering controller for precision farming* (Patent EP3365220A1). European Patent Office.
- Moscatelli, F., C. Chacua, S. Gadgin Matha, H. Hartog, E. Hernandez Rodriguez, J.D. Raffo and M.A. Yildirim (2024). *Can we map innovation capabilities? WIPO Economic Research Working Paper No. 81*. World Intellectual Property Organization.
- Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering* 114(4), 358–371.
<https://doi.org/10.1016/j.biosystemseng.2012.08.009>
- OMPI. (2022). *The WIPO manual on open source patent analytics*.
<https://wipo-analytics.github.io/manual/>

OMPI. (2026). *PCT – The international patent system*.

<https://www.wipo.int/en/web/pct-system>

Pan, D., Chen, S., Ding, H., Gan, W., Wang, H., & Ye, Z. (2021). *Agricultural machine precision control method applied to smart agriculture* (Patent WO2021248678A1). World Intellectual Property Organization.

Peters, O., Hoffmann, H., Zhao, G., & Das, S. (2023). *Planning and implementing agricultural measures* (Patent US11818975B2). United States Patent and Trademark Office.

Peters, O., Selinger, S., Rommel, T., & Andree-Labsch, S. (2025). *Apparatus for determining agricultural relevant information* (Patent US12270966B2). United States Patent and Trademark Office.

Ramachandran, S., & Villela, M. A. (2022). *Using smart-phones and other hand-held mobile devices in precision agriculture* (Patent EP4002980A1). European Patent Office.

Santos Valle, S., & Kienzle, J. (2020). Agriculture 4.0: Agricultural robotics and automated equipment for sustainable crop production. *Integrated Crop Management*, Vol. 24. FAO.

Sanyaolu, M., & Sadowski, A. (2024). The role of precision agriculture technologies in enhancing sustainable agriculture. *Sustainability* 16(15), 6668.
<https://doi.org/10.3390/su16156668>

Shi, J., Shi, Y., Zou, X., Huang, X., Li, Z., Guo, Z., & Qiao, C. (2023). *Small-grain agricultural product color selection method combining area scan and line scan photoelectric features* (Patent WO2023065396A1). World Intellectual Property Organization.

Shi, Z., Wang, N., Peng, J., & Xue, J. (2024). *Method for jointly estimating soil profile salinity by using time-series remote sensing image* (Patent US2024288602A1). United States Patent and Trademark Office.

Shi, Z., Wang, N., Xue, J., & Peng, J. (2023). *Method for estimating soil salinity of straw residue farmland by using remote sensing construction index* (Patent WO2023087630A1). World Intellectual Property Organization.

Trippe, A. (2015). *Guidelines for preparing patent landscape reports: guidelines prepared for the world intellectual property organization (WIPO)*.
<http://www.wipo.int/tisc/en/>

- Viola, E. & Mendes, V. (2022). Agricultura 4.0 e mudanças climáticas no Brasil. *Ambiente & Sociedade*, 25. <https://doi.org/https://doi.org/10.1590/1809-4422>
- Viton, R., Castillo, A., & Lopes Teixeira, T. (2020). *Mapa de la innovación Agtech en América Latina y el Caribe*. Banco Internacional de Desarrollo
- White, J. G., Miller, B. A., & Bielski, J. (2023). *Enhanced management zones for precision agriculture* (Patent US11744168B2). United States Patent and Trademark Office.
- World Intellectual Property Organization (WIPO). (2026). *World intellectual property report 2026: Technology on the move*.
<https://doi.org/10.34667/tind.59025>
- Xu, L., & Xu, Y. (2021). *Forecasting field level crop yield during a growing season* (Patent US11062223B2). United States Patent and Trademark Office.
- Zhang, X., Mao, H., Gao, H., Zuo, Z., Qiu, B., Zhang, H., & Zhang, Y. (2020). *Smart mobile detection platform for greenhouse* (Patent US10591927B2). United States Patent and Trademark Office.
- Zuo, Z., Qin, L., Mao, H., Zhang, X., Ni, J., Li, Q., & Lv, T. (2019). *Testing device for integrated irrigation and disinfection* (Patent US10317326B2). United States Patent and Trademark Office.

Arquitecturas YOLO y RF DETR

para el diagnóstico temprano de enfermedades en
Solanum tuberosum L

Manolo Sebastián Muñoz-Espinoza¹

¹Universidad Técnica de Ambato, Facultad
de Ciencias Agropecuarias, Ambato,
Ecuador,
<https://orcid.org/0000-0001-5897-1211>
mmunoz@uta.edu.ec

DOI: 10.61854/rccedia.v1n1.005

Enviado: 12 de febrero de 2026

Aprobado: 06 de abril de 2026

Publicado: martes 14 de julio de 2026



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Resumen

Se compararon, bajo un protocolo común, tres detectores de objetos para el diagnóstico poscosecha en tubérculos: dos arquitecturas de la familia YOLO y un detector basado en transformadores (RF-DETR). Se empleó un conjunto de datos público de seis clases (cinco patologías y una sana). Las lesiones se anotaron con bounding boxes en Roboflow y se aplicó aumento de datos geométrico y fotométrico. Tras la conversión a COCO para RF-DETR, se mantuvieron idénticas particiones (train/val/test = 792/56/57), misma resolución (640 px) y el mismo protocolo de entrenamiento (60 épocas con early stopping). La evaluación se realizó exclusivamente en test con precisión, recall, mAP@0.50 y mAP@0.50:0.95. En test, YOLOv12 alcanzó P = 78,72 %, R = 96,86 %, mAP@0.50 = 79,36 %, mAP@0.50:0.95 = 73,26 %; YOLOv26 obtuvo P = 79,34 %, R = 96,64 %, mAP@0.50 = 78,48 %, mAP@0.50:0.95 = 73,55 % (según los registros experimentales). RF-DETR logró P = 70,86 %, R = 88,39 %, mAP@0.50 = 85,61 % y mAP@0.50:0.95 = 82,64 %. Para el tamizado de alta sensibilidad (recall alto), la arquitectura YOLO es más conveniente, mientras que RF-DETR ofrece localización estricta (mAP superior en 0.50–0.95) y simplifica el posprocesamiento al prescindir de NMS. Un pipeline en dos etapas (YOLO → RF-DETR) combina velocidad y precisión espacial. Como trabajo futuro, se sugiere calibración por clase y fusión con NIR/HSI para lesiones subepidérmicas.

Palabras clave:

agricultura de precisión, aprendizaje profundo, aumento de datos, localización de objetos, visión por computadora.

Introducción

La papa (*Solanum tuberosum* L.) es uno de los cultivos alimentarios relevantes del mundo y ocupa el tercer lugar en consumo global (Nagel y otros, 2022). En el 2022, la producción superó 375 millones de toneladas, con China e India como principales productores (95,5 y 56 millones de toneladas, respectivamente) (Guillemette y otros, 2024; Solankey, 2025). Su relevancia se sustenta no solo en su valor nutricional y versatilidad culinaria, sino también en su papel estratégico para la seguridad alimentaria y la economía rural, especialmente en países en desarrollo (Moreno Mayhuire & Herrera Quispe, 2023). Sin embargo, la productividad y la calidad poscosecha se ven afectadas por enfermedades fúngicas, bacterianas y fisiológicas que impactan directamente los tubérculos (Keithellakpam y otros, 2025).

Entre las patologías de relevancia económica se encuentran la pierna negra (*Pectobacterium* spp.), la podredumbre rosada (*Phytophthora erythroseptica*), la pudrición seca (*Fusarium* spp.), la sarna común (*Streptomyces scabies*) y la sarna negra (*Rhizoctonia solani*) (Sharma y otros, 2024; Upeniece y otros, 2025). Estas enfermedades pueden ocasionar pérdidas poscosecha del 30 % al 50 % cuando no se detectan ni gestionan oportunamente (Aleinzi, 2025).

El diagnóstico temprano es un componente necesario en la cadena de valor agrícola. No obstante, los métodos basados en la inspección visual experta suelen ser subjetivos, lentos, costosos y dependientes de la experiencia humana, lo cual limita su escalabilidad y reproducibilidad (Qin y otros, 2024). En contraste, los enfoques de inteligencia artificial (IA), en particular el aprendizaje profundo aplicado a la visión por computadora, han emergido como herramientas útiles en la agricultura de precisión (Jayanthi & Kumar, 2024). Los

modelos de detección de objetos ofrecen ventajas frente a los enfoques de clasificación al permitir no solo identificar la presencia de una enfermedad, sino también localizarla en la superficie del tubérculo (Ma y otros, 2022).

En este contexto, Ultralytics YOLO (You Only Look Once) ha demostrado un equilibrio entre precisión, velocidad y eficiencia computacional, lo que ha motivado su adopción en aplicaciones agrícolas (Divyanth y otros, 2024; Geoffrey Manurung y otros, 2024; LIU, 2024; Palacio Betancur & Bolaños Martínez, 2025; Redmon, 2016). Versiones previas, como YOLOv5, YOLOv8 y YOLOv12, han mostrado resultados prometedores en la detección de plagas y enfermedades en cultivos como tomate, fresa y papa (He y otros, 2024; Manolo Muñoz-Espinoza y otros, 2026; J. Zhang y otros, 2024).

YOLO26 es una versión reciente para detección de objetos en tiempo real, diseñada para equipos de borde y con bajo consumo energético. Emplea un diseño optimizado que reduce la complejidad computacional, lo que facilita una implementación ágil, liviana y accesible (Jocher & Qiu, 2026; Sapkota y otros, 2025; Yurdakul y otros, 2026).

Del mismo modo, RF-DETR es una arquitectura de detección de objetos en tiempo real basada en transformadores, perteneciente a la familia de los DETR (*detection transformers*). Se ajusta a diversos dominios y conjuntos de datos de distintos tamaños y está orientada a aplicaciones que requieren alta velocidad y precisión, incluso en entornos con recursos computacionales limitados (por ejemplo, dispositivos de borde o aplicaciones de baja latencia) (Robinson y otros, 2026).

A pesar de estos avances, persisten desafíos: (1) la escasez de conjuntos de datos locales, públicos y etiquetados que representen condiciones reales de campo o poscosecha; (2) la necesidad de adaptar modelos a contextos con muestras limitadas mediante un aumento de datos robusto; y (3) la validación rigurosa en tareas de detección multiclase con clases visualmente similares.

Con el objetivo de comparar prioridades de diseño complementarias, en este estudio se analizaron dos detectores representativos de la familia YOLO —que priorizan velocidad e implementación sencilla— y se amplió el alcance incorporando un detector basado en transformadores, RF-DETR, que formula la detección como predicción de conjuntos a partir de consultas (*queries*) y una asignación uno a uno, reduciendo la dependencia de anclajes y el posprocesamiento intensivo (Robinson y otros, 2026). Para asegurar la equidad experimental, los tres detectores se entrenaron con las mismas imágenes, idénticas particiones (entrenamiento/validación/prueba) y la misma resolución de entrada, manteniendo un protocolo de evaluación unificado. Las anotaciones se convirtieron al formato COCO para el entrenamiento del modelo de tipo DETR.

El enfoque propuesto emplea un conjunto de datos abierto de tubérculos de papa (Faria y otros, 2023), con seis clases (cinco enfermedades y una condición sana), anotado en Roboflow (*Roboflow: Computer Vision Tools for Developers and Enterprises*, 2025) y ampliado mediante un protocolo de aumento diseñado para simular variabilidad realista en orientación, iluminación y ruido.

El objetivo principal fue evaluar comparativamente el rendimiento de detectores de la familia

YOLO y detectores basados en transformadores (RF-DETR) en el descubrimiento temprano de enfermedades en tubérculos de papa, con miras a desarrollar una herramienta automatizada, precisa y escalable que pueda integrarse en sistemas de monitoreo en tiempo real y en entornos con recursos limitados.

Contribuciones

- Un *benchmark* comparativo entre detectores *CNN-based* de la familia YOLO y un detector *transformer-based* (RF-DETR), utilizando imágenes agrícolas reales de papa con seis clases, caracterizadas por alta variabilidad visual y condiciones de adquisición no controladas.
- Un *pipeline* reproducible de anotación y conversión a formato COCO, con criterios de comparabilidad definidos, incluyendo particiones idénticas, resolución uniforme y estrategias de aumento consistentes.
- Una evaluación comparativa homogénea y orientada al análisis del comportamiento de los modelos, que complementa las métricas estándar (mAP@0.5 y mAP@0.5:0.95) con métricas de *precision*, *recall* y matrices de confusión, permitiendo identificar errores sistemáticos y desafíos específicos del dominio agrícola.

Métodos

El estudio presenta un diseño experimental comparativo de tres detectores de objetos (YOLOv12, YOLOv26 y RF-DETR) bajo un protocolo común. La secuencia completa del procesamiento fue: (1) obtención y etiquetado manual de lesiones en 377 imágenes originales; (2) división estratificada en entrenamiento (70 %), validación (15 %) y prueba (15 %); (3) aumento exclusivo del conjunto de entrenamiento; (4) conversión de anotaciones a formato COCO para RF-DETR; (5) entrenamiento independiente de cada modelo con

igual resolución (640 px), mismas particiones y criterios de evaluación; (6) evaluación final sobre el conjunto de prueba con métricas estandarizadas (*precision*, *recall*, $mAP@0.50$, $mAP@0.50:0.95$).

Conjunto de datos original y criterios de inclusión/exclusión

El conjunto de datos base se obtuvo de la plataforma Kaggle (Faria y otros, 2023).




Figura 1

Secuencia completa del pipeline experimental, desde la adquisición de datos hasta la evaluación comparativa

Nota. Las etapas incluyen: etiquetado manual en Roboflow, división estratificada del conjunto original (377 imágenes), aumento exclusivo del entrenamiento, conversión a COCO para RF-DETR, entrenamiento de los tres detectores con mismos parámetros base (640 px, mismas particiones) y evaluación final en el conjunto de prueba.

El conjunto de datos se compiló a partir de múltiples fuentes en línea y fue validado por el Instituto de Investigación Agrícola de Bangladesh (BARI). Consta de 451 imágenes de tubérculos de papa. En este estudio se utilizaron 377 imágenes, excluyendo la clase “misceláneos” para mantener un enfoque estrictamente fitosanitario. Las seis clases consideradas y su distribución fueron:

- Pierna negra: 60 imágenes
- Podredumbre rosada: 57
- Pudrición seca: 60
- Sarna común: 62
- Sarna negra: 58
- Sana: 80

Etiquetado de objetos y control de calidad

El etiquetado manual de las lesiones se realizó con Roboflow (*Roboflow: Computer Vision Tools for Developers and Enterprises, 2025*). Cada instancia de lesión se definió mediante un rectángulo delimitador (*bounding box*), procurando cubrir la lesión visible sin incluir áreas sanas adyacentes en exceso. Para controlar la calidad de las anotaciones:

- Los ejemplos de cada clase fueron revisados visualmente por un especialista en fitopatología, con el fin de verificar la coherencia en el criterio de las anotaciones.
- Se corrigieron cajas excesivamente holgadas o que no coincidían con el contorno aparente de la lesión.
- Las anotaciones se gestionaron en los formatos YOLO y COCO, generados a partir de un mismo conjunto base, con el fin de asegurar la compatibilidad con los frameworks de entrenamiento y evaluación utilizados.

Preprocesamiento

Antes del entrenamiento, se aplicaron las transformaciones:

- Orientación automática para normalizar la rotación del objeto principal (tubérculo).
- Redimensionamiento de las imágenes a 640 × 640 px, manteniendo la relación de aspecto mediante *letterboxing* cuando fue necesario (comportamiento por defecto de Ultralytics).

División estratificada de datos

A partir del conjunto original de 377 imágenes (sin aumento de datos), se realizó una división estratificada para preservar la proporción de clases en cada subconjunto:

- Entrenamiento: 264 imágenes (70 %).
- Validación: 56 imágenes (15 %).
- Prueba: 57 imágenes (15 %).

Aumento de datos (aplicado solo al conjunto de entrenamiento)

Con el fin de incrementar la diversidad de patrones y mitigar el sobreajuste, se aplicó un *pipeline* de aumento exclusivamente sobre las 264 imágenes del conjunto de entrenamiento. Se utilizaron transformaciones en Roboflow que preservan la coherencia geométrica entre imagen y *bounding boxes*:

Transformaciones de imagen:

- Volteo horizontal (*horizontal flip*).
- Rotaciones rígidas de 90° (horaria y antihoraria).
- Rotación aleatoria en el rango [-15° a +15°].
- Inyección de ruido aleatorio hasta el 0,65 % de los píxeles.

Transformaciones de *bounding box*:

- Volteo horizontal sincronizado con la imagen.
- Rotación en $[-15^\circ \text{ a } +15^\circ]$.
- Cizallamiento (*shear*) horizontal y vertical de $\pm 10^\circ$.
- Ruido posicional limitado (hasta 0,16 % de los píxeles) para robustecer la sensibilidad a pequeñas variaciones de anotación.

Este proceso produjo un conjunto de entrenamiento aumentado de 792 imágenes (factor de aumento $\sim 3\times$). Los conjuntos de validación (56 imágenes) y prueba (57 imágenes) se mantuvieron sin aumento.

- Entrenamiento: 792 imágenes ($\sim 88\%$).
- Validación: 56 imágenes ($\sim 6\%$).
- Prueba: 57 imágenes ($\sim 6\%$).

Estos porcentajes se calculan sobre el total de imágenes utilizadas en el experimento ($905 = 792 + 56 + 57$).

La división estratificada $\sim 88\% / \sim 6\% / \sim 6\%$ se seleccionó teniendo en cuenta las prácticas comunes en tareas de detección de objetos con redes profundas, en las que se privilegia un conjunto de entrenamiento amplio para favorecer la convergencia y la capacidad de generalización del modelo. Dado el tamaño limitado del conjunto de datos, se optó por un conjunto de validación reducido pero representativo, suficiente para el monitoreo del entrenamiento y el ajuste de hiperparámetros, y por un conjunto de prueba independiente para la evaluación final.

La estratificación asegura la preservación de la proporción de clases en todos los subconjuntos, reduciendo sesgos derivados del desbalance de clases y permitiendo una comparación consistente del desempeño entre modelos.

Modelos de detección: YOLOv12 y YOLOv26

- YOLOv12 (nano) - *yolov12n.pt*. Detector reciente centrado en mecanismos de atención para enfatizar características relevantes y mejorar la detección de objetos pequeños o parcialmente ocluidos. El modelo se obtuvo del repositorio oficial (Tian y otros, 2025).
- YOLOv26 (nano) - *yolov26n.pt*. Variante optimizada para dispositivos periféricos (*edge*) con recursos limitados; prioriza simplicidad arquitectónica y eficiencia en inferencia (Jocher & Qiu, 2026).
- RF-DETR (base). Arquitectura de transformador en tiempo real para la detección de objetos y la segmentación de instancias, desarrollada por Roboflow (Robinson y otros, 2026).

Para garantizar la comparabilidad, los modelos se entrenaron y evaluaron con el mismo conjunto de datos, idéntica partición (train/val/test), misma resolución de entrada (640×640 px) y mismo protocolo de entrenamiento y evaluación.

Entorno de software y hardware

Los experimentos se ejecutaron en Google Colab con GPU NVIDIA Tesla T4 (parámetros en la Figura 2). Todo el software utilizado es de código abierto y gratuito: Ultralytics YOLO (licencia AGPL-3.0), RF-DETR (licencia Apache 2.0) y Google Colab (versión gratuita). Las anotaciones se realizaron con Roboflow (versión gratuita, licencia de uso académico).

NVIDIA-SMI 550.54.15				Driver Version: 550.54.15				CUDA Version: 12.4			
GPU	Name			Persistence-M	Bus-Id	Disp.A	Volatile	Uncorr.	ECC		
Fan	Temp	Perf		Pwr:Usage/Cap		Memory-Usage	GPU-Util	Compute	M.		
								MIG	M.		
0	Tesla T4			Off	00000000:00:04.0	Off				0	
N/A	35C	P8		9W / 70W	0MiB / 15360MiB		0%	Default		N/A	

Processes:											
GPU	GI	CI	PID	Type	Process name					GPU Memory	
	ID	ID								Usage	
No running processes found											

Figura 2

Parámetros de Google Colab para el entrenamiento

Protocolo de entrenamiento

Pesos iniciales: Se usaron pesos preentrenados (*pretrained*) de cada variante “nano” correspondiente (yolov12n.pt y yolov26n.pt) y “base” de RF-DETR.

Para la arquitectura YOLO, en los dos modelos, los hiperparámetros fueron:

- Épocas (*epochs*): 60
- Tamaño de imagen (*imgsz*): 640 px
- Tamaño de lote (*batch*): 16
- Patience (*early_stopping_patience*): 10 (si no mejora la métrica de validación durante 10 épocas consecutivas)
- Archivo de configuración (*data.yaml*): rutas de train/val/test y definición de 6 clases
- Aumentaciones: las descritas en la sección de “División estratificada de datos” (aplicadas de manera consistente)

Para la arquitectura RF-DETR, los hiperparámetros fueron:

- Épocas (*epochs*): 15
- Tamaño de imagen (*imgsz*): 640 px
- Tamaño de lote (*batch*): 4
- Patience (*early_stopping_patience*): 5

Las diferencias en el tamaño del lote y número de épocas responden a las características propias de cada arquitectura y a restricciones de memoria, práctica común en estudios comparativos cuando se emplean *frameworks* distintos, manteniendo constantes el conjunto de datos, la resolución y los criterios de evaluación.

Evaluación y métricas

La evaluación se realizó exclusivamente sobre el conjunto de prueba (57 imágenes); se reportaron las métricas estándar de Ultralytics para tareas de detección:

- $mAP@0.5$: media del *average precision* por clase empleando un umbral de $IoU = 0.5$.

$$(3) \ mAP@0.50 = \frac{1}{N} \sum_{i=1}^N AP_i(IoU \geq 0.50)$$

- $mAP@0.5:0.95$: media del AP en múltiples umbrales de IoU [0.5: 0.95] con paso de 0.05, más exigente y sensible a la localización.

$$(4) \ mAP@0.50:0.95 = \frac{1}{10} \sum_{t=0.50}^{0.95} mAP_t$$

- $F1$ -score: combina la *precision* y el *recall*.

$$(5) \ F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Resultados

Métricas de rendimiento global

Los tres modelos se evaluaron en el conjunto de prueba (n = 57 imágenes), bajo las mismas condiciones. En la Figura 3 se observan las de-

tecciones de cada modelo y la Tabla 1 resume los resultados globales.




Figura 3
Comparación visual de los diferentes modelos

Tabla 1
Resultados globales

Modelo	<i>Precision</i>	<i>Recall</i>	mAP50	mAP95
RF-DETR	70,86 %	88,39 %	85,61 %	82,64 %
YOLOv1 2	78,72 %	96,86 %	79,36 %	73,26 %
YOLOv2 6	79,34 %	96,64 %	78,48 %	73,55 %

Matriz de confusión

La Figura 4 (YOLOv12) y la Figura 5 (YOLOv26) muestran las matrices de confusión obtenidas; en el eje diagonal se observan los aciertos por clase. Además de las seis clases del estudio (pierna negra, podredumbre rosada, pudrición seca, sarna común, sarna negra, sana), ambas matrices incluyen una columna/fila de *background*, que agrega:

- Falsos positivos (detecciones en regiones sin lesión asignable).
- Falsos negativos (lesiones omitidas que se contabilizan contra la clase esperada como *background*).




Figura 4
Matriz de confusión – YOLOv12




Figura 5
Matriz de confusión – YOLOv26

Desempeño por clase

A partir de las matrices de confusión, se calcularon: *precision* y *recall* por clase.

Tabla 2
Métricas por clase - YOLOv12

Clase	Precision	Recall
Pierna negra	50,00 %	75,00 %
Podredumbre rosada	61,54 %	66,67 %
Pudrición seca	35,71 %	41,67 %
Sarna común	33,33 %	90,00 %
Sarna negra	60,00 %	52,94 %
Sana	92,31 %	86,96 %

Tabla 3
Métricas por clase - YOLOv26

Clase	<i>Precision</i>	<i>Recall</i>
Pierna negra	78,57 %	64,71 %
Podredumbre rosada	61,54 %	66,67 %
Pudrición seca	35,71 %	41,67 %
Sarna común	33,33 %	90,00 %
Sarna negra	60,00 %	52,94 %
Sana	92,31 %	86,96 %

Tabla 4
Métricas por clase - RF-DETR

Clase	<i>Precision</i>	<i>Recall</i>
Pierna negra	67,00 %	35,00 %
Podredumbre rosada	100,00 %	75,00 %
Pudrición seca	53,00 %	75,00 %
Sarna común	50,00 %	100,00 %
Sarna negra	93,00 %	82,00 %
Sana	92,00 %	88,00 %

Hallazgos clave: comparación integral entre modelos

De las tablas 1, 2, 3 y 4, se obtienen hallazgos importantes que permiten realizar una comparación integral entre modelos.

3.4.1. Comparación global (exactitud y localización)

A partir de los resultados (Tabla 1), se observa:

- *Precision* global (P): YOLOv26 alcanza el valor más alto (79,34 %), seguido de YOLOv12 (78,72 %) y RF-DETR (70,86 %).
- *Recall* global (R): YOLOv12 es ligeramente superior (96,86 %), cerca de YOLOv26 (96,64 %) y por encima de RF-DETR (88,39 %).
- $mAP@0.50$: RF-DETR es el mejor (85,61 %) y supera a YOLOv12 (79,36 %) y YOLOv26 (78,48 %).
- $mAP@0.50:0.95$ (más estricto): RF-DETR también lidera (82,64 %), con YOLOv26 (73,55 %) y YOLOv12 (73,26 %) cercanos entre sí.

Los modelos YOLO presentan mayor precisión puntual y sensibilidad globales al umbral por defecto (alta capacidad para no omitir lesiones y controlar falsos positivos a un punto de operación fijo).

RF-DETR exhibe AP superior tanto a IoU laxo (0.50) como a IoU estricto (0.50–0.95), lo que sugiere que a lo largo del barrido de umbrales el modelo mantiene mejor el área bajo la curva *precision–recall* y produce cajas más consistentes en términos de localización.

Implicación práctica: Si la aplicación exige máxima sensibilidad y bajo costo de

omisión (tamizado), uno de los YOLO es una opción adecuada con el umbral por defecto. Si la prioridad es la calidad de localización (p. ej., estimar severidad por área, recortar lesiones para segmentar o integrar a un *pipeline* posterior), RF-DETR ofrece una ventaja consistente en mAP, especialmente en el rango de 0.50–0.95.

3.4.2. Comparación por clase (*precision*, *recall* y *F1*)

Resultados por clase

- Pierna negra
- YOLOv26: P = 78,57 % (máxima), R = 64,71 %, F1 $\approx$ 71,00 % (mejor balance).
- YOLOv12: P = 50,00 %, R = 75,00 % (máximo *recall*), F1 $\approx$ 60,00 %.
- RF-DETR: P = 67,00 %, R = 35,00 %, F1 $\approx$ 46,00 %.
- Conclusión: YOLOv26 equilibra mejor la clase; YOLOv12 recupera más verdaderos positivos (mayor R), útil para no omitir casos; RF-DETR necesita calibración del umbral o más muestras.

Podredumbre rosada

- RF-DETR: P = 100,00 %, R = 75,00 %, F1 $\approx$ 86,00 % (superior).
- YOLOv12/YOLOv26: P = 61,54 %, R = 66,67 %, F1 $\approx$ 64,00 %.
- Conclusión: RF-DETR es superior; combina cero falsos positivos con alta sensibilidad en esta clase.

Pudrición seca

- RF-DETR: P = 53,00 %, R = 75,00 %, F1 $\approx$ 62,00 % (mejor).
- YOLOv12/YOLOv26: P = 35,71 %, R = 41,67 %, F1 $\approx$ 39,00 %.
- Conclusión: La variabilidad morfológica de esta lesión (bordes difusos/subepidérmicos) perjudica a los YOLO con cajas; RF-DETR maneja mejor la localización y recupera más casos.

Sarna común

- RF-DETR: P = 50,00 %, R = 100,00 %, F1 $\approx$ 67,00 % (mejor).
- YOLOv12/YOLOv26: P = 33,33 %, R = 90,00 %, F1 $\approx$ 48,00 %.
- Conclusión: RF-DETR reduce la sobre-detección típica de esta clase en los YOLO (P baja) manteniendo *recall* máximo.

Sarna negra

- RF-DETR: P = 93,00 %, R = 82,00 %, F1 $\approx$ 88,00 % (muy superior).
- YOLOv12/YOLOv26: P = 60,00 %, R = 53,00 %, F1 $\approx$ 56,00 %.
- Conclusión: RF-DETR distingue mejor la textura/tonalidad de esta lesión, minimizando confusiones con sarna común y *background*.

Sana

- RF-DETR: P = 92,00 %, R = 88,00 %, F1 $\approx$ 94,00 %.
- YOLOv12/YOLOv26: P = 92,00 %, R = 87,00 %, F1 $\approx$ 89,00 %.
- Conclusión: Los tres modelos son robustos; RF-DETR ofrece una ventaja pequeña.

Tabla 5
Mejor modelo por clase

Clase	Mejor <i>precision</i>	Mejor <i>recall</i>	Mejor F1	Comentario clave
Pierna negra	YOLO v26 (78,57 %)	YOLO v12 (75,00 %)	YOLO v26 (~71,00 %)	YOLOv26 balancea; YOLOv12 maximiza sensibilidad.
Podre dumbre rosada	RF-D ETR (100,00 %)	RF-D ETR (75,00 %)	RF-DE TR (~86,00 %)	RF-DETR sin falsos positivos y con alta R.
Pudri ción seca	RF-D ETR (53,00 %)	RF-D ETR (75,00 %)	RF-DE TR (~62,00 %)	RF-DETR maneja bordes difusos/subepidérmicos.
Sarna común	RF-D ETR (50,00 %)	RF-D ETR (100,00 %)	RF-DE TR (~67,00 %)	Reduce sobredetección de YOLO.
Sarna negra	RF-D ETR (93,00 %)	RF-D ETR (82,00 %)	RF-DE TR (~88,00 %)	Distingue mejor textura/tonos oscuros.
Sana	RF-D ETR (92,00 %)	RF-D ETR (88,00 %)	RF-DE TR (~90,00 %)	Diferencias marginales; todos robustos.

Discusión

Panorama general y coherencia con la literatura

Bajo un protocolo común (misma partición, resolución y protocolo de entrenamiento), los tres detectores alcanzaron rendimientos competitivos, con paridad entre YOLOv12 y YOLOv26 en las métricas globales (P/R y mAP) y una ventaja en mAP para RF-DETR (tanto a $\text{IoU} = 0.50$ como en el rango $0.50\text{--}0.95$). Según los registros, YOLOv12 consiguió *precision* = 78,72 %, *recall* = 96,86 %, $\text{mAP}@0.50$ = 79,36 % y $\text{mAP}@0.50:0.95$ = 73,26 %, mientras que YOLOv26 obtuvo *precision* = 79,34 %, *recall* = 96,64 %, $\text{mAP}@0.50$ = 78,48 % y $\text{mAP}@0.50:0.95$ = 73,55 %. En múltiples aplicaciones agrícolas contemporáneas, la familia YOLO se ha impuesto por su equilibrio velocidad-exactitud y adopción práctica en el campo (incluidos tubérculos y tareas en poscosecha), lo que concuerda con revisiones sistemáticas y estudios de *benchmarking* recientes (Badgujar y otros, 2024; Divyanth y otros, 2024).

Por su parte, la familia DETR —y en particular las variantes en tiempo real— prescinde de NMS y aprovecha las consultas (*queries*) con asignación bipartita, lo que a menudo se traduce en mejor consistencia de localización a IoU estrictos y curvas P–R con mayor área (AP) en rangos amplios de umbrales (Dahiya y otros, 2025). Este comportamiento está documentado por RT-DETR (CVPR 2024) (Zhao y otros, 2024) y sus implementaciones, que muestran mejoras conjuntas en velocidad y AP respecto a detectores de una etapa y a otros DETR clásicos. Además,

comienzan a reportarse aplicaciones agrícolas con RF-DETR, reforzando la pertinencia de incluir un *transformer-based* en esta comparación (Blok y otros, 2025; Öztürk & Şin, 2026).

Métricas globales: P/R puntuales vs. AP integrados ($\text{IoU} = 0.50$ y $0.50\text{--}0.95$)

Las métricas puntuales (P y R) dependen del umbral de confianza y del posprocesamiento (p. ej., NMS en YOLO), mientras que $\text{mAP}@0.50$ y $\text{mAP}@0.50:0.95$ integran el área bajo la curva P–R al barrer umbrales (y, en COCO, distintos IoU), ofreciendo una medida umbral-agnóstica de clasificación y localización. Esta diferencia explica por qué un modelo puede exhibir AP superior y, aun así, mostrar P/R inferiores en un punto de operación dado: el óptimo global de la curva puede no coincidir con el umbral usado en validación/inferencia (Thibaut, 2023).

En los resultados, RF-DETR presentó mAP superior tanto a 0.50 como a $0.50\text{--}0.95$, coherente con la literatura que reporta mejor localización a IoU estrictos, eliminación de NMS y mayor área P–R gracias a consultas de mayor calidad y decodificadores eficientes (Parlak, 2026; Rahman Sams y otros, 2026). En cambio, YOLOv12/ YOLOv26 retuvieron R y P puntuales ligeramente mejores al umbral por defecto (Ultralytics), un patrón habitual en detectores de una etapa con NMS y calibración hiperprobada en la práctica agrícola (Badgujar y otros, 2024; Divyanth y otros, 2024).

Desempeño por clase: lectura comparada y causas probables

Pierna negra. YOLOv26 alcanzó el mejor F1 ($P \approx 79,00\%$; $R \approx 65,00\%$), equilibrando precisión y sensibilidad; YOLOv12 retuvo el *recall* más alto ($75,00\%$), idóneo para tamizado. La menor R de RF-DETR sugiere umbral subóptimo o necesidad de muestras adicionales en esta clase concreta. Este tipo de intercambio P–R entre arquitecturas se ha observado en *benchmarks* agrícolas, donde la textura y la humedad influyen en la confusión interclase (Badgujar y otros, 2024).

Podredumbre rosada. RF-DETR fue superior ($P = 100,00\%$; $R = 75,00\%$), esto es, sin falsos positivos y con alta R al punto de operación usado; la curva P–R de esta clase tiende a dominar a lo largo de los umbrales, coherente con las ventajas de los transformadores en contexto y consistencia espacial (Zhao y otros, 2024).

Pudrición seca. RF-DETR superó a YOLO en R y F1; su mejor desempeño ante bordes difusos y manifestaciones subepidérmicas sugiere que la función de coste ($L1+GIoU$) y el matching uno-a-uno amortiguan la penalización a IoU altos; aun así, la literatura coincide en que lesiones internas/incipientes requieren NIR/SW-NIR/HSI para elevar sensibilidad, lo que refuerza una vía multimodal futura (Prasetyo y otros, 2024; F. Zhang y otros, 2024).

Sarna común vs. sarna negra. En YOLO se observa sobredetección en sarna común (P baja, R alta), mientras que RF-DETR mejora el balance (mayores P y R), probablemente por capturar mejor la textura granular y el contexto espacial de los esclerocios de *Rhizoctonia solani* (sarna negra) y su variabilidad (AG-3, etc.), conocidos por inducir ambigüedades visuales en tubérculos (Chaudhary y otros, 2023; *Potato - Rhizoctonia Solani* (Stem Canker & Black Scurf), 2025).

Sana. Los tres modelos son robustos (P y R altos, con ventaja marginal de RF-DETR), resultado coherente con aplicaciones en tubérculos/poscosecha y revisiones sobre YOLO en contextos agrícolas (Badgujar y otros, 2024; Divyanth y otros, 2024).

Validez estadística y transparencia

Dado el tamaño del conjunto de prueba ($n = 57$), las diferencias pequeñas (≤ 1 punto porcentual) pueden no ser estadísticamente significativas. Se recomienda aplicar remuestreo por imagen o instancia para obtener intervalos de confianza del $95,00\%$ en P , R , mAP y F1; así como pruebas de permutación para contrastar la hipótesis nula de “sin diferencia”. Además, se sugiere reportar curvas P–R con puntos de máxima F1 (global y por clase) para anclar el punto de operación a la política de riesgo (costo de FN vs. FP). Estas prácticas son coherentes con la evaluación COCO y con guías recientes para mAP y P–R (Thibaut, 2023; F. Zhang y otros, 2024).

Implicaciones prácticas en TIC

- 1. Arquitectura de sistema (*edge* ↔ nube).

Los resultados sustentan un diseño híbrido: inferencia en el borde (cámaras/SoC/Jetson) para respuesta en tiempo real y envío *event-driven* de casos ambiguos a la nube para auditoría y reetiquetado. La familia YOLO es ampliamente adoptada en el agro por su baja latencia y facilidad de despliegue; RF-DETR aporta detección *end-to-end* sin NMS, lo que simplifica la canalización de posprocesamiento en dispositivos con recursos limitados y ofrece mejor AP a IoU estrictos (Badgujar y otros, 2024; F. Zhang y otros, 2024).

- 2. Selección de modelo por caso de uso (puntos de operación).

Para tamizado de alto volumen (no omitir lesiones), un YOLO calibrado a umbral bajo maximiza *recall*; para diagnóstico con cuantificación de severidad (IoU altos), RF-DETR ofrece mayor mAP@0.50:0.95 y cajas más consistentes a lo largo del barrido de umbrales. Las curvas P–R y mAP (COCO) son la herramienta recomendada para fijar umbrales por clase según costo de error (Thibaut, 2023; Zhao y otros, 2024).

- 3. *Pipelines* en dos etapas (*screening* → refinamiento).

Un flujo YOLO → RF-DETR reduce el costo computacional en *edge* (detección rápida) y eleva la *precision*/IoU en los positivos (refinamiento sin NMS), estrategia ya sugerida en *benchmarking* de visión agrícola y consistente con la evidencia de RT-DETR en tiempo real (Zhou y otros, 2025).

- 4. Multimodalidad para lesiones internas.

Para pudrición seca y otras lesiones subepidérmicas, integrar NIR/SW-NIR/HSI en el *pipeline* TIC eleva la detección temprana, superando las limitaciones de RGB. La fusión tardía (*late fusion*) o el enrutamiento de muestras sospechosas a una estación NIR/HSI son estrategias escalables en plantas con limitaciones de tiempo-ciclo (Prasetyo y otros, 2024; F. Zhang y otros, 2024).

Conclusiones

1. Rendimiento comparativo y viabilidad operativa

Bajo un mismo protocolo experimental — mismo conjunto de datos, partición estratificada y resolución de entrada (640 px)—, los detectores de la familia YOLO y el modelo basado en transformadores RF-DETR demostraron ser viables para la detección temprana de enfermedades en tubérculos de papa en escenarios poscosecha. YOLOv12 y YOLOv26 presentaron un desempeño comparable en términos de *precision* y *recall*, mientras que RF-DETR obtuvo valores superiores de mAP tanto a IoU = 0.50 como en el rango 0.50–0.95. Estos resultados indican la pertinencia de ambos paradigmas para su integración en sistemas automatizados de inspección agrícola con recursos computacionales moderados.

2. Sensibilidad, localización y elección según el caso de uso

El análisis comparativo evidenció un intercambio sistemático entre sensibilidad y exactitud de localización. Los modelos YOLO mostraron un *recall* ligeramente superior al umbral por defecto, lo que los hace adecuados para escenarios de tamizado masivo donde minimizar falsos negativos es prioritario. En contraste, RF-DETR presentó una localización más estricta y consistente, reflejada en su ventaja en mAP@0.50:0.95, atribuible a su mecanismo de asignación uno a uno y a la ausencia de supresión no máxima. Este comportamiento resulta relevante cuando la delimitación precisa de la lesión es necesaria para la estimación de severidad o clasificación posterior.

3. Comportamiento por clase y limitaciones del enfoque RGB

El análisis mediante matrices de confusión permitió identificar patrones de error específicos del dominio agrícola. En particular, las confusiones entre sarna común y sarna negra se explican por similitudes fenotípicas en textura y coloración superficial, reportadas en la literatura fitopatológica. Asimismo, las lesiones subepidérmicas asociadas a *Fusarium spp.* presentaron mayores tasas de falsos negativos y menor solapamiento espacial, lo que evidencia una limitación inherente al uso exclusivo de imágenes RGB para la detección temprana de daños internos.

4. Implicaciones prácticas y recomendación de arquitectura

A partir de los resultados obtenidos, se propone una arquitectura funcional en dos etapas: un primer nivel de detección basado en YOLO, orientado a maximizar la sensibilidad y permitir un cribado rápido, seguido de un segundo nivel con RF-DETR para el refinamiento de la localización y la mejora del IoU. Esta combinación equilibra eficiencia computacional y precisión espacial y puede reforzarse mediante técnicas de calibración y, cuando el objetivo sea reducir omisiones en lesiones incipientes, mediante la fusión tardía con información espectral NIR o HSI. En conjunto, los hallazgos sugieren la viabilidad de desarrollar una herramienta automatizada, precisa y escalable, alineada con los requisitos de sistemas de monitoreo en tiempo real y *edge computing* en entornos poscosecha.

Declaración de conflictos de interés

Quien firma este artículo declara no tener conflictos de interés.

Fuentes de financiación

Quien firma este artículo declara que esta investigación no recibió financiamiento externo

de ninguna agencia de financiamiento del sector público, comercial o sin fines de lucro.

Contribución de autoría (CRediT):

Manolo Sebastián Muñoz-Espinoza: Conceptualización; metodología; software; validación; análisis formal; investigación; recursos; gestión

de datos; redacción - borrador original; redacción - revisión y edición; visualización; supervisión; administración del proyecto.

Referencias

- Aleinzi, M. (2025). Enhancing precision agriculture with YOLOv8: A deep learning approach to potato disease identification. *International Journal of Advanced Computer Science and Applications*, 16(4), 1156–1166.
<https://doi.org/10.14569/IJACSA.2025.01604110>
- Badgujar, C. M., Poulouse, A., & Gan, H. (2024). Agricultural object detection with You Look Only Once (YOLO) algorithm: A bibliometric and systematic literature review. *Computers and Electronics in Agriculture*, 223.
<https://doi.org/10.1016/j.compag.2024.109090>
- Blok, P. M., Wang, H., Suh, H. K., Wang, P., Burridge, J., & Guo, W. (2025). PointRAFT: 3D deep learning for high-throughput prediction of potato tuber weight from partial point clouds [Preprint]. *arXiv*.
<https://doi.org/10.48550/arXiv.2512.24193>
- Chaudhary, S., Lal, M., Sagar, S., Sharma, S., & Kumar, M. (2023). Black scurf of potato: Insights into biology, diagnosis, detection, host-pathogen interaction, and management strategies. *Tropical Plant Pathology*, 49(2), 169–192.
<https://doi.org/10.1007/s40858-023-00622-4>
- Dahiya, N., Prakash, D., Kundu, S., Kuttan, S. R., Suwalka, I., Ayadi, M., Dubale, M., & Hashmi, A. (2025). Optimised RFO tuned RF-DETR model for precision urine microscopy for renal and systemic disease diagnosis. *Scientific Reports*, 15(1), 25842.
<https://doi.org/10.1038/s41598-025-11725-0>
- Divyanth, L. G., Khanal, S. R., Paudel, A., Mattupalli, C., & Karkee, M. (2024). Efficient detection of eyes on potato tubers using deep-learning for robotic high-throughput sampling. *Frontiers in Plant Science*, 15, 1512632.
<https://doi.org/10.3389/fpls.2024.1512632>
- Ephytia. (2025, July 24). Potato—Rhizoctonia solani (stem canker & black scurf). <https://ephytia.inra.fr/en/C/20899/Potato-Rhizoctonia-solani-Stem-canker-Black-scurf>
- Faria, F. T. J., Moin, M. Bin, & Wase, A. Al. (2023). *Potato Diseases Datasets* [Conjunto de datos]. Kaggle.
<https://doi.org/10.34740/KAGGLE/DSV/7203264>

- Geoffrey Manurung, D., Ryan Pinasthika, M., Obila Vasya, M. A., Dwi Setya Putri, R. A., Parasian Tampubolon, A., Fadhil Prayata, R., Khoirin Nisa, S., & Yudistira, N. (2024). Deteksi dan klasifikasi hama potato beetle pada tanaman kentang menggunakan YOLOV8. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(4), 723–734.
<https://doi.org/10.25126/jtiik.1148092>
- Guillemette, A. M., Casanova, G. H., Hamilton, J. P., Pokorná, E., Dobrev, P. I., Motyka, V., Rashotte, A. M., & Leisner, C. P. (2024). The physiological and molecular responses of potato tuberization to projected future elevated temperatures. *Plant Physiology*, 197(1), 664.
<https://doi.org/10.1093/PLPHYS/KIAE664>
- He, Y., Peng, Y., Wei, C., Zheng, Y., Yang, C., & Zou, T. (2024). Automatic disease detection from strawberry leaf based on improved YOLOv8. *Plants*, 13(18), 2256
<https://doi.org/10.3390/PLANTS13182556>
- Jayanthi, J., & Kumar, K. A. (2024). Transformative impact of AI-driven computer vision in agriculture. En *Artificial intelligence techniques in smart agriculture* (pp. 129–150). Springer
https://doi.org/10.1007/978-981-97-5878-4_9
- Jocher, G., & Qiu, J. (2026). *Ultralytics YOLO26* [Software]. GitHub.
<https://github.com/ultralytics/ultralytics>
- Keithellakpam, L. B., Karunakaran, C., Singh, C. B., Jayas, D. S., & Danielski, R. (2026). A comprehensive review on pre- and post-harvest perspectives of potato quality and non-destructive assessment approaches. *Applied Sciences*, 16(1), 190
<https://doi.org/10.3390/APP16010190>
- Liu, C. (2024). Advancing strawberry disease detection in agriculture: A transfer learning approach with YOLOv5 algorithm. *International Journal of Advanced Computer Science and Applications*, 15(3), 1013–1022.
<https://dx.doi.org/10.14569/IJACSA.2024.01503101>
- Ma, P., Li, C., Rahaman, M. M., Yao, Y., Zhang, J., Zou, S., Zhao, X., & Grzegorzec, M. (2022). A state-of-the-art survey of object detection techniques in microorganism image analysis: From classical methods to deep learning approaches. *Artificial Intelligence Review*, 56(2), 1627–1698.
<https://doi.org/10.1007/S10462-022-10209-1>

- Muñoz Espinoza, M., Moreno Castillo, W. E., y Palacios Ruiz, F. P. (2026). Detección de enfermedades en papa mediante deep learning usando YOLOv12. *Ciencias de la Ingeniería y Aplicadas*, 10(1), 119–129.
<https://doi.org/10.61236/CIYA.V10I1.1239>
- Moreno Mayhuire, J. S., & Herrera Quispe, J. A. (2023). Modelos de aprendizaje automático para la clasificación de enfermedades de la *Solanum tuberosum*: Una revisión sistemática de la literatura. *Revista de Investigación de Sistemas e Informática*, 16(2), 129–137.
<https://doi.org/10.15381/risi.v16i2.25980>
- Nagel, M., Dulloo, M. E., Bissessur, P., Gavrilenko, T., Bamberg, J., Ellis, D., & Giovannini, P. (2022). *Global strategy for the conservation of potato*. Leibniz Institute of Plant Genetics and Crop Plant Research.
<https://doi.org/10.5447/IPK/2022/29>
- Öztürk, L., & Şin, B. (2026). Real-time transformer-based object detection for advanced plant disease recognition: The grapevine fanleaf virus example. *Applied Fruit Science*, 68(1).
<https://doi.org/10.1007/s10341-026-01777-5>
- Palacio Betancur, S., & Bolaños Martínez, F. (2025). Tomato (*Solanum lycopersicum* L.) leaf disease detection using computer vision. *Revista Facultad Nacional de Agronomía*, 78(3), 11203–11212.
<https://doi.org/10.15446/rfnam.v78n3.116493>
- Parlak, C. (2026). Evaluation of cutting-edge object detection architectures on multi-object and single-object datasets. *Black Sea Journal of Engineering and Science*, (9)1. 287-294.
<https://doi.org/10.34248/bsengineering.1736319>
- Prasetyo, E. W., Amanah, H. Z., Farras, I., Pahlawan, M. F. R., & Masithoh, R. E. (2024). Detection of *Fusarium spp.* infection in potato (*Solanum tuberosum* L.) during postharvest storage through visible-near-infrared and shortwave-near-infrared reflectance spectroscopy. *Open Agriculture*, 9(1).
<https://doi.org/10.1515/opag-2022-0295>
- Qin, R., Wang, Y., Liu, X., & Yu, H. (2024). Advancing precision agriculture with deep learning enhanced SIS-YOLOv8 for Solanaceae crop monitoring. *Frontiers in Plant Science*, 15, 1485903.
<https://doi.org/10.3389/fpls.2024.1485903>
- Rahaman Sams, F., Kazi Supti, S., Binte Hamid, S., Junayed, R., Fahim A Bari, K. M., Junaeid Ali, M., Gani, R., Shams, K., Rifat Ahmmad Rashid, M., & Ul Islam, R. (2026). Real-time sunflower detection using semi-supervised and self-supervised deep learning for precision agriculture. *Smart Agricultural Technology*, 13, 101684.
<https://doi.org/10.1016/J.ATECH.2025.101684>

- Redmon, J. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Robinson, I., Robicheaux, P., Popov, M., Ramanan, D., & Peri, N. (2026). RF-DETR: Neural architecture search for real-time detection transformers [Preprint]. arXiv.
<https://arxiv.org/abs/2511.09554>
- Roboflow. (2025). *Roboflow: Computer vision tools for developers and enterprises*.
<https://roboflow.com/>
- Sapkota, R., Cheppally, R. H., Sharda, A., & Karkee, M. (2025). YOLO26: Key architectural enhancements and performance benchmarking for real-time object detection [Preprint]. arXiv.
<https://arxiv.org/pdf/2509.25164>
- Sharma, S., Tiwari, R. K., Sagar, V., & Maharana, C. (2024). Soil- and tuber-borne diseases of potato. In *Approaches for potato crop improvement and stress management* (pp. 179–231).
https://doi.org/10.1007/978-981-97-1223-6_7
- Solankey, S. S. (Ed.). (2025). *Advances in research on potato production*. Springer.
<https://doi.org/10.1007/978-3-031-82710-5>
- Thibaut, L. (2023, August 13). *COCO evaluation metrics explained*. Picsellia.
<https://www.picsellia.com/post/coco-evaluation-metrics-explained>
- Tian, Y., Ye, Q., & Doermann, D. (2025, February 20). YOLO12: Attention-centric real-time object detectors [Preprint]. arXiv.
<https://arxiv.org/abs/2502.12524>
- Upeniece, L., Bimšteine, G., & Stramkale, V. (2025). The most important potato diseases and microbiological agents for their control: A review. *Research for Rural Development 2025: Annual 31st International Scientific Conference Proceedings* (Vol. 1, pp. 17–23). Latvia University of Life Sciences and Technologies.
<https://doi.org/10.22616/RRD.31.2025.003>
- Yurdakul, M., Sazak, H., Kotan, M., & Taşdemir, T. (2026). *A review of YOLO family from YOLOv1 to YOLO26* [Preprint]. Preprints.org
<https://doi.org/10.20944/PREPRINTS202602.1844.V1>

- Zhang, F., Wang, W. X., Wang, C. S., Zhou, J., Pan, Y., & Sun, J. F. (2024). Study on hyperspectral detection of potato dry rot in gley stage based on convolutional neural network. *Spectroscopy and Spectral Analysis*, 44(2), 480-489.
[https://doi.org/10.3964/j.issn.1000-0593\(2024\)02-0480-10](https://doi.org/10.3964/j.issn.1000-0593(2024)02-0480-10)
- Zhang, J., Xie, J., Zhang, F., Gao, J., Yang, C., Song, C., Rao, W., & Zhang, Y. (2024). Greenhouse tomato detection and pose classification algorithm based on improved YOLOv5. *Computers and Electronics in Agriculture*, 216, 108519.
<https://doi.org/10.1016/J.COMPAG.2023.108519>
- Zhao, Y., Lv, W., Xu, S., Wei, J., Wang, G., Dang, Q., Liu, Y., & Chen, J. (2024). DETRs beat YOLOs on real-time object detection. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 16965–16974).
<https://zhao-yian.github.io/RTDETR>.
- Zhou, H., Liu, Y., & Wang, J. (2025). Railway fastener defect detection using RFD-DETR: A lightweight real-time transformer-based approach. *PLOS ONE*, 20(11), e0331513.
<https://doi.org/10.1371/JOURNAL.PONE.0331513>

YOLO and RF-DETR architectures

for early disease diagnosis in *Solanum tuberosum* L

*Manolo Sebastián Muñoz-Espinoza*¹

¹Universidad Técnica de Ambato, Facultad
de Ciencias Agropecuarias, Ambato,
Ecuador,
<https://orcid.org/0000-0001-5897-1211>
mmunoz@uta.edu.ec

DOI: 10.61854/rccedia.v1n1.005

Sent: February 12, 2026

Approved: April 6, 2026

Published: Tuesday, July 14, 2026



This work is licensed under a Creative Commons
Attribution-NonCommercial 4.0 International License.

Abstract

Three object detectors for post-harvest diagnosis in tubers were compared under a unified protocol: two YOLO-family architectures and a transformer-based detector (RF-DETR). We used a six-class public dataset (five diseases plus healthy). Lesions were manually annotated with bounding boxes in Roboflow and augmented with geometric/photometric transforms. Annotations were converted to COCO for RF-DETR. We enforced identical splits (train/val/test = 792/56/57), the same input size (640 px), and an identical training recipe (60 epochs with early stopping). Evaluation on the held-out test set reported precision, recall, mAP@0.50, and mAP@0.50:0.95. On test images, YOLOv12 achieved P = 78.72%, R = 96.86%, mAP@0.50 = 79.36%, mAP@0.50:0.95 = 73.26%; YOLOv26 reached P = 79.34%, R = 96.64%, mAP@0.50 = 78.48%, mAP@0.50:0.95 = 73.55% (experimental logs). RF-DETR delivered P = 70.86%, R = 88.39%, mAP@0.50 = 85.61%, and mAP@0.50:0.95 = 82.64%. For high-sensitivity screening (high recall), the YOLO architecture is more convenient, while RF-DETR offers strict localization (superior mAP at 0.50–0.95) and simplifies post-processing by eliminating the need for an NMS. A two-stage pipeline (YOLO → RF-DETR) balances speed with spatial accuracy. Future work includes per-class score calibration and multimodal fusion with NIR/HSI for subepidermal symptoms.

Keywords:

precision agriculture, deep learning, data augmentation, object localization, computer vision.

Introduction

Potato (*Solanum tuberosum* L.) is one of the world's most important food crops and ranks third in global consumption (Nagel et al., 2022). In 2022, global production exceeded 375 million tons, with China and India as the leading producers (95.5 and 56 million tons, respectively) (Guillemette et al., 2024; Solankey, 2025). Its importance is supported not only by its nutritional value and culinary versatility but also by its strategic role in food security and the rural economy, particularly in developing countries (Moreno Mayhuire & Herrera Quispe, 2023). However, productivity and postharvest quality are affected by fungal, bacterial, and physiological diseases that directly impact tubers (Keithellakpam et al., 2025).

Among the economically significant diseases are blackleg (*Pectobacterium* spp.), pink rot (*Phytophthora erythroseptica*), dry rot (*Fusarium* spp.), common scab (*Streptomyces scabies*), and black scurf (*Rhizoctonia solani*) (Sharma et al., 2024; Upeniece et al., 2025). These diseases can cause postharvest losses ranging from 30% to 50% when they are not detected and managed in a timely manner (Aleinzi, 2025).

Early diagnosis is an essential component of the agricultural value chain. However, methods based on expert visual inspection are often subjective, slow, costly, and dependent on human expertise, limiting their scalability and reproducibility (Qin et al., 2024). In contrast, artificial intelligence (AI) approaches, particularly deep learning applied to computer vision, have emerged as valuable tools in precision agriculture (Jayanthi & Kumar, 2024). Object detection models offer advantages over classification approaches by enabling not only the identification of disease presence but also its localization

on the surface of the tuber (Ma et al., 2022).

In this context, Ultralytics YOLO (You Only Look Once) has demonstrated a balance between accuracy, speed, and computational efficiency, motivating its adoption in agricultural applications (Divyanth et al., 2024; Geoffrey Manurung et al., 2024; LIU, 2024; Palacio Betancur & Bolaños Martínez, 2025; Redmon, 2016). Previous versions, such as YOLOv5, YOLOv8, and YOLOv12, have shown promising results in the detection of pests and diseases affecting crops such as tomato, strawberry, and potato (He et al., 2024; Manolo Muñoz-Espinoza et al., 2026; J. Zhang et al., 2024).

YOLO26 is a recent real-time object detection model designed for edge devices and low energy consumption. It employs an optimized architecture that reduces computational complexity, facilitating agile, lightweight, and accessible deployment (Jocher & Qiu, 2026; Sapkota et al., 2025; Yurdakul et al., 2026).

Similarly, RF-DETR is a real-time transformer-based object detection architecture belonging to the DETR (Detection Transformer) family. It is adaptable to different domains and datasets of varying sizes and is intended for applications requiring high speed and accuracy, even in environments with limited computational resources (e.g., edge devices or low-latency applications) (Robinson et al., 2026).

Despite these advances, several challenges remain: (1) the scarcity of local, public, and annotated datasets representing real field or postharvest conditions; (2) the need to adapt models to contexts with limited samples through robust data augmentation; and (3) rigorous validation in multiclass detection tasks involving visually similar classes.

To compare complementary design priorities, this study analyzed two representative detectors from the YOLO family—which prioritize speed and ease of deployment—and expanded the scope by incorporating the transformer-based detector RF-DETR, which formulates detection as set prediction based on queries and one-to-one assignment, reducing dependence on anchors and intensive post-processing (Robinson et al., 2026). To ensure experimental fairness, the three detectors were trained using the same images, identical training/validation/test splits, and the same input resolution, while maintaining a unified evaluation protocol. The annotations were converted to the COCO format for training the DETR-based model.

The proposed approach employs an open potato tuber dataset (Faria et al., 2023), containing six classes (five diseases and one healthy condition), annotated in Roboflow (Roboflow: Computer Vision Tools for Developers and Enterprises, 2025) and expanded through a data augmentation protocol designed to simulate realistic variability in orientation, illumination, and noise.

The primary objective was to comparatively evaluate the performance of YOLO-family detectors and transformer-based detectors (RF-DETR) for the early detection of diseases in potato tubers, with the aim of developing an automated, accurate, and scalable tool that can be integrated into real-time monitoring systems and deployed in resource-constrained environments.

Contributions

- A comparative benchmark between CNN-based detectors from the YOLO family and a transformer-based detector (RF-DETR), using real agricultural potato images comprising six classes characterized by high visual variability and uncontrolled acquisition conditions.
- A reproducible annotation and COCO conversion pipeline, with clearly defined comparability criteria, including identical data splits, uniform input resolution, and consistent data augmentation strategies.
- A homogeneous comparative evaluation focused on analyzing model behavior, complementing standard metrics (mAP@0.5 and mAP@0.5:0.95) with precision, recall, and confusion matrices, enabling the identification of systematic errors and domain-specific challenges in agricultural applications.

Methods

The study presents a comparative experimental design involving three object detectors (YOLOv12, YOLOv26, and RF-DETR) evaluated under a common protocol. The complete processing workflow consisted of: (1) acquisition and manual annotation of lesions in 377 original images; (2) stratified splitting into training (70%), validation (15%), and test (15%) sets; (3) augmentation applied exclusively to the training set; (4) conversion of annotations to COCO format for RF-DETR; (5) independent training of each model

using the same input resolution (640 px), identical data splits, and identical evaluation criteria; and (6) final evaluation on the test set using standardized metrics (precision, recall, mAP@0.50, and mAP@0.50:0.95).

Original dataset and inclusion /exclusion criteria

The original dataset was obtained from the Kaggle platform (Faria et al., 2023).




Figure 1

Complete experimental pipeline, from data acquisition to comparative evaluation

Note. The stages include manual annotation in Roboflow, stratified splitting of the original dataset (377 images), augmentation applied exclusively to the training set, conversion to COCO format for RF-DETR, training of the three detectors using the same baseline parameters (640 px, identical data splits), and final evaluation on the test set.

The dataset was compiled from multiple online sources and validated by the Bangladesh Agricultural Research Institute (BARI). It consists of 451 potato tuber images. In this study, 377 images were used after excluding the “miscellaneous” class to maintain a strictly phytosanitary focus. The six classes considered and their distribution were:

- Blackleg: 60 images
- Pink rot: 57
- Dry rot: 60
- Common scab: 62
- Black scurf: 58
- Healthy: 80

Object annotation and quality control

Manual lesion annotation was performed using Roboflow (Roboflow: Computer Vision Tools for Developers and Enterprises, 2025). Each lesion instance was defined by a bounding box, carefully adjusted to cover the visible lesion while minimizing the inclusion of adjacent healthy tissue. Annotation quality was controlled through the following procedures:

- Representative examples of each class were visually reviewed by a plant pathology specialist to verify annotation consistency.
- Bounding boxes that were excessively loose or did not correspond to the apparent lesion boundaries were corrected.
- Annotations were managed in both YOLO and COCO formats, generated from the same base annotation set to ensure compatibility with the training and evaluation frameworks.

Preprocessing

Before training, the following transformations were applied:

- Automatic orientation to normalize the rotation of the main object (tuber).
- Image resizing to 640 × 640 px while preserving the aspect ratio through letterboxing when necessary (Ultralytics default behavior).

Stratified data splitting

The original dataset of 377 images (before data augmentation) was stratified to preserve class proportions across all subsets:

- Training: 264 images (70%).
- Validation: 56 images (15%).
- Test: 57 images (15%).

Data augmentation (applied only to the training set)

To increase pattern diversity and mitigate overfitting, a data augmentation pipeline was applied exclusively to the 264 images in the training set. Transformations were performed in Roboflow while preserving geometric consistency between images and bounding boxes.

Image transformations:

- Horizontal flip.
- Fixed 90° rotations (clockwise and counter-clockwise).
- Random rotation within the range [-15° to +15°].
- Random noise injection affecting up to 0.65% of image pixels.

Bounding box transformations:

- Horizontal flip synchronized with the image.
- Rotation within the range $[-15^\circ \text{ to } +15^\circ]$.
- Horizontal and vertical shear of $\pm 10^\circ$.
- Limited positional noise (up to 0.16% of image pixels) to improve robustness to small annotation variations.

This process produced an augmented training set of 792 images (approximately a 3× augmentation factor). The validation (56 images) and test (57 images) sets remained unaugmented.

- Training: 792 images (~88%).
- Validation: 56 images (~6%).
- Test: 57 images (~6%). These percentages were calculated based on the total number of images used in the experiment ($905 = 792 + 56 + 57$).

The stratified split of approximately 88%/6%/6% was selected following common practices in deep-learning object detection tasks, where a large training set is prioritized to promote model convergence and generalization. Given the limited dataset size, a reduced but representative validation set was considered sufficient for monitoring training and tuning hyperparameters, while an independent test set was reserved for the final evaluation.

Stratification preserved class proportions across all subsets, reducing class imbalance bias and enabling a consistent comparison of model performance.

Detection models: YOLOv12 and YOLOv26

- YOLOv12 (nano) – yolov12n.pt. A recent detector focused on attention mechanisms to emphasize relevant features and improve the detection of small or partially occluded objects. The model was obtained from the official repository (Tian et al., 2025).
- YOLOv26 (nano) – yolov26n.pt. A variant optimized for edge devices with limited computational resources, prioritizing architectural simplicity and inference efficiency (Jocher & Qiu, 2026).
- RF-DETR (base). A real-time transformer architecture for object detection and instance segmentation developed by Roboflow (Robinson et al., 2026).

To ensure comparability, all models were trained and evaluated using the same dataset, identical train/validation/test partitions, the same input resolution (640×640 px), and the same training and evaluation protocol.

Software and hardware environment

The experiments were conducted in Google Colab using an NVIDIA Tesla T4 GPU (parameters shown in Figure 2). All software used was open-source and freely available: Ultralytics YOLO (AGPL-3.0 license), RF-DETR (Apache 2.0 license), and Google Colab (free version). Annotations were performed using Roboflow (free version for academic use).

NVIDIA-SMI 550.54.15			Driver Version: 550.54.15			CUDA Version: 12.4		
GPU	Name		Persistence-M	Bus-Id	Disp.A	Volatile	Uncorr. ECC	
Fan	Temp	Perf	Pwr:Usage/Cap		Memory-Usage	GPU-Util	Compute M.	
							MIG M.	
0	Tesla T4		Off	00000000:00:04.0	Off		0	
N/A	35C	P8	9W / 70W	0MiB / 15360MiB		0%	Default	
							N/A	

Processes:								
GPU	GI	CI	PID	Type	Process name		GPU Memory	
	ID	ID					Usage	
No running processes found								

Figure 2

Google Colab training parameters

Training protocol

Initial weights: Pretrained weights were used for each corresponding “nano” variant (yolov12n.pt and yolov26n.pt) and the RF-DETR “base” model.

For the YOLO architecture (both models), the hyperparameters were:

- Epochs: 60
- Image size (imgsz): 640 px
- Batch size: 16
- Patience (early_stopping_patience): 10 (training stopped if the validation metric did not improve for 10 consecutive epochs)
- Configuration file (data.yaml): train/validation/test paths and six-class definition
- Data augmentation: as described in the “Stratified Data Splitting” section (applied consistently)

For the RF-DETR architecture, the hyperparameters were:

- Epochs: 15
- Image size (imgsz): 640 px
- Batch size: 4
- Patience (early_stopping_patience): 5

The differences in batch size and number of epochs reflect the characteristics of each architecture and memory constraints, which is common practice in comparative studies using different frameworks, while maintaining the dataset, input resolution, and evaluation criteria constant.

Evaluation and Metrics

The evaluation was performed exclusively on the test set (57 images). Standard Ultralytics metrics for object detection tasks were reported:

- mAP@0.5: mean average precision per class using an IoU threshold of 0.5.

$$(3) \text{ mAP@0.50} = \frac{1}{N} \sum_{i=1}^N AP_i(IoU \geq 0.50)$$

- mAP@0.5:0.95: mean of AP at multiple IoU thresholds [0.5: 0.95] with a step of 0.05, more demanding and sensitive to localization.

$$(4) \text{ mAP@0.50:0.95} = \frac{1}{10} \sum_{t=0.50}^{0.95} mAP_t$$

- F1-score: combines precision and recall.

$$(5) F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Results

Overall performance metrics

The three models were evaluated on the test set (n = 57 images) under identical conditions. Figure 3 shows the detections produced by each model, and Table 1 summarizes the overall results.




Figure 3
Visual comparison of the different models

Table 1
Overall results

Modelo	Precision	Recall	mAP50	mAP95
RF-DETR	70,86 %	88,39 %	85,61 %	82,64 %
YOLOv12	78,72 %	96,86 %	79,36 %	73,26 %
YOLOv26	79,34 %	96,64 %	78,48 %	73,55 %

Confusion matrix

Figure 4 (YOLOv12) and Figure 5 (YOLOv26) show the resulting confusion matrices; the diagonal axis displays the correct predictions for each class. In addition to the six study classes (blackleg, pink rot, dry rot, common scab, black scurf, and healthy), both matrices include a background row/column that aggregates:

- False positives (detections in regions without an assignable lesion).
- False negatives (missed lesions counted against the expected class as background).




Figure 4
Confusion matrix – YOLOv12




Figure 5

Confusion matrix – YOLOv26

Performance by class

Based on the confusion matrices, precision and recall were calculated for each class.

Table 2
Class-wise metrics – YOLOv12

Class	Precision	Recall
Blackleg	50,00 %	75,00 %
Pink rot	61,54 %	66,67 %
Dry rot	35,71 %	41,67 %
Common scab	33,33 %	90,00 %
Black scurf	60,00 %	52,94 %
Healthy	92,31 %	86,96 %

Table 3
Class-wise metrics - YOLOv26

Class	Precision	Recall
Blackleg	78,57 %	64,71 %
Pink rot	61,54 %	66,67 %
Dry rot	35,71 %	41,67 %
Common scab	33,33 %	90,00 %
Black scurf	60,00 %	52,94 %
Healthy	92,31 %	86,96 %

Table 4
Class-wise metrics – RF-DETR

Class	Precision	Recall
Blackleg	67,00 %	35,00 %
Pink rot	100,00 %	75,00 %
Dry rot	53,00 %	75,00 %
Common scab	50,00 %	100,00 %
Black scurf	93,00 %	82,00 %
Healthy	92,00 %	88,00 %

Key Findings: Comprehensive Comparison Between Models

Based on Tables 1, 2, 3, and 4, several important findings enable a comprehensive comparison between the models.

Overall comparison (accuracy and localization)

Based on the results (Table 1), the following observations can be made:

- *Overall precision (P): YOLOv26 achieved the highest value (79.34%), followed by YOLOv12 (78.72%) and RF-DETR (70.86%).*
- *Overall recall (R): YOLOv12 performed slightly better (96.86%), followed closely by YOLOv26 (96.64%) and above RF-DETR (88.39%).*
- *mAP@0.50: RF-DETR achieved the highest score (85.61%), outperforming YOLOv12 (79.36%) and YOLOv26 (78.48%).*
- *mAP@0.50:0.95 (more stringent): RF-DETR also ranked first (82.64%), while YOLOv26 (73.55%) and YOLOv12 (73.26%) achieved similar results.*

The YOLO models exhibited higher point precision and overall sensitivity at the default threshold (high capability to avoid missing lesions and to control false positives at a fixed operating point).

RF-DETR achieved higher Average Precision at both relaxed IoU (0.50) and strict IoU (0.50–0.95), suggesting that throughout the threshold sweep the model better preserves the area under the precision–recall curve and produces more consistent bounding boxes in terms of localization.

Practical implication: If the application requires maximum sensitivity and a low cost of missed detections (screening), either YOLO model is an appropriate option using the default threshold. If localization quality is the priority (e.g., severity estimation by lesion area, lesion cropping for segmentation, or integration into a downstream pipeline), RF-DETR offers a consistent advantage in mAP, particularly across the 0.50–0.95 range.

Class-wise comparison (precision, recall and F1)

Class-wise results

- Blackleg
- YOLOv26: P = 78.57% (highest), R = 64.71%, F1 $\approx$ 71.00% (best balance).
- YOLOv12: P = 50.00%, R = 75.00% (highest recall), F1 $\approx$ 60.00%.
- RF-DETR: P = 67.00%, R = 35.00%, F1 $\approx$ 46.00%.
- Conclusion: YOLOv26 provides the best balance for this class; YOLOv12 recovers more true positives (higher R), making it useful when minimizing missed cases is critical; RF-DETR requires threshold calibration or additional training samples.

Pink Rot

- RF-DETR: P = 100.00%, R = 75.00%, F1 $\approx$ 86.00% (best).
- YOLOv12/YOLOv26: P = 61.54%, R = 66.67%, F1 $\approx$ 64.00%.
- Conclusion: RF-DETR is superior, combining zero false positives with high sensitivity for this class.

Dry Rot

- RF-DETR: P = 53.00%, R = 75.00%, F1 $\approx$ 62.00% (best).
- YOLOv12/YOLOv26: P = 35.71%, R = 41.67%, F1 $\approx$ 39.00%.
- Conclusion: The morphological variability of this lesion (diffuse/subepidermal boundaries) negatively affects the YOLO models using bounding boxes; RF-DETR handles localization better and detects more cases.

Common scab

- RF-DETR: P = 50.00%, R = 100.00%, F1 $\approx$ 67.00% (best).
- YOLOv12/YOLOv26: P = 33.33%, R = 90.00%, F1 $\approx$ 48.00%.
- Conclusion: RF-DETR reduces the over-detection typically observed in the YOLO models (low P) while maintaining maximum recall.

Black scurf

- RF-DETR: P = 93.00%, R = 82.00%, F1 $\approx$ 88.00% (clearly superior).
- YOLOv12/YOLOv26: P = 60.00%, R = 53.00%, F1 $\approx$ 56.00%.
- Conclusion: RF-DETR better distinguishes the texture and tonal characteristics of this lesion, minimizing confusion with common scab and background.

Healthy

- RF-DETR: P = 92.00%, R = 88.00%, F1 $\approx$ 94.00%.
- YOLOv12/YOLOv26: P = 92.00%, R = 87.00%, F1 $\approx$ 89.00%.
- Conclusion: All three models are robust, with RF-DETR showing a slight advantage.

Table 5
Best model by class

Class	Best precision	Best recall	Best F1	Key comment
Blackleg	YOLOv26 (78.57 %)	YOLOv12 (75,00 %)	YOLOv26 (~71.00 %)	YOLOv26 provides better balance; YOLOv12 maximizes sensitivity.
Pink rot	RF-DETR (100.00 %)	RF-DETR (75,00 %)	RF-DETR (~86.00 %)	RF-DETR achieves zero false positives with high recall.
Dry rot	RF-DETR (53.00 %)	RF-DETR (75,00 %)	RF-DETR (~62.00 %)	RF-DETR handles diffuse/subepidermal boundaries better.
Common scab	RF-DETR (50.00 %)	RF-DETR (100.00 %)	RF-DETR (~67.00 %)	Reduces YOLO over-detection.
Black scurf	RF-DETR (93.00 %)	RF-DETR (82,00 %)	RF-DETR (~88.00 %)	Better distinguishes texture and dark tones.
Healthy	RF-DETR (92.00 %)	RF-DETR (88.00 %)	RF-DETR (~90.00 %)	Marginal differences; all models are robust.

Discussion

General overview and consistency with the literature

Under a common protocol (same data split, input resolution, and training protocol), the three detectors achieved competitive performance, with parity between YOLOv12 and YOLOv26 in the overall metrics (P/R and mAP) and an advantage in mAP for RF-DETR (both at IoU = 0.50 and across the 0.50–0.95 range). According to the results, YOLOv12 achieved precision = 78.72%, recall = 96.86%, $\text{mAP}@0.50 = 79.36\%$, and $\text{mAP}@0.50:0.95 = 73.26\%$, whereas YOLOv26 obtained precision = 79.34%, recall = 96.64%, $\text{mAP}@0.50 = 78.48\%$, and $\text{mAP}@0.50:0.95 = 73.55\%$. In numerous contemporary agricultural applications, the YOLO family has become predominant because of its balance between speed and accuracy and its practical adoption in the field (including tubers and postharvest tasks), which is consistent with recent systematic reviews and benchmarking studies (Badgujar et al., 2024; Divyanth et al., 2024).

The DETR family—and particularly its real-time variants—eliminates the need for NMS and leverages query-based bipartite matching, which often results in better localization consistency at strict IoU thresholds and precision–recall curves with greater area (AP) across a wide range of thresholds (Dahiya et al., 2025). This behavior has been documented for RT-DETR (CVPR 2024) (Zhao et al., 2024) and its implementations, which demonstrate simultaneous improvements in speed and AP compared with one-stage detectors and other classical DETR architectures. In addition,

agricultural applications using RF-DETR have begun to appear, reinforcing the relevance of including a transformer-based detector in this comparison (Blok et al., 2025; Öztürk & Şin, 2026).

Overall metrics: Point P/R vs. Integrated AP (IoU = 0.50 and 0.50–0.95)

Point metrics (P and R) depend on the confidence threshold and post-processing (e.g., NMS in YOLO), whereas $\text{mAP}@0.50$ and $\text{mAP}@0.50:0.95$ integrate the area under the precision–recall curve across threshold sweeps (and, in COCO, across multiple IoU thresholds), providing a threshold-independent measure of classification and localization. This difference explains why a model may exhibit superior AP while simultaneously showing lower P/R at a given operating point: the global optimum of the curve does not necessarily coincide with the threshold used during validation or inference (Thibaut, 2023).

In the present results, RF-DETR achieved higher mAP at both 0.50 and 0.50–0.95, consistent with the literature reporting improved localization at strict IoU thresholds, elimination of NMS, and larger precision–recall areas due to higher-quality queries and efficient decoders (Parlak, 2026; Rahaman Sams et al., 2026). In contrast, YOLOv12 and YOLOv26 retained slightly better point recall and precision at the default Ultralytics threshold, a common pattern in one-stage detectors with NMS and highly optimized calibration for agricultural applications (Badgujar et al., 2024; Divyanth et al., 2024).

Class-wise performance: comparative interpretation and probable causes

Blackleg. YOLOv26 achieved the highest F1-score ($P \approx 79.00\%$; $R \approx 65.00\%$), providing the best balance between precision and sensitivity, whereas YOLOv12 retained the highest recall (75.00%), making it suitable for screening. The lower recall of RF-DETR suggests a suboptimal threshold or the need for additional samples for this specific class. This type of precision–recall trade-off between architectures has been observed in agricultural benchmarks, where texture and moisture influence inter-class confusion (Badgujar et al., 2024).

Pink Rot. RF-DETR performed best ($P = 100.00\%$; $R = 75.00\%$), achieving zero false positives and high recall at the selected operating point. The precision–recall curve for this class tends to dominate across thresholds, consistent with the advantages of transformers in contextual representation and spatial consistency (Zhao et al., 2024).

Dry Rot. RF-DETR outperformed YOLO in recall and F1-score. Its superior performance with diffuse lesion boundaries and subepidermal manifestations suggests that the cost function ($L1 + \text{GloU}$) and one-to-one matching reduce the penalty at high IoU thresholds. Nevertheless, the literature agrees that internal or incipient lesions require NIR/SW-NIR/HSI imaging to improve sensitivity, reinforcing a future multimodal approach (Prasetyo et al., 2024; F. Zhang et al., 2024).

Common Scab vs. Black Scurf. The YOLO models exhibited over-detection of common scab (low precision, high recall), whereas RF-DETR improved the balance (higher precision and recall), probably because it better captures the granular texture and spatial context of *Rhizoctonia solani* sclerotia (black scurf) and their variability (AG-3,

etc.), which are known to produce visual ambiguities in potato tubers (Chaudhary et al., 2023; Potato - *Rhizoctonia Solani* (Stem Canker & Black Scurf), 2025).

Healthy. All three models were robust (high precision and recall, with a slight advantage for RF-DETR), a result consistent with applications involving tubers and postharvest inspection as well as reviews of YOLO-based agricultural applications (Badgujar et al., 2024; Divyanth et al., 2024).

Statistical validity and transparency

Given the size of the test set ($n = 57$), small differences (≤ 1 percentage point) may not be statistically significant. It is recommended to apply image- or instance-level bootstrapping to obtain 95.00% confidence intervals for precision, recall, mAP, and F1-score, as well as permutation tests to evaluate the null hypothesis of “no difference.” In addition, reporting precision–recall curves together with the points of maximum F1 (overall and per class) is recommended to align the operating point with the desired risk policy (cost of false negatives versus false positives). These practices are consistent with the COCO evaluation protocol and recent guidelines for mAP and precision–recall analysis (Thibaut, 2023; F. Zhang et al., 2024).

Practical ICT implications

- 1. System architecture (edge ↔ cloud)

The results support a hybrid design consisting of edge inference (cameras/SoC/Jetson) for real-time response and event-driven transmission of ambiguous cases to the cloud for auditing and re-annotation. The YOLO family is widely adopted in agriculture because of its low latency and ease of deployment, whereas

RF-DETR provides end-to-end detection without NMS, simplifying the post-processing pipeline on resource-constrained devices while offering superior AP at strict IoU thresholds (Badgujar et al., 2024; F. Zhang et al., 2024).

2. Model selection according to the use case (operating points)

For high-throughput screening (avoiding missed lesions), a YOLO model calibrated with a low confidence threshold maximizes recall. For diagnosis requiring severity quantification (high IoU), RF-DETR provides higher mAP@0.50:0.95 and more consistent bounding boxes throughout the threshold sweep. Precision–recall curves and COCO mAP are the recommended tools for selecting class-specific thresholds according to the cost of errors (Thibaut, 2023; Zhao et al., 2024).

• 3. Two-Stage Pipelines (Screening → Refinement)

A YOLO → RF-DETR workflow reduces computational cost on edge devices (fast detection) while increasing precision and IoU for positive detections (NMS-free refinement), a strategy already suggested in agricultural computer vision benchmarking and consistent with the real-time RT-DETR evidence (Zhou et al., 2025).

• 4. Multimodality for internal lesion

For dry rot and other subepidermal lesions, integrating NIR/SW-NIR/HSI into the ICT pipeline improves early detection, overcoming the limitations of RGB imaging. Late fusion or routing suspicious samples to an NIR/HSI inspection station are scalable strategies for processing plants operating under cycle-time constraints (Prasetyo et al., 2024; F. Zhang et al., 2024).

Conclusions

1. Comparative Performance and Operational Feasibility

Under the same experimental protocol—identical dataset, stratified split, and input resolution (640 px)—the YOLO family detectors and the transformer-based RF-DETR model proved to be viable for the early detection of diseases in postharvest potato tubers. YOLOv12 and YOLOv26 showed comparable performance in terms of precision and recall, whereas RF-DETR achieved higher mAP values at both IoU = 0.50 and across the 0.50–0.95 range. These results indicate the suitability of both paradigms for integration into automated agricultural inspection systems with moderate computational resources.

2. Sensitivity, localization, and selection according to the use case

The comparative analysis revealed a systematic trade-off between sensitivity and localization accuracy. The YOLO models exhibited slightly higher recall at the default threshold, making them suitable for large-scale screening scenarios where minimizing false negatives is a priority. In contrast, RF-DETR demonstrated stricter and more consistent localization, reflected in its advantage in mAP@0.50:0.95, attributed to its one-to-one assignment mechanism and the absence of non-maximum suppression. This behavior is particularly relevant when precise lesion delineation is required for severity estimation or subsequent classification.

3. Class-wise Behavior and Limitations of the RGB Approach

The confusion matrix analysis identified error patterns specific to the agricultural domain. In particular, the confusion between common scab and black scurf is explained by phenotypic similarities in surface texture and coloration, as reported in the phytopathological literature. Likewise, subepidermal lesions associated with *Fusarium* spp. exhibited higher false-negative rates and lower spatial overlap, highlighting an inherent limitation of using RGB images alone for the early detection of internal damage.

4. Practical implications and recommended architecture

Based on the obtained results, a two-stage functional architecture is proposed: an initial YOLO-based detection stage aimed at maximizing sensitivity and enabling rapid screening, followed by a second stage using RF-DETR for localization refinement and IoU improvement. This combination balances computational efficiency and spatial precision and can be further enhanced through calibration techniques and, when the objective is to reduce missed detections of incipient lesions, by late fusion with NIR or HSI spectral information. Overall, the findings suggest the feasibility of developing an automated, accurate, and scalable tool aligned with the requirements of real-time monitoring systems and edge computing in postharvest environments.

Conflict of interest statement

The authors declare that they have no conflicts of interest.

Funding sources

The author declares that this research received no external funding from any public, commercial,

or non-profit funding agency.

Author contributions (CRediT):

Manolo Sebastián Muñoz-Espinoza: Conceptualization; methodology; software; validation; formal analysis; investigation; resources; data

curation; writing – original draft; writing – review and editing; visualization; supervision; project administration.

Referencias

- Aleinzi, M. (2025). Enhancing precision agriculture with YOLOv8: A deep learning approach to potato disease identification. *International Journal of Advanced Computer Science and Applications*, 16(4), 1156–1166.
<https://doi.org/10.14569/IJACSA.2025.01604110>
- Badgujar, C. M., Poulouse, A., & Gan, H. (2024). Agricultural object detection with You Look Only Once (YOLO) algorithm: A bibliometric and systematic literature review. *Computers and Electronics in Agriculture*, 223.
<https://doi.org/10.1016/j.compag.2024.109090>
- Blok, P. M., Wang, H., Suh, H. K., Wang, P., BurrIDGE, J., & Guo, W. (2025). PointRAFT: 3D deep learning for high-throughput prediction of potato tuber weight from partial point clouds [Preprint]. *arXiv*.
<https://doi.org/10.48550/arXiv.2512.24193>
- Chaudhary, S., Lal, M., Sagar, S., Sharma, S., & Kumar, M. (2023). Black scurf of potato: Insights into biology, diagnosis, detection, host-pathogen interaction, and management strategies. *Tropical Plant Pathology*, 49(2), 169–192.
<https://doi.org/10.1007/s40858-023-00622-4>
- Dahiya, N., Prakash, D., Kundu, S., Kuttan, S. R., Suwalka, I., Ayadi, M., Dubale, M., & Hashmi, A. (2025). Optimised RFO tuned RF-DETR model for precision urine microscopy for renal and systemic disease diagnosis. *Scientific Reports*, 15(1), 25842.
<https://doi.org/10.1038/s41598-025-11725-0>
- Divyanth, L. G., Khanal, S. R., Paudel, A., Mattupalli, C., & Karkee, M. (2024). Efficient detection of eyes on potato tubers using deep-learning for robotic high-throughput sampling. *Frontiers in Plant Science*, 15, 1512632.
<https://doi.org/10.3389/fpls.2024.1512632>
- Ephytia. (2025, July 24). Potato—Rhizoctonia solani (stem canker & black scurf). <https://ephytia.inra.fr/en/C/20899/Potato-Rhizoctonia-solani-Stem-canker-Black-scurf>
- Faria, F. T. J., Moin, M. Bin, & Wase, A. Al. (2023). *Potato Diseases Datasets* [Conjunto de datos]. Kaggle.
<https://doi.org/10.34740/KAGGLE/DSV/7203264>

- Geoffrey Manurung, D., Ryan Pinasthika, M., Obila Vasya, M. A., Dwi Setya Putri, R. A., Parasian Tampubolon, A., Fadhil Prayata, R., Khoirin Nisa, S., & Yudistira, N. (2024). Deteksi dan klasifikasi hama potato beetle pada tanaman kentang menggunakan YOLOV8. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 11(4), 723–734.
<https://doi.org/10.25126/jtiik.1148092>
- Guillemette, A. M., Casanova, G. H., Hamilton, J. P., Pokorná, E., Dobrev, P. I., Motyka, V., Rashotte, A. M., & Leisner, C. P. (2024). The physiological and molecular responses of potato tuberization to projected future elevated temperatures. *Plant Physiology*, 197(1), 664.
<https://doi.org/10.1093/PLPHYS/KIAE664>
- He, Y., Peng, Y., Wei, C., Zheng, Y., Yang, C., & Zou, T. (2024). Automatic disease detection from strawberry leaf based on improved YOLOv8. *Plants*, 13(18), 2256
<https://doi.org/10.3390/PLANTS13182556>
- Jayanthi, J., & Kumar, K. A. (2024). Transformative impact of AI-driven computer vision in agriculture. En *Artificial intelligence techniques in smart agriculture* (pp. 129–150). Springer
https://doi.org/10.1007/978-981-97-5878-4_9
- Jocher, G., & Qiu, J. (2026). *Ultralytics YOLO26* [Software]. GitHub.
<https://github.com/ultralytics/ultralytics>
- Keithellakpam, L. B., Karunakaran, C., Singh, C. B., Jayas, D. S., & Danielski, R. (2026). A comprehensive review on pre- and post-harvest perspectives of potato quality and non-destructive assessment approaches. *Applied Sciences*, 16(1), 190
<https://doi.org/10.3390/APP16010190>
- Liu, C. (2024). Advancing strawberry disease detection in agriculture: A transfer learning approach with YOLOv5 algorithm. *International Journal of Advanced Computer Science and Applications*, 15(3), 1013–1022.
<https://dx.doi.org/10.14569/IJACSA.2024.01503101>
- Ma, P., Li, C., Rahaman, M. M., Yao, Y., Zhang, J., Zou, S., Zhao, X., & Grzegorzec, M. (2022). A state-of-the-art survey of object detection techniques in microorganism image analysis: From classical methods to deep learning approaches. *Artificial Intelligence Review*, 56(2), 1627–1698.
<https://doi.org/10.1007/S10462-022-10209-1>

- Muñoz Espinoza, M., Moreno Castillo, W. E., y Palacios Ruiz, F. P. (2026). Detección de enfermedades en papa mediante deep learning usando YOLOv12. *Ciencias de la Ingeniería y Aplicadas*, 10(1), 119–129.
<https://doi.org/10.61236/CIYA.V10I1.1239>
- Moreno Mayhuire, J. S., & Herrera Quispe, J. A. (2023). Modelos de aprendizaje automático para la clasificación de enfermedades de la *Solanum tuberosum*: Una revisión sistemática de la literatura. *Revista de Investigación de Sistemas e Informática*, 16(2), 129–137.
<https://doi.org/10.15381/risi.v16i2.25980>
- Nagel, M., Dulloo, M. E., Bissessur, P., Gavrilenko, T., Bamberg, J., Ellis, D., & Giovannini, P. (2022). *Global strategy for the conservation of potato*. Leibniz Institute of Plant Genetics and Crop Plant Research.
<https://doi.org/10.5447/IPK/2022/29>
- Öztürk, L., & Şin, B. (2026). Real-time transformer-based object detection for advanced plant disease recognition: The grapevine fanleaf virus example. *Applied Fruit Science*, 68(1).
<https://doi.org/10.1007/s10341-026-01777-5>
- Palacio Betancur, S., & Bolaños Martínez, F. (2025). Tomato (*Solanum lycopersicum* L.) leaf disease detection using computer vision. *Revista Facultad Nacional de Agronomía*, 78(3), 11203–11212.
<https://doi.org/10.15446/rfnam.v78n3.116493>
- Parlak, C. (2026). Evaluation of cutting-edge object detection architectures on multi-object and single-object datasets. *Black Sea Journal of Engineering and Science*, (9)1. 287-294.
<https://doi.org/10.34248/bsengineering.1736319>
- Prasetyo, E. W., Amanah, H. Z., Farras, I., Pahlawan, M. F. R., & Masithoh, R. E. (2024). Detection of *Fusarium spp.* infection in potato (*Solanum tuberosum* L.) during postharvest storage through visible-near-infrared and shortwave-near-infrared reflectance spectroscopy. *Open Agriculture*, 9(1).
<https://doi.org/10.1515/opag-2022-0295>
- Qin, R., Wang, Y., Liu, X., & Yu, H. (2024). Advancing precision agriculture with deep learning enhanced SIS-YOLOv8 for Solanaceae crop monitoring. *Frontiers in Plant Science*, 15, 1485903.
<https://doi.org/10.3389/fpls.2024.1485903>
- Rahaman Sams, F., Kazi Supti, S., Binte Hamid, S., Junayed, R., Fahim A Bari, K. M., Junaeid Ali, M., Gani, R., Shams, K., Rifat Ahmmad Rashid, M., & Ul Islam, R. (2026). Real-time sunflower detection using semi-supervised and self-supervised deep learning for precision agriculture. *Smart Agricultural Technology*, 13, 101684.
<https://doi.org/10.1016/J.ATECH.2025.101684>

- Redmon, J. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Robinson, I., Robicheaux, P., Popov, M., Ramanan, D., & Peri, N. (2026). RF-DETR: Neural architecture search for real-time detection transformers [Preprint]. arXiv.
<https://arxiv.org/abs/2511.09554>
- Roboflow. (2025). *Roboflow: Computer vision tools for developers and enterprises*.
<https://roboflow.com/>
- Sapkota, R., Cheppally, R. H., Sharda, A., & Karkee, M. (2025). YOLO26: Key architectural enhancements and performance benchmarking for real-time object detection [Preprint]. arXiv.
<https://arxiv.org/pdf/2509.25164>
- Sharma, S., Tiwari, R. K., Sagar, V., & Maharana, C. (2024). Soil- and tuber-borne diseases of potato. *En Approaches for potato crop improvement and stress management* (pp. 179–231).
https://doi.org/10.1007/978-981-97-1223-6_7
- Solankey, S. S. (Ed.). (2025). *Advances in research on potato production*. Springer.
<https://doi.org/10.1007/978-3-031-82710-5>
- Thibaut, L. (2023, August 13). *COCO evaluation metrics explained*. Picsellia.
<https://www.picsellia.com/post/coco-evaluation-metrics-explained>
- Tian, Y., Ye, Q., & Doermann, D. (2025, February 20). YOLO12: Attention-centric real-time object detectors [Preprint]. arXiv.
<https://arxiv.org/abs/2502.12524>
- Upeniece, L., Bimšteine, G., & Stramkale, V. (2025). The most important potato diseases and microbiological agents for their control: A review. *Research for Rural Development 2025: Annual 31st International Scientific Conference Proceedings* (Vol. 1, pp. 17–23). Latvia University of Life Sciences and Technologies.
<https://doi.org/10.22616/RRD.31.2025.003>
- Yurdakul, M., Sazak, H., Kotan, M., & Taşdemir, T. (2026). *A review of YOLO family from YOLOv1 to YOLO26* [Preprint]. Preprints.org
<https://doi.org/10.20944/PREPRINTS202602.1844.V1>

- Zhang, F., Wang, W. X., Wang, C. S., Zhou, J., Pan, Y., & Sun, J. F. (2024). Study on hyperspectral detection of potato dry rot in gley stage based on convolutional neural network. *Spectroscopy and Spectral Analysis*, 44(2), 480-489.
[https://doi.org/10.3964/j.issn.1000-0593\(2024\)02-0480-10](https://doi.org/10.3964/j.issn.1000-0593(2024)02-0480-10)
- Zhang, J., Xie, J., Zhang, F., Gao, J., Yang, C., Song, C., Rao, W., & Zhang, Y. (2024). Greenhouse tomato detection and pose classification algorithm based on improved YOLOv5. *Computers and Electronics in Agriculture*, 216, 108519.
<https://doi.org/10.1016/J.COMPAG.2023.108519>
- Zhao, Y., Lv, W., Xu, S., Wei, J., Wang, G., Dang, Q., Liu, Y., & Chen, J. (2024). DETRs beat YOLOs on real-time object detection. En *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 16965–16974).
<https://zhao-yian.github.io/RTDETR>.
- Zhou, H., Liu, Y., & Wang, J. (2025). Railway fastener defect detection using RFD-DETR: A lightweight real-time transformer-based approach. *PLOS ONE*, 20(11), e0331513.
<https://doi.org/10.1371/JOURNAL.PONE.0331513>

REVISIONES SISTEMÁTICAS

/ Systematic Reviews

Floricultura 4.0 en el Ecuador:

retos y directrices para la integración de tecnologías digitales y políticas públicas en el mejoramiento genético y la innovación productiva

Floriculture 4.0 in Ecuador: Challenges and guidelines for the integration of digital technologies and public policies in genetic improvement and productive innovation

Xavier Rojas-Ruilova ¹

Génesis Vásquez²

Isabel Marques³

¹Universidad Nacional de Loja, Facultad de la Salud Humana, Loja, Ecuador,
<https://orcid.org/0000-0002-5692-5366>
xavier.rojas@unl.edu.ec

²Universidad Nacional de Loja, Facultad de Energía, Loja, Ecuador,
<https://orcid.org/0000-0002-9632-5429>
genesis.vasquez@unl.edu.ec

³University of Lisbon, Forest Research Centre, Associate Laboratory TERRA, School of Agriculture, Lisboa, Portugal,
<https://orcid.org/0000-0001-9788-4831>
isabelmarques@isa.ulisboa.pt

DOI: 10.61854/rccedia.v1n1.006

Enviado: 20 de enero de 2026

Aprobado: 08 de abril de 2026

Publicado: martes 14 de julio de 2026



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Resumen

La floricultura ecuatoriana se encuentra en un proceso de transformación impulsado por la digitalización, la biotecnología y la ciencia de datos. Este estudio examina el papel de las tecnologías de la información y la comunicación (TIC), la bioinformática y el análisis de big data en el mejoramiento genético, con especial énfasis en el contexto nacional. Mediante una revisión exploratoria de la literatura científica, se identifican patrones emergentes en la adopción de tecnologías digitales para el desarrollo de nuevas variedades florales. Los resultados evidencian un claro desequilibrio en el panorama tecnológico actual, caracterizado por un predominio de herramientas digitales orientadas a la producción, como sensores IoT e inteligencia artificial, frente a una integración aún limitada de enfoques bioinformáticos y genómicos. Esta asimetría sugiere que la innovación en la floricultura ecuatoriana está siendo impulsada principalmente por la optimización del manejo del cultivo, más que por avances en la base genética de los sistemas productivos. No obstante, la incorporación de herramientas genómicas en especies ornamentales presenta un alto potencial para perfeccionar la eficiencia del mejoramiento genético, mediante la identificación de genes asociados a rasgos de interés y tolerancia al estrés, contribuyendo al desarrollo de sistemas de producción más resilientes y competitivos. En este contexto, los resultados subrayan la necesidad de fortalecer políticas públicas que promuevan la integración de capacidades genómicas y bioinformáticas dentro del sector florícola. Esto incluye la inversión en infraestructura científica, la formación de capital humano especializado y el fomento de alianzas entre academia, sector productivo y entidades gubernamentales. Una estrategia coordinada en esta dirección podría posicionar al Ecuador como un referente regional en floricultura 4.0, articulando innovación tecnológica con el aprovechamiento sostenible de su biodiversidad.

Palabras clave:

flores, bioinformática, big data, industria, innovación digital, orquídeas.

Introducción

La floricultura constituye uno de los sectores agrícolas más dinámicos del Ecuador, reconocido a nivel internacional por la calidad y diversidad de sus flores de corte, especialmente las rosas (Guaita-Pradas y otros, 2023). Desde su consolidación en la década de 1990, esta industria ha contribuido de manera significativa al producto interno bruto (PIB) agroexportador, “sumando más de 65 mil empleos directos y 55 mil empleos indirectos, con una participación destacada de mujeres, quienes representan el 51 % de la fuerza laboral”¹.

Según datos del Banco Central del Ecuador (BCE, 2024), entre enero y noviembre de 2024 las exportaciones florícolas alcanzaron 925 millones de dólares, con un crecimiento interanual del 2,6 % y un volumen superior a 160 000 toneladas, consolidando al país como el tercer exportador mundial después de los Países Bajos y Colombia (BCE, 2024). La producción florícola en el Ecuador ha estado históricamente concentrada en el norte del país, en las provincias de Pichincha y Cotopaxi, que representan conjuntamente más del 80 % de la producción nacional, mientras que el restante proviene de otras provincias del país, entre ellas Guayas, Imbabura y Azuay (Mañay y otros, 2022).

Sin embargo, la competitividad del sector florícola enfrenta actualmente una transición estructural marcada por la digitalización, la sostenibilidad y la innovación biotecnológica. La demanda global exige nuevas variedades con mayor vida útil, resistencia a enfermedades, tolerancia al transporte y adaptación al cambio climático

(Casigña y otros, 2024). En este contexto, las tecnologías de la información y la comunicación (TIC), junto con la bioinformática y el análisis de big data, emergen como pilares de una nueva etapa de innovación agrobiotecnológica (García Torres y otros, 2024; Chavarro, 2021). En este marco, las TIC contribuyen a optimizar el uso de recursos, anticipar problemas fitosanitarios, mejorar la trazabilidad y reducir pérdidas poscosecha, al tiempo que facilitan modelos de gestión basados en datos y estrategias de innovación orientadas a la sostenibilidad (Vernier y otros, 2021; Abbes, 2025).

En la práctica, estas tecnologías se materializan en múltiples aplicaciones, como la automatización de invernaderos, la sensorización ambiental, el riego inteligente y la trazabilidad digital (Pandiyan y otros, 2024; Dai y otros, 2025; Peña-Holguín y otros, 2025; Kumar & Verma, 2025). Por ejemplo, los sensores IoT instalados en invernaderos permiten registrar variables como temperatura, humedad, radiación y concentración de CO₂, cuyos datos son procesados en plataformas en la nube mediante modelos predictivos que optimizan el crecimiento y la floración (Hosny y otros, 2025; Soussi y otros, 2025). En paralelo, el uso de tecnologías *blockchain* permite reforzar la trazabilidad del proceso productivo y aumentar la transparencia en mercados internacionales cada vez más sensibles a criterios de sostenibilidad (de Carvalho y otros, 2022; Chen y otros, 2023; Pang y otros, 2024; Thuy y otros, 2025).

Paralelamente, la convergencia entre biología molecular, bioinformática y análisis de datos

¹ Ecuador reafirma su liderazgo en la industria florícola mundial con la inauguración de Expo Flor 2024 – Ministerio de Producción, Comercio Exterior e Inversiones, n.d.

ha impulsado avances significativos en el mejoramiento genético vegetal (Hasan y otros, 2021; Khan y otros, 2022; Panahi y otros, 2024; Belbase y otros, 2025; Li y otros, 2025; Salgado-Velázquez y otros, 2026). El uso de marcadores moleculares, secuenciación genómica y enfoques transcriptómicos permite identificar regiones genómicas y genes asociados a rasgos de interés, como color, aroma, resistencia a patógenos o tolerancia al estrés ambiental (Kim y otros, 2020; Koboldt y otros, 2013; Berman y otros, 2025; Pei y otros, 2026). Asimismo, enfoques como el mapeo de QTL, los estudios de asociación genómica (GWAS) y la edición génica mediante CRISPR amplían las posibilidades de mejora dirigida y exploración funcional de genes (Doll y otros, 2019; Li y otros, 2025; Verdezoto-Prado y otros, 2025).

A su vez, la integración de herramientas genómicas con modelos predictivos basados en inteligencia artificial está acelerando los programas de mejoramiento y ampliando las posibilidades de selección de rasgos complejos (Yang y otros, 2022; Afonso y otros, 2024; Mantilla y otros, 2025). La experiencia internacional muestra que estos enfoques permiten acortar los tiempos de desarrollo varietal y mejorar la selección anticipada de progenitores. Por ejemplo, en *Chrysanthemum morifolium* se ha demostrado el potencial de la predicción genómica para identificar combinaciones con rasgos comerciales deseables (OECD, 2015; Kim y otros, 2024; Su y otros, 2024).

A pesar del creciente interés en la digitalización del sector florícola, persiste una fragmentación en la literatura que dificulta comprender de manera integrada las oportunidades, limitaciones y desafíos asociados a la transición hacia una floricultura 4.0 en el país. Estudios recientes han analizado la adopción de tecnologías TIC en el

sector florícola, evidenciando que, aunque existe un alto potencial de mejora en eficiencia y sostenibilidad, su implementación en países emergentes como el Ecuador sigue siendo limitada debido a barreras económicas, técnicas y de capacitación (Mantilla y otros, 2025). Estos enfoques se han centrado principalmente en la adopción tecnológica a nivel productivo, mientras que la bioinformática, la inteligencia artificial y el mejoramiento genético, como componentes clave de la innovación florícola, han recibido una atención significativamente menor.

En este contexto, el presente estudio se plantea como una revisión exploratoria con orientación analítica, cuyo propósito es sintetizar y estructurar el conocimiento disponible sobre el papel de las tecnologías digitales en la floricultura ecuatoriana, integrando perspectivas tecnológicas, genómicas y productivas. A partir de este enfoque, se formulan las siguientes preguntas de investigación:

- (i) ¿Qué tecnologías están configurando el paradigma de la floricultura 4.0 en los procesos de producción y mejoramiento genético en floricultura y cuál es su relevancia en el contexto ecuatoriano?
- (ii) ¿Cuáles son las principales limitaciones estructurales, tecnológicas y formativas que condicionan su adopción en el Ecuador?
- (iii) ¿Qué oportunidades emergen de la convergencia entre TIC, bioinformática e inteligencia artificial para el desarrollo de una floricultura genética innovadora en el Ecuador?

Métodos

El presente estudio se desarrolló como una revisión exploratoria con enfoque cualitativo, incorporando elementos de revisión sistemática basados en las directrices de PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) (Page y otros, 2021). La identificación de fuentes se realizó mediante una búsqueda estructurada en la base de datos Scopus, utilizando operadores booleanos y combinaciones de términos definidos, incluyendo “digital agriculture” OR “bioinformatics” OR “artificial intelligence” OR “floriculture” AND “plant breeding” AND “Ecuador”. Scopus fue seleccionada como base de datos principal debido a su amplia cobertura de literatura revisada por pares en múltiples disciplinas, lo que garantiza una recuperación amplia y consistente de estudios relevantes.

Posteriormente, se llevó a cabo un proceso de selección en varias etapas, basado en la revisión de títulos, resúmenes y contenido completo, con el fin de identificar aquellos estudios alineados con los objetivos del trabajo. Para minimizar posibles sesgos, el proceso de cribado fue realizado de forma independiente por dos investigadores. Durante esta fase, se excluyeron 30 registros por no ajustarse al ámbito temático del estudio, incluyendo trabajos centrados en prácticas agrícolas no tecnológicas y cultivos fuera del sector florícola o sin relación con el mejoramiento

vegetal. Asimismo, se descartaron 32 registros adicionales por no corresponder a artículos científicos o revisiones (por ejemplo, libros u otros tipos de documentos no revisados por pares). Como resultado de este proceso, el conjunto final de análisis quedó conformado por 55 documentos, que constituyen la base de la revisión.

Este conjunto incluye un estudio de tipo revisión que integra evidencia procedente de 41 trabajos adicionales, lo que amplía el alcance empírico del corpus analizado. Además, el corpus fue clasificado según el tipo de tecnología y el campo de aplicación, lo que permitió realizar un análisis temático y cuantitativo de la literatura. Asimismo, los estudios seleccionados fueron analizados mediante una metodología de codificación temática, en la que cada documento fue categorizado según su enfoque tecnológico principal (por ejemplo, IoT, inteligencia artificial, bioinformática o mejoramiento genético) y su área de aplicación. Para ello, se construyó una matriz de extracción de datos que incluyó variables como tipo de tecnología, ámbito de aplicación, contexto geográfico y contribución principal del estudio. Esta información permitió identificar patrones recurrentes y cuantificar la distribución de enfoques tecnológicos dentro del corpus analizado, facilitando así la interpretación sistemática de los resultados.

Resultados

A partir del análisis de los 55 estudios seleccionados, clasificados mediante codificación temática según su enfoque tecnológico y área de aplicación, se identificaron patrones consistentes en la aplicación de tecnologías digitales en el sector florícola. En particular, 15 estudios se centraron en tecnologías IoT y sensores, 7 en inteligencia artificial y 8 incluyeron componentes relacionados con genética y mejoramiento. Los estudios restantes se distribuyen entre otras categorías tecnológicas o enfoques mixtos, reflejando la heterogeneidad del campo analizado (Figura 1).

Los estudios revisados muestran que la inteligencia artificial y el aprendizaje automático emergen como uno de los enfoques más recurrentes dentro de la literatura revisada, espe-

cialmente en aplicaciones relacionadas con la detección de enfermedades, la predicción de demanda, la clasificación de flores y la estimación de características fenotípicas mediante visión por computador.

Por otro lado, el análisis evidencia una presencia más limitada de estudios centrados en la aplicación de herramientas bioinformáticas y enfoques de mejoramiento genético en el contexto específico de la floricultura ecuatoriana. Asimismo, la mayoría de los estudios se desarrollan en contextos internacionales, con una representación reducida de investigaciones específicamente enfocadas en el Ecuador.




Figura 1

Distribución de los estudios incluidos en la revisión según categoría tecnológica.

Estos avances reflejan una transición emergente hacia una floricultura basada en datos, abriendo oportunidades para una producción más sostenible, eficiente y trazable. En este sentido, la Tabla 1 sintetiza las principales tecnologías identificadas, sus aplicaciones y su nivel de adop-

ción en el contexto ecuatoriano, evidenciando un desarrollo desigual entre tecnologías, con mayor consolidación en herramientas de monitoreo y automatización y un estado aún incipiente en bioinformática y edición génica.

Tabla 1

Tecnologías consideradas prioritarias para la transición hacia la floricultura 4.0 en el Ecuador, según su aplicación y nivel de adopción

Tecnología	Aplicación en floricultura	Beneficios principales	Nivel de adopción en el Ecuador
IoT y sensores climáticos	Monitoreo ambiental, riego y fertilización de precisión	Ahorro hídrico, control automatizado	Medio
Big data y analítica predictiva	Procesamiento de datos genómicos y fenotípicos	Mejora en selección varietal y trazabilidad	Bajo
Bioinformática	Identificación de genes asociados a color, resistencia y aroma	Aceleración del mejoramiento genético	Bajo
Inteligencia artificial (IA)	Predicción de floración, control de plagas, análisis de imágenes	Mayor eficiencia y reducción de pérdidas	Bajo
Blockchain	Certificación de origen y sostenibilidad	Trazabilidad y confianza comercial	Muy bajo
Edición génica (CRISPR)	Modificación precisa de rasgos de interés	Innovación genética y resiliencia	Experimental

Discusión

Potencialidades de la innovación digital en la floricultura ecuatoriana

Los resultados obtenidos evidencian un claro predominio de tecnologías digitales aplicadas a la producción, como *IoT*, sensores e inteligencia artificial, frente a una menor representación de enfoques centrados en bioinformática y mejoramiento genético. Este patrón sugiere que la transformación digital de la floricultura ha avanzado principalmente en la optimización de procesos productivos (Montalvo, 2025), mientras que la integración con la innovación genética permanece aún limitada.

En este contexto, el caso ecuatoriano representa una oportunidad estratégica para avanzar hacia modelos más integrados de floricultura 4.0, aunque existen esfuerzos incipientes en universidades, que han iniciado proyectos piloto de análisis de imágenes florales y modelado predictivo de rendimiento (Pérez-Campdesuñer y otros, 2025). La incorporación de TIC no debe entenderse únicamente como una modernización tecnológica, sino como un cambio de paradigma que transforma la forma en que se conciben la investigación, la producción y la comercialización.

A pesar de los aportes de este estudio, es importante reconocer ciertas limitaciones inherentes al enfoque metodológico adoptado al tratarse de una revisión basada principalmente en la base de datos Scopus. Igualmente, la limitada disponibilidad de estudios específicos sobre el contexto ecuatoriano restringe la capacidad de generalización de algunos resultados, lo que pone de manifiesto la necesidad de futuras investigaciones empíricas que profundicen en la

incorporación de tecnologías digitales y genómicas en la floricultura nacional.

Integración de la bioinformática y el mejoramiento genético

Los escasos hallazgos de nuestra exploración evidencian una limitación en el avance del mejoramiento genético en floricultura en el Ecuador. En contraste con el predominio de tecnologías digitales encauzadas a la producción que se identificó en los resultados, hay una falta de información molecular. Sin embargo, la irrupción de la bioinformática y el análisis de big data permite transformar este panorama, lo que posibilita procesar grandes volúmenes de información genética, transcriptómica, fenotípica y ambiental con un nivel de resolución sin precedentes.

El Ecuador, al poseer una de las floras más diversas del planeta, tiene el potencial de convertirse en un centro regional de big data florícola, integrando información genómica de especies nativas con datos fenotípicos generados por empresas exportadoras. Por ejemplo, el país alberga más de 4 000 especies nativas de Orchidaceae, de las cuales una gran proporción son endémicas y aún poco estudiadas genéticamente (Vega y otros, 2013). Esta riqueza convierte al país en un laboratorio natural para aplicar herramientas de bioinformática, análisis de datos masivos e inteligencia artificial orientadas tanto a la conservación como al mejoramiento genético.

Plataformas internacionales han permitido avanzar en el análisis de secuencias, la identificación de genes y la exploración de rutas metabólicas relacionadas con rasgos florales como el color, la forma o la fragancia (Chen y

otros, 2022). Asimismo, adelantos recientes en genómica comparada y secuenciación de transcriptomas han posibilitado identificar genes implicados en la morfogénesis floral, la producción de pigmentos y la resistencia a estrés abiótico. Ejemplos como *Vanilla planifolia* (Gastelbond y otros, 2025; Hernández-Peña y otros, 2025) o *Cymbidium goeringii* (Ramya y otros, 2019) ilustran el potencial de estas herramientas para aplicaciones en calidad y sostenibilidad.

En el caso ecuatoriano, la floricultura de precisión podría beneficiarse de la incorporación de marcadores moleculares para acelerar programas de mejoramiento genético orientados a rasgos de interés comercial, tales como la longevidad poscosecha, la intensidad del color o la tolerancia a enfermedades y condiciones ambientales adversas (Abril-Espin y otros, 2024). De forma complementaria, la edición génica mediante tecnologías como CRISPR/Cas9 abriría la posibilidad de estudiar funciones génicas específicas o desarrollar variedades adaptadas a los distintos pisos altitudinales del país, sin comprometer la biodiversidad nativa (Motoche-Monar y otros, 2023; Gómez-Lama y otros, 2025; Verdezoto-Prado y otros, 2025). Esta estrategia permitiría optimizar recursos, reducir pérdidas y potenciar una floricultura resiliente frente al cambio climático, diversificando además la base genética de los cultivos ornamentales.

La consolidación de estas innovaciones requiere avanzar hacia la estandarización metodológica en el manejo de datos genómicos y fenotípicos, así como en la implementación de modelos predictivos reproducibles basados en inteligencia artificial (Caballero-Ramírez y otros, 2023; Montalvo y otros, 2025). El uso de plataformas de secuenciación de nueva generación, herramientas de análisis transcriptómico de novo y algoritmos de aprendizaje profundo aplicados a imágenes hiperespectrales permitirá generar modelos más precisos y transferibles entre especies ornamen-

tales (Anastasiou y otros, 2025; Cravero y otros, 2026). De este modo, la integración de la genómica con la fenómica digital y la inteligencia artificial consolidará la base de una floricultura inteligente, centrada en la innovación sostenible y el conocimiento científico como ventaja competitiva.

Retos y perspectivas hacia una floricultura 4.0 ecuatoriana

La escasa adopción de herramientas genómicas identificada en los resultados se traduce en barreras estructurales para el desarrollo de una floricultura 4.0 plenamente integrada en el Ecuador. A pesar del potencial identificado, la implementación de tecnologías digitales enfrenta obstáculos relacionados con la infraestructura tecnológica, la disponibilidad de recursos humanos especializados y la gobernanza de datos. En particular, la falta de conectividad, la limitada capacidad de almacenamiento y procesamiento de datos y la escasez de profesionales en bioinformática y ciencia de datos restringen el desarrollo del sector.

En este contexto, la creación de centros de excelencia y plataformas de transferencia tecnológica resulta clave para conectar investigación y producción. A su vez, la implementación de laboratorios vivos (*living labs*) en zonas florícolas ofrecería escenarios reales para validar, adaptar y escalar innovaciones tecnológicas. En estos espacios, las orquídeas ecuatorianas y otras especies ornamentales nativas se convertirían en modelos biológicos de referencia para integrar inteligencia artificial, genómica y fenómica digital. Este enfoque permitiría transformar la biodiversidad en capital biotecnológico, impulsando una nueva economía del conocimiento donde los datos genéticos y fenotípicos sean considerados activos estratégicos de alto valor.

Desde la perspectiva institucional, el Estado desempeña un papel fundamental en la creación de marcos regulatorios e incentivos que promuevan la adopción tecnológica (De Leon Nazareno, 2024). Esto se establece en la Política Pública para la Transformación Digital del Ecuador 2025–2030, tal como se incluye en la base legal de la Ley Orgánica para la Transformación Digital y Audiovisual, la Ley Orgánica de Telecomunicaciones, la Ley Orgánica de Gestión de Identidad y Datos Civiles, la Ley Orgánica del Sistema Nacional de Registro de Datos Públicos, la Ley Orgánica para la Optimización y Eficiencia de Trámites Administrativos y la Ley Orgánica de Protección de Datos Personales (MINTEL, 2025).

Avanzar hacia una floricultura 4.0 exige una visión articulada en torno a la sostenibilidad, la innovación y la valorización de la biodiversidad que resumimos en la Tabla 2. La integración de TIC, biotecnología y economía circular no solo permitirá mejorar la eficiencia productiva, sino también posicionar al Ecuador como líder regional en floricultura inteligente, capaz de exportar no solo flores, sino también conocimiento, tecnología y modelos de gestión sostenible. Este paradigma emergente redefine el papel del país en la bioeconomía global, promoviendo una producción más resiliente, trazable y alineada con la conservación de su patrimonio natural.

Tabla 2
Marco estratégico para la implementación de la floricultura 4.0 en el Ecuador, integrando dimensiones tecnológicas, socioeconómicas y ambientales

Eje estratégico	Componente tecnológico	Impacto esperado	Actores involucrados
Digitalización productiva	IoT, automatización, data analytics	Eficiencia, reducción de costos	Empresas florícolas, universidades
Innovación genética	Genómica, bioinformática, CRISPR	Nuevas variedades, resiliencia climática	Centros de investigación, universidades
Sostenibilidad ambiental	Energías limpias, blockchain, circularidad	Huella ecológica reducida, trazabilidad verde	Estado, certificadoras
Formación y talento	Educación STEM, redes tecnológicas	Empleo calificado, innovación local	Universidades, gobierno
Gobernanza de datos	Infraestructura digital, marcos legales	Protección biogenética, soberanía científica	Ministerio de Producción, academia

Conclusiones

En respuesta a las preguntas de investigación planteadas, los resultados de este estudio evidencian un desarrollo asimétrico en la transición hacia la floricultura 4.0, con un predominio de tecnologías digitales orientadas a la producción frente a una limitada adopción de herramientas bioinformáticas y enfoques de mejoramiento genético. Este desequilibrio señala una oportunidad estratégica para avanzar hacia modelos más integrados basados en datos, genómica e innovación.

En este contexto, el Ecuador, gracias a su biodiversidad y liderazgo exportador, cuenta con condiciones favorables para establecerse como un polo regional de innovación florícola digital. La inclusión de tecnologías como IoT, inteligencia artificial y big data permitirá optimizar la producción, mejorar la trazabilidad y acelerar el desarrollo de variedades adaptadas al cambio climático.

No obstante, este potencial depende de superar limitaciones estructurales relacionadas con la infraestructura tecnológica, la formación de capital humano especializado y la gobernanza de datos. En esta línea, la inversión en formación interdisciplinaria, en estandarización de datos y en fortalecimiento de redes de cooperación será clave para consolidar un sistema de innovación sostenible. En conjunto, la integración de TIC, biotecnología y biodiversidad posiciona a la floricultura ecuatoriana como un sector estratégico dentro de la bioeconomía, con capacidad para impulsar un modelo productivo más resiliente, competitivo y basado en conocimiento.

Declaración de conflictos de interés

Quienes firman este artículo declaran no tener conflictos de interés.

Fuentes de financiación

Esta investigación fue financiada por los Fondos Nacionales a través de la Fundación para la Ciencia y la Tecnología (FCT) mediante los proyectos con referencia UID/00239/2025 (CEF) y LA/P/0092/2020 (Laboratorio Asociado TERRA),

así como por I.M. a través del programa de Estímulo al Empleo Científico—Convocatoria Individual (CEEC Individual)—2021.01107.CEECIND/CP1689/CT0001.

Contribución de autoría (CRedit):

Xavier Rojas Ruilova: Conceptualización; metodología; análisis formal; investigación; validación; redacción – borrador original; redacción – revisión y edición; visualización; recursos; supervisión; administración del proyecto.

Génesis Vásquez: Conceptualización; metodología; análisis formal; gestión de datos; investigación; validación; redacción – borrador original; redacción – revisión y edición; visualización; software.

Isabel Marques: Conceptualización; metodología; análisis formal; investigación; validación; redacción – borrador original; redacción – revisión y edición; recursos; supervisión; adquisición de fondos.

Referencias

- Abbes, I. (2025). Strategic pathways for innovation and sustainability in digital transformation: Insights from leading global companies. *Social Sciences & Humanities Open*, 12, 101906.
<https://doi.org/10.1016/j.ssaho.2025.101906>
- Abril-Espin, E., Montes-Escobar, K., de la Hoz-M, J., Garcés-Fiallos, F. R., & Salas-Macias, C. A. (2024). Exploring global trends in scientific research on *Rubus glaucus* Benth: A comprehensive analysis integrating bibliometrics, LDA, and HJ-Biplot. *Journal of Berry Research*, 14(4), 287-300.
<https://doi.org/10.1177/187850932412849>
- Afonso, M., Paulo, M. J., Fonteijn, H., van den Helder, M., Zwinkels, H., Rijsbergen, M., van Hameren, G., Haegens, R., & Wehrens, R. (2024). Automatic trait estimation in floriculture using computer vision and deep learning. *Smart Agricultural Technology*, 7, 100383.
<https://doi.org/10.1016/j.atech.2023.100383>
- Anastasiou, E., Kasimati, A., Papadopoulos, G., Vatsanidou, A., Gemtou, M., Kantelhardt, J., Gabriel, A., Schwierz, F., Matavel, C.E., Meyer-Aurich, A., Maritan, E., Behrendt, K., Moroder, A., Bellingra-th-Kimura, S. D., Pedersen, S. M., Landi, A., Pesonen, L., Rojic, J., Kim, M., ... Denzer, H. (2025). Review and assessment of crop-related digital tools for agroecology. *Agronomy*, 15(11), 2600.
<https://doi.org/10.3390/agronomy15112600>
- Banco Central del Ecuador. (2024). *Resultados de comercio exterior: Abril 2024*.
https://contenido.bce.fin.ec/documentos/Estadisticas/SectorExterno/ComercioExterior/informes/ResultCE_042024.pdf
- Belbase, P., & Balaji Bhaskar, M.S. (2025). Sustainable cultivation of dragon fruit: integrated nutrient and pest management strategies for enhanced productivity and environmental stewardship. *Agronomy*, 15, 2514.
<https://doi.org/10.3390/agronomy15112514>
- Berman, A., Su, N., Li, Z., Landau, U., Chakraborty, J., Gerbi, N., Liu, J., Qin, Y., Yuan, B., Wei, W., Yanai, O., Mayrose, I., Zhang, Y., & Shani, E. (2025). Construction of multi-targeted CRISPR libraries in tomato to overcome functional redundancy at genome-scale level. *Nature Communications*, 16(1), 1–14.
<https://doi.org/10.1038/s41467-025-59280-6>

- Caballero-Ramirez, D., Baez-Lopez, Y., Limon-Romero, J., Tortorella, G., & Tlapa, D., (2023). An assessment of human inspection and deep learning for defect identification in floral wreaths. *Horticulturae* 9(11). 1213.
<https://doi.org/10.3390/horticulturae9111213>
- Casigña Guaman, N. S., Chicaiza Reisancho, E. R., Cali Palacios, M. A., Fiallos Ulloa, L. A., & Uvidia Armijo, J. H. (2024). Flores y suelo: Un estudio ambiental sobre las actividades florícolas en Los Ilinizas, Cotopaxi. *Ciencia Latina Revista Científica Multidisciplinar*, 8(1), 8249–8262.
https://doi.org/10.37811/cl_rcm.v8i1.10153
- Chavarro, J. (2021). *Evolución y desafíos de la floricultura ecuatoriana en el futuro próximo*. Metroflor.
<https://www.metroflorcolombia.com/evolucion-y-desafios-de-la-floricultura-ecuatoriana-en-el-futuro-proximo/>
- Chen, H. Y., Sharma, K., Sharma, C., & Sharma, S. (2023). Integrating explainable artificial intelligence and blockchain to smart agriculture: Research prospects for decision making and improved security. *Smart Agricultural Technology*, 6, 100350. doi: 10.1016/J.ATECH.2023.100350
- Chen, Y., Li, C., Hsiao, Y., Ho, S. Y., Zhang, Z., Liao, C., Lee, B., Lin, S., Wu, W., Wang, J., Zhang, D., Liu, K., Liu, D., Zhao, X., Li, Y., Ke, S., Zhou, Z., Huang, M., Wu, Y., ... Tsai, W. (2022). OrchidBase 5.0: Updates of the orchid genome knowledgebase. *BMC Plant Biology*, 22(1), 557.
<https://doi.org/10.1186/s12870-022-03955-5>
- Colantonio, V., Ferrão, L. F. V., Tieman, D. M., Bliznyuk, N., Sims, C., Klee, H. J., Munoz, P., & Resende, M. F. R. (2022). Metabolomic selection for enhanced fruit flavor. *Proceedings of the National Academy of Sciences of the United States of America*, 119(7), e2115865119.
<https://doi.org/10.1073/pnas.2115865119>
- Cravero, A., Sepúlveda, S., Gutiérrez, F., & Muñoz, L. (2026). From precision agriculture to intelligent agricultural ecosystems: A systematic review of machine learning and big data applications. *Agronomy*, 16(5).
<https://doi.org/10.3390/agronomy16050516>
- Dai, Y., Huang, Z., Khan, N., & Labbo, M. S. (2025). Smart water management: governance innovation, technological integration, and policy pathways toward economic and ecological sustainability. *Water*, 17(13), 1932.
<https://doi.org/10.3390/w17131932>

- Danilevicz, M. F., Upadhyaya, S. R., Batley, J., Bennamoun, M., Bayer, P. E., & Edwards, D. (2025). Understanding plant phenotypes in crop breeding through explainable AI. *Plant Biotechnology Journal*, 23(10), 4200–4213.
<https://doi.org/10.1111/pbi.70208>
- de Carvalho, P. R. V., Naoum-Sawaya, J., & Elhedhli, S. (2022). Blockchain-enabled supply chains: An application in fresh-cut flowers. *Applied Mathematical Modelling*, 110, 841–858.
<https://doi.org/10.1016/j.apm.2022.06.011>
- de Leon Nazareno, D. O. (2024). Transformación digital como factor de cambio de la matriz productiva de Ecuador. *Economía y Desarrollo*, 168(2), 1–22.
https://doi.org/10.37811/cl_rcm.v8i4.12331?no
- Doll, N. M., Gilles, L. M., Gérentes, M. F., Richard, C., Just, J., Fierlej, Y., Borrelli, V. M. G., Gendrot, G., Ingram, G. C., Rogowsky, P. M., & Widiez, T. (2019). Single and multiple gene knockouts by CRISPR–Cas9 in maize. *Plant Cell Reports*, 38(4), 487–501.
<https://doi.org/10.1007/s00299-019-02378-1>
- Fan, Z., Hasing, T., Johnson, T. S., Garner, D. M., Barbey, C. R., Colquhoun, T. A., Sims, C. A., Resende, M. F. R., & Whitaker, V. M. (2021). Strawberry sweetness and consumer preference are enhanced by specific volatile compounds. *Horticulture Research*, 8(1), 66.
<https://doi.org/10.1038/s41438-021-00502-5>
- Ferrão, L. F. V., Dhakal, R., Dias, R., Tieman, D., Whitaker, V., Gore, M. A., Messina, C., & Resende, M. F. R. (2023). Machine learning applications to improve flavor and nutritional content of horticultural crops through breeding and genetics. *Current Opinion in Biotechnology*, 83, 102968.
<https://doi.org/10.1016/j.copbio.2023.102968>
- García Torres, I. A., Castillo León, R. E., Navas Espín, W. R., & Veintimilla Andrade, J. G. (2024). El uso de la inteligencia artificial en un invernadero. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 910–930.
https://doi.org/10.37811/cl_rcm.v8i4.12331
- Gastelbondo, M., Micheal, V., Wang, Y., Chambers, A., & Wu, X. (2025). Comparative transcriptome profiling of vanilla (*Vanilla planifolia*) capsule development provides insights of vanillin biosynthesis. *BMC Plant Biology*, 25(1), 1–16.
<https://doi.org/10.1186/s12870-025-06360-w>

- Gómez-Lama Cabanás, C., & Mercado-Blanco, J. (2025). Groundbreaking technologies and the bio-control of fungal vascular plant pathogens. *Journal of Fungi*, 11(1), 77.
<https://doi.org/10.3390/jof11010077>
- Guaita-Pradas, I., Rodríguez-Mañay, L. O., & Marques-Perez, I. (2023). Competitiveness of Ecuador's flower industry in the global market in the period 2016–2020. *Sustainability*, 15(7), 5821.
<https://doi.org/10.3390/su15075821>
- Hasan, N., Choudhary, S., Naaz, N., Sharma, N., & Laskar, R. A. (2021). Recent advancements in molecular marker-assisted selection and applications in plant breeding programmes. *Journal of Genetic Engineering and Biotechnology*, 19(1) 128.
<https://doi.org/10.1186/s43141-021-00231-1>
- Hernández-Peña, R., Lorenzo-Manzanarez, J. L., Cruz-Ramírez, L. A., Reyes-López, D., Hernández-Domínguez, C., Pascual-Ramírez, F., & Ordaz-Ortiz, J. J. (2025). Unravelling vanillin biosynthesis: Integrative transcriptomic and metabolomic insights into pod development. *Journal of Agricultural and Food Chemistry*, 73(30), 19094.
<https://doi.org/10.1021/acs.jafc.5c05293>
- Hosny, K. M., El-Hady, W. M., & Samy, F. M. (2025). Technologies, protocols, and applications of internet of things in greenhouse farming: A survey of recent advances. *Information Processing in Agriculture*, 12(1), 91–111.
<https://doi.org/10.1016/j.inpa.2024.04.002>
- Khan, I. A., Cao, K., Guo, J., Li, Y., Wang, Q., Yang, X., Wu, J., Fang, W., & Wang, L. (2022). Identification of key gene networks controlling anthocyanin biosynthesis in peach flower. *Plant Science*, 316, 111151.
<https://doi.org/10.1016/j.plantsci.2021.111151>
- Kim, S. Y., Lee, H. Y., Park, C., Kim, D., Kim, J. B., Kim, S. H., Jeong, K. J., Pak, H. S., Jung, J. A., & Kim, T. S. (2024). Assessing amounts of genetic variability in key horticultural traits underlying core korean breeding lines of cut chrysanthemums. *Plants*, 13(5), 577.
<https://doi.org/10.3390/plants13050577>
- Koboldt, D. C., Steinberg, K. M., Larson, D. E., Wilson, R. K., & Mardis, E. R. (2013). The next-generation sequencing revolution and its impact on genomics. *Cell*, 155(1), 27–38.
<https://doi.org/10.1016/j.cell.2013.09.006>

- Kumar, V., & Verma, P. (2025). Advances in microbial biotechnology for sustainable wastewater reclamation: Recent trends and future prospects. *World Journal of Microbiology Biotechnology*, 41(12), 478.
<https://doi.org/10.1007/s11274-025-04674-3>
- Li, X., Li, Y., Sun, Y., Li, S., Cai, Q., Li, S., Sun, M., Yu, T., Meng, X., & Zhang, J. (2025). Integrating genetic diversity and agronomic innovations for climate-resilient maize systems. *Plants*, 14(10), 1552.
<https://doi.org/10.3390/plants14101552>
- Mañay, L. O. R., Guaita-Pradas, I., & Marques-Perez, I. (2022). Measuring the supply chain performance of the floricultural sector using the SCOR model and a multicriteria decision-making method. *Horticulturae*, 8(2), 168.
<https://doi.org/10.3390/horticulturae8020168>
- Mantilla, F., Mejía, G., & Tascón, D. (2025). The role of industry 4.0 technologies in the export flower industry: Insights from a systematic literature review and surveys in emerging economies. *Results in Engineering*, 25, 104507.
<https://doi.org/10.1016/j.rineng.2025.104507>
- Ministerio de Producción, Comercio Exterior e Inversiones. (2024, octubre 8). Ecuador reafirma su liderazgo en la industria florícola mundial con la inauguración de Expo Flor 2024.
<https://www.produccion.gob.ec/ecuador-reafirma-su-liderazgo-en-la-industria-floricola-mundial-con-la-inauguracion-de-expo-flor-2024/>
- Ministerio de Telecomunicaciones y de la Sociedad de la Información [MINTEL]. (2025). Política pública para la transformación digital del Ecuador 2025-2030.
https://www.gobiernoelectronico.gob.ec/wp-content/uploads/2025/03/INSTRUMENTO-Politica-Publica-para-la-Transformacion-Digital-Ecuador-2025-2030-MINTEL-signed_f.pdf
- Montalvo Rodríguez, S. P. (2025). Implementación de un sistema de gestión energética aplicado a la empresa “ESTRUCTIM”. *Arandu UTIC*, 12(1), 1946–1969.
<https://doi.org/10.69639/arandu.v12i1.720>
- Motoche-Monar, C., Ordoñez, J. E., Chang, O., Gonzales-Zubiate, F. A. (2023). gRNA Design: How its evolution impacted on CRISPR/Cas9 systems refinement. *Biomolecules*, 13(12), 1698.
<https://doi.org/10.3390/biom13121698>
- Nisio, A., Adamo, F., Acciani, G., & Attivissimo, F. (2020). Fast detection of olive trees affected by *Xylella fastidiosa* from UAVs using multispectral imaging. *Sensors*, 20(17), 4915.
<https://doi.org/10.3390/s20174915>

- Novielli, P., Romano, D., Pavan, S., Losciale, P., Stellacci, A. M., Diacono, D., Bellotti, R., & Tangaro, S. (2024). Explainable artificial intelligence for genotype-to-phenotype prediction in plant breeding: A case study with a dataset from an almond germplasm collection. *Frontiers in Plant Science*, 15, 1434229.
<https://doi.org/10.3389/fpls.2024.1434229>
- OECD. (2015). *Innovation, agricultural productivity and sustainability in Brazil* (OECD Food and Agricultural Reviews).
<https://doi.org/10.1787/9789264237056-en>.
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71.
<https://doi.org/10.1136/bmj.n71>
- Panahi, B., Mohammadzadeh Jalaly, H., & Hamid, R. (2024). Using next-generation sequencing approach for discovery and characterization of plant molecular markers. *Current Plant Biology*, 40, 100412.
<https://doi.org/10.1016/j.cpb.2024.100412>
- Pandiyani, P., Saravanan, S., Kannadasan, R., Krishnaveni, S., Alsharif, M. H., & Kim, M. K. (2024). A comprehensive review of advancements in green IoT for smart grids: Paving the path to sustainability. *Energy Reports*, 11, 5504–5531.
<https://doi.org/10.1016/j.egy.2024.05.021>
- Pang, S., Teng, S. W., Murshed, M., Bui, C., Karmakar, P., Li, Y., & Lin, H. (2024). A survey on evaluation of blockchain-based agricultural traceability. *Computers and Electronics in Agriculture*, 227, 109548.
<https://doi.org/10.1016/j.compag.2024.109450>
- Pei, X., Xie, J., Liang, C., & Utkina, A. O. (2026). Next-generation precision breeding in peanut (*Arachis hypogaea* L.) for disease and pest resistance: From multi-omics to AI-driven innovations. *Insects*, 17(1), 63.
<https://doi.org/10.3390/insects17010063>
- Peña-Holguín, R. R., Vaca-Coronel, C. A., Farías-Lema, R. M., Zapatier-Castro, S. V., & Valenzuela-Cobos, J. D. (2025). Smart agriculture in Ecuador: Adoption of IoT technologies by farmers in Guayas to improve agricultural yields. *Agriculture*, 15(15), 1679.
<https://doi.org/10.3390/agriculture15151679>

- Pérez-Campdesuñer, R., Sánchez-Rodríguez, A., García-Vidal, G., Martínez-Vivar, R., & De Miguel-Guzmán, M. (2025). Artificial intelligence in Ecuadorian SMEs: Drivers and obstacles to adoption. *Information*, 16(6), 443.
<https://doi.org/10.3390/info16060443>
- Ramya, M., Park, P. H., Chuang, Y. C., Kwon, O. K., An, H. R., Park, P. M., Baek, Y. S., Kang, B. C., Tsai, W. C., & Chen, H. H. (2019). RNA sequencing analysis of *Cymbidium goeringii* identifies floral scent biosynthesis related genes. *BMC Plant Biology*, 19(1), 337.
<https://doi.org/10.1186/s12870-019-1940-6>
- Reynolds, C., Colmer, J., Rees, H., Khajouei, E., Rusholme-Pilcher, R., Kudoh, H., Dodd, A. N., & Hall, A. (2025). Machine learning models highlight environmental and genetic factors associated with the Arabidopsis circadian clock. *Nature Communications*, 16(1), 1–17.
<https://doi.org/10.1038/s41467-025-62196-w>
- Salgado-Velázquez, S., Barrios-Gómez, E., Hernández-Aragón, L., Hernández-Lara, P. U., Olvera-Rincón, F., Sumano-López, D., Inurreta-Aguirre, H. D., & Palma-Cancino, D. J. (2026). Advances in rice agronomic technologies in Latin America in the face of climate change. *Crops*, 6(1):8.
<https://doi.org/10.3390/crops6010008>
- Soussi, A., Zero, E., Ouammi, A., Zejli, D., Zahmoun, S., & Sacile, R. (2025). Smart greenhouse farming: A review towards near zero energy consumption. *Discover Cities*, 2(1), 1–29.
<https://doi.org/10.1007/s44327-025-00096-w>
- Soussi, A., Zero, E., Sacile, R., Trincherro, D., & Fossa, M. (2024). Smart sensors and smart data for precision agriculture: a review. *Sensors*, 24(8), 2647.
<https://doi.org/10.3390/s24082647>
- Su, J., Lu, Z., Zeng, J., Zhang, X., Yang, X., Wang, S., Zhang, F., Jiang, J., & Chen, F. (2024). Multi-locus genome-wide association study and genomic prediction for flowering time in chrysanthemum. *Planta*, 259(1), 13.
<https://doi.org/10.1007/s00425-023-04297-8>
- Thuy, T. Le, Nguyen, M. K., Bui, T. D., Yen, H. P. H., Hoai, N. T., Ngan, N. V. C., Pradiprao Khedulkar, A., Van, D. P., Halog, A., & Hoang, T. D. (2025). Blockchain-enabled water quality monitoring: A comprehensive review of digital innovations and challenges. *Water*, 17(17), 2522.
<https://doi.org/10.3390/w17172522>

- Vega, Y., Marques, I., Castro, S., & Loureiro, J. (2013). Outcomes of extensive hybridization and introgression in *Epidendrum* (Orchidaceae): Can we rely on species boundaries? *PLoS ONE*, 8(11), e80662.
<https://doi.org/10.1371/journal.pone.0080662>
- Verdezoto-Prado, J., Chicaiza-Ortiz, C., Mejía-Pérez, A.B. Freire-Torres, C., Viteri-Yáñez, M., Deng, L., Barba-Ostria, C., & Guamán, L. P. (2025). Advances in environmental biotechnology with CRISPR/Cas9: Bibliometric review and cutting-edge applications. *Discover Applied Sciences*, 7, 167.
<https://doi.org/10.1007/s42452-025-06609-x>
- Vernier, C., Loeillet, D., Thomopoulos, R., & Macombe, C. (2021). Adoption of ICTs in agri-food logistics: Potential and limitations for supply chain sustainability. *Sustainability*, 13(12), 6702.
<https://doi.org/10.3390/su13126702>
- Wang, T., Thomasson, J. A., Isakeit, T., Yang, C., & Nichols, R. L. (2020). A plant-by-plant method to identify and treat cotton root rot based on UAV remote sensing. *Remote Sensing*, 12(15), 2453.
<https://doi.org/10.3390/rs12152453>
- Yang, L., Wang, H., Zou, M., Chai, H., & Xia, Z. (2025). Artificial intelligence-driven plant bio-genomics research: A new era. *Tropical Plants*, 4(1), 15.
<https://doi.org/10.48130/tp-0025-0008>
- Yang, W., Egea, G., & Ghamkhar, K. (2022). Editorial: Convolutional neural networks and deep learning for crop improvement and production. *Frontiers in Plant Science*, 13, 1079148.
<https://doi.org/10.3389/fpls.2022.1079148>
- Zinke-Wehlmann, C., & Charvát, K. (2021). Introduction of smart agriculture. En *Big Data in Bioeconomy: Results from the European DataBio Project* (pp. 187–190).
https://doi.org/10.1007/978-3-030-71069-9_14

Floriculture 4.0 in Ecuador:

Challenges and guidelines for the integration of digital technologies and public policies in genetic improvement and productive innovation

*Xavier Rojas-Ruilova*¹
*Génesis Vásquez*²
*Isabel Marques*³

¹Universidad Nacional de Loja, Facultad de la Salud Humana, Loja, Ecuador,
<https://orcid.org/0000-0002-5692-5366>
xavier.rojas@unl.edu.ec

²Universidad Nacional de Loja, Facultad de Energía, Loja, Ecuador,
<https://orcid.org/0000-0002-9632-5429>
genesis.vasquez@unl.edu.ec

³University of Lisbon, Forest Research Centre, Associate Laboratory TERRA, School of Agriculture, Lisboa, Portugal,
<https://orcid.org/0000-0001-9788-4831>
isabelmarques@isa.ulisboa.pt

DOI: 10.61854/rccedia.v1n1.006
Sent: January 20, 2026
Approved: April 8, 2026
Published: Tuesday, July 14, 2026



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

Abstract

Ecuadorian floriculture is undergoing a transformation driven by digitalization, biotechnology, and data science. This study examines the role of Information and Communication Technologies (ICTs), bioinformatics, and Big Data analytics in genetic improvement, with a focus on the national context. Through an exploratory review of the scientific literature, we identify emerging patterns in the adoption of digital technologies for the development of new floral varieties. The results reveal a clear imbalance in the current technological landscape, characterized by a predominance of production-oriented digital tools, such as IoT sensors and artificial intelligence, alongside a still limited integration of bioinformatic and genomic approaches. This asymmetry suggests that innovation in Ecuadorian floriculture is currently driven primarily by crop management optimization rather than advances in the genetic foundation of production systems. Nevertheless, the incorporation of genomic tools in ornamental species shows strong potential to improve the efficiency of breeding programs by enabling the identification of genes associated with key traits and stress tolerance, thereby supporting the development of more resilient and competitive production systems. In this context, the findings highlight the need to strengthen public policies that promote the integration of genomic and bioinformatic capacities within the floriculture sector. This includes investments in scientific infrastructure, the development of specialized human capital, and the promotion of partnerships between academia, industry, and governmental institutions. A coordinated strategy in this direction could position Ecuador as a regional leader in Floriculture 4.0, aligning technological innovation with the sustainable use of its biodiversity.

Keywords:

flowers; bioinformatics; big data; digital innovation; industry; orchids.

Introduction

Floriculture is one of Ecuador's most dynamic agricultural sectors, internationally recognized for the quality and diversity of its cut flowers, particularly roses (Guaita-Pradas et al., 2023). Since its consolidation in the 1990s, this industry has made a significant contribution to the agricultural export gross domestic product (GDP), "generating more than 65,000 direct jobs and 55,000 indirect jobs, with a notable participation of women, who represent 51% of the workforce."¹

According to data from the Central Bank of Ecuador (BCE, 2024), between January and November 2024, floriculture exports reached USD 925 million, with a year-over-year growth of 2.6% and a volume exceeding 160,000 tons, consolidating the country as the world's third-largest exporter after the Netherlands and Colombia (BCE, 2024). Floriculture production in Ecuador has historically been concentrated in the northern region of the country, particularly in the provinces of Pichincha and Cotopaxi, which together account for more than 80% of national production, while the remainder originates from other provinces, including Guayas, Imbabura, and Azuay (Mañay et al., 2022).

However, the competitiveness of the floriculture sector is currently undergoing a structural transition driven by digitalization, sustainability, and biotechnological innovation. Global demand requires new varieties with longer vase life, disease resistance, transport tolerance, and adaptation to climate change (Casigña et al., 2024). In this context, information and communication technologies (ICTs), together with bioinformatics and big data

analytics, are emerging as key pillars of a new phase of agrobiotechnological innovation (García Torres et al., 2024; Chavarro, 2021). Within this framework, ICTs contribute to optimizing resource use, anticipating phytosanitary issues, improving traceability, and reducing postharvest losses, while facilitating data-driven management models and innovation strategies oriented toward sustainability (Vernier et al., 2021; Abbes, 2025).

In practice, these technologies are materialized through multiple applications, including greenhouse automation, environmental sensing, smart irrigation, and digital traceability (Pandiyan et al., 2024; Dai et al., 2025; Peña-Holguín et al., 2025; Kumar & Verma, 2025). For example, IoT sensors installed in greenhouses enable the monitoring of variables such as temperature, humidity, radiation, and CO₂ concentration, with the resulting data processed on cloud-based platforms through predictive models that optimize plant growth and flowering (Hosny et al., 2025; Soussi et al., 2025). At the same time, the use of blockchain technologies strengthens production traceability and enhances transparency in international markets that are increasingly sensitive to sustainability criteria (de Carvalho et al., 2022; Chen et al., 2023; Pang et al., 2024; Thuy et al., 2025).

Likewise, the convergence of molecular biology, bioinformatics, and data analytics has driven significant advances in plant genetic improvement (Hasan et al., 2021; Khan et al., 2022; Panahi et al., 2024; Belbase et al., 2025; Li et al., 2025; Salgado-Velázquez et al., 2026). The use of molecular markers, genomic sequencing, and trans-

¹ Ecuador reaffirms its leadership in the global flower industry with the inauguration of Expo Flor 2024 – Ministry of Production, Foreign Trade and Investment, n.d.

criptomic approaches enables the identification of genomic regions and genes associated with traits of interest, such as color, fragrance, pathogen resistance, and tolerance to environmental stress (Kim et al., 2020; Koboldt et al., 2013; Berman et al., 2025; Pei et al., 2026). Similarly, approaches such as QTL mapping, genome-wide association studies (GWAS), and CRISPR-based gene editing expand the possibilities for targeted improvement and functional gene exploration (Doll et al., 2019; Li et al., 2025; Verdezoto-Prado et al., 2025).

Furthermore, the integration of genomic tools with predictive models based on artificial intelligence is accelerating breeding programs and expanding opportunities for the selection of complex traits (Yang et al., 2022; Afonso et al., 2024; Mantilla et al., 2025). International experience demonstrates that these approaches can shorten varietal development timelines and improve the early selection of parental lines. For example, in *Chrysanthemum morifolium*, genomic prediction has demonstrated potential for identifying combinations with desirable commercial traits (OECD, 2015; Kim et al., 2024; Su et al., 2024).

Despite the growing interest in the digitalization of the floriculture sector, the literature remains fragmented, making it difficult to develop an integrated understanding of the opportunities, limitations, and challenges associated with the transition toward Floriculture 4.0 in the country. Recent studies have examined the adoption of ICT technologies in the floriculture sector, showing that although there is considerable potential to improve efficiency and sustainability, implementation

in emerging countries such as Ecuador remains limited due to economic, technical, and training-related barriers (Mantilla et al., 2025). These studies have focused primarily on technological adoption at the production level, whereas bioinformatics, artificial intelligence, and genetic improvement, as key components of floricultural innovation, have received significantly less attention.

In this context, the present study is proposed as an exploratory review with an analytical orientation, aimed at synthesizing and structuring the available knowledge regarding the role of digital technologies in Ecuadorian floriculture by integrating technological, genomic, and production-related perspectives. Based on this approach, the following research questions are formulated:

- (i) Which technologies are shaping the Floriculture 4.0 paradigm in floriculture production and genetic improvement processes, and what is their relevance within the Ecuadorian context?
- (ii) What are the main structural, technological, and educational limitations that condition their adoption in Ecuador?
- (iii) What opportunities emerge from the convergence of ICTs, bioinformatics, and artificial intelligence for the development of innovative genetic floriculture in Ecuador?

Methods

The present study was conducted as an exploratory review with a qualitative approach, incorporating elements of a systematic review based on the PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) guidelines (Page et al., 2021). Source identification was carried out through a structured search in the Scopus database, using Boolean operators and predefined combinations of terms, including “digital agriculture” OR “bioinformatics” OR “artificial intelligence” OR “floriculture” AND “plant breeding” AND “Ecuador.” Scopus was selected as the primary database due to its broad coverage of peer-reviewed literature across multiple disciplines, ensuring comprehensive and consistent retrieval of relevant studies.

Subsequently, a multi-stage selection process was conducted based on the review of titles, abstracts, and full-text content to identify studies aligned with the objectives of this work. To minimize potential bias, the screening process was performed independently by two researchers. During this phase, 30 records were excluded for not fitting the thematic scope of the study, including works focused on non-technological agricultural practices and crops outside the floriculture sector or unrelated to plant breeding. In addition,

32 further records were excluded because they did not correspond to scientific articles or reviews (e.g., books or other types of non-peer-reviewed documents). As a result of this process, the final dataset consisted of 55 documents, which form the basis of the review.

This dataset includes one review study that integrates evidence from 41 additional works, thereby expanding the empirical scope of the analyzed corpus. Furthermore, the corpus was classified according to technology type and field of application, allowing both thematic and quantitative analyses of the literature. The selected studies were also analyzed using a thematic coding methodology, in which each document was categorized according to its primary technological focus (e.g., IoT, artificial intelligence, bioinformatics, or genetic improvement) and its area of application. For this purpose, a data extraction matrix was developed, including variables such as technology type, application domain, geographic context, and the study’s main contribution. This information enabled the identification of recurring patterns and the quantification of the distribution of technological approaches within the analyzed corpus, thereby facilitating the systematic interpretation of the results.

Results

Based on the analysis of the 55 selected studies, classified through thematic coding according to their technological focus and area of application, consistent patterns were identified in the application of digital technologies within the floriculture sector. In particular, 15 studies focused on IoT technologies and sensors, 7 on artificial intelligence, and 8 included components related to genetics and breeding. The remaining studies were distributed across other technological categories or mixed approaches, reflecting the heterogeneity of the field analyzed (Figure 1).

The reviewed studies show that artificial intelligence and machine learning are among the

most recurrent approaches in the literature, particularly in applications related to disease detection, demand forecasting, flower classification, and the estimation of phenotypic traits through computer vision.

On the other hand, the analysis reveals a more limited presence of studies focused on the application of bioinformatics tools and genetic improvement approaches in the specific context of Ecuadorian floriculture. Likewise, most studies were conducted in international settings, with relatively few investigations specifically focused on Ecuador.




Figure 1

Distribution of studies included in the review according to technological category.

These advances reflect an emerging transition toward data-driven floriculture, creating opportunities for more sustainable, efficient, and traceable production systems. In this regard, Table 1 summarizes the main technologies identified, their

applications, and their level of adoption within the Ecuadorian context, highlighting uneven development across technologies, with greater consolidation in monitoring and automation tools and a still incipient stage in bioinformatics and gene editing.

Table 1

Technologies considered priorities for the transition toward Floriculture 4.0 in Ecuador, according to their application and level of adoption

Technology	Application in floriculture	Main benefits	Level of adoption in Ecuador
IoT and climate sensors	Environmental monitoring, precision irrigation, and fertilization	Water savings, automated control	Medium
Big data and predictive analytics	Processing of genomic and phenotypic data	Improved varietal selection and traceability	Low
Bioinformatics	Identification of genes associated with color, resistance, and fragrance	Acceleration of genetic improvement	Low
Artificial intelligence (AI)	Flowering prediction, pest control, image analysis	Greater efficiency and reduced losses	Low
Blockchain	Certification of origin and sustainability	Traceability and commercial trust	Very low
Gene editing (CRISPR)	Precise modification of traits of interest	Genetic innovation and resilience	Experimental

Discussion

Potential of digital innovation in ecuadorian floriculture

The results obtained reveal a clear predominance of digital technologies applied to production, such as IoT, sensors, and artificial intelligence, compared with a lower representation of approaches focused on bioinformatics and genetic improvement. This pattern suggests that the digital transformation of floriculture has progressed mainly in the optimization of production processes (Montalvo, 2025), while integration with genetic innovation remains limited.

In this context, the Ecuadorian case represents a strategic opportunity to advance toward more integrated Floriculture 4.0 models, although there are still only incipient efforts by universities, which have initiated pilot projects involving floral image analysis and predictive yield modeling (Pérez-Campdesuñer et al., 2025). The incorporation of ICTs should not be understood merely as technological modernization, but rather as a paradigm shift that transforms the way research, production, and commercialization are conceived.

Despite the contributions of this study, it is important to acknowledge certain limitations inherent to the methodological approach adopted, as it is a review based primarily on the Scopus database. Likewise, the limited availability of studies specifically addressing the Ecuadorian context restricts the generalizability of some findings, highlighting the need for future empirical research that explores in greater depth the incorporation of digital and genomic technologies into national floriculture.

Integration of bioinformatics and genetic improvement

The limited findings of our review reveal constraints in the advancement of genetic improvement in Ecuadorian floriculture. In contrast to the predominance of production-oriented digital technologies identified in the results, there is a lack of molecular-level information. However, the emergence of bioinformatics and big data analytics offers the possibility of transforming this scenario by enabling the processing of large volumes of genetic, transcriptomic, phenotypic, and environmental information with unprecedented levels of resolution.

Ecuador, as one of the most biodiverse countries in the world, has the potential to become a regional center for floricultural big data, integrating genomic information from native species with phenotypic data generated by export-oriented companies. For example, the country is home to more than 4,000 native Orchidaceae species, a large proportion of which are endemic and remain poorly studied at the genetic level (Vega et al., 2013). This biological wealth makes Ecuador a natural laboratory for the application of bioinformatics tools, big data analytics, and artificial intelligence aimed at both conservation and genetic improvement.

International platforms have enabled advances in sequence analysis, gene identification, and the exploration of metabolic pathways associated with floral traits such as color, shape, and fragrance (Chen et al., 2022). Likewise, recent developments in comparative genomics and transcriptome sequencing have made it possible to identify genes involved in floral morphogenesis, pigment production, and resistance to abiotic stress. Exam-

ples such as *Vanilla planifolia* (Gastelbondo et al., 2025; Hernández-Peña et al., 2025) and *Cymbidium goeringii* (Ramya et al., 2019) illustrate the potential of these tools for applications related to quality and sustainability.

In the Ecuadorian context, precision floriculture could benefit from the incorporation of molecular markers to accelerate breeding programs targeting commercially valuable traits, such as postharvest longevity, color intensity, and tolerance to diseases and adverse environmental conditions (Abril-Espin et al., 2024). Complementarily, gene editing technologies such as CRISPR/Cas9 would create opportunities to investigate specific gene functions or develop varieties adapted to the country's diverse altitudinal zones without compromising native biodiversity (Motoche-Monar et al., 2023; Gómez-Lama et al., 2025; Verdezoto-Prado et al., 2025). This strategy would enable resource optimization, loss reduction, and the promotion of climate-resilient floriculture, while also diversifying the genetic base of ornamental crops.

The consolidation of these innovations requires progress toward methodological standardization in the management of genomic and phenotypic data, as well as the implementation of reproducible predictive models based on artificial intelligence (Caballero-Ramirez et al., 2023; Montalvo et al., 2025). The use of next-generation sequencing platforms, de novo transcriptomic analysis tools, and deep learning algorithms applied to hyperspectral images will enable the development of more accurate and transferable models across ornamental species (Anastasiou et al., 2025; Cravero et al., 2026). In this way, the integration of genomics with digital phenomics and artificial intelligence will establish the foundation for intelligent floriculture centered on sustainable innovation and scientific knowledge as a competitive advantage.

Challenges and perspectives toward ecuadorian floriculture 4.0

La escasa adopción de herramientas genómicasThe limited adoption of genomic tools identified in the results translates into structural barriers to the development of a fully integrated Floriculture 4.0 in Ecuador. Despite the identified potential, the implementation of digital technologies faces obstacles related to technological infrastructure, the availability of specialized human resources, and data governance. In particular, insufficient connectivity, limited data storage and processing capacity, and the shortage of professionals trained in bioinformatics and data science constrain the sector's development.

In this context, the creation of centers of excellence and technology transfer platforms is essential for connecting research and production. Likewise, the implementation of living labs in floricultural regions would provide real-world environments for validating, adapting, and scaling technological innovations. Within these spaces, Ecuadorian orchids and other native ornamental species could serve as reference biological models for integrating artificial intelligence, genomics, and digital phenomics. This approach would transform biodiversity into biotechnological capital, fostering a new knowledge economy in which genetic and phenotypic data are considered high-value strategic assets.

From an institutional perspective, the State plays a fundamental role in establishing regulatory frameworks and incentives that promote technological adoption (De Leon Nazareno, 2024). This is reflected in the Public Policy for Ecuador's Digital Transformation 2025–2030, as established within the legal framework of the Organic Law for Digital and Audiovisual Transformation, the Organic Telecommunications Law, the Organic Law on Identity Management and Civil Data, the Organic Law

of the National Public Data Registry System, the Organic Law for the Optimization and Efficiency of Administrative Procedures, and the Organic Law on Personal Data Protection (MINTEL, 2025).

Advancing toward Floriculture 4.0 requires a coordinated vision centered on sustainability, innovation, and the valorization of biodiversity, as summarized in Table 2. The integration of ICTs, biotechnology, and the circular economy will not

only improve production efficiency but also position Ecuador as a regional leader in intelligent floriculture, capable of exporting not only flowers but also knowledge, technology, and sustainable management models. This emerging paradigm redefines the country’s role in the global bioeconomy, promoting production systems that are more resilient, traceable, and aligned with the conservation of natural heritage.

Table 2
Strategic framework for the implementation of floriculture 4.0 in Ecuador, integrating technological, socioeconomic, and environmental dimensions

Strategic Axis	Technological component	Expected impact	Stakeholders involved
Productive digitalization	IoT, automation, data analytics	Efficiency, cost reduction	Floriculture companies, universities
Genetic innovation	Genomics, bioinformatics, CRISPR	New varieties, climate resilience	Research centers, universities
Environmental sustainability	Clean energy, blockchain, circularity	Reduced ecological footprint, green traceability	Government, certification bodies
Education and talent development	STEM education, technology networks	Skilled employment, local innovation	Universities, government
Data governance	Digital infrastructure, legal frameworks	Biogenetic protection, scientific sovereignty	Ministry of Production, academia

Conclusions

In response to the research questions posed, the results of this study reveal an asymmetric development in the transition toward Floriculture 4.0, characterized by the predominance of production-oriented digital technologies and the limited adoption of bioinformatics tools and genetic improvement approaches. This imbalance highlights a strategic opportunity to advance toward more integrated models based on data, genomics, and innovation.

In this context, Ecuador, owing to its biodiversity and export leadership, possesses favorable conditions to establish itself as a regional hub for digital floricultural innovation. The incorporation of technologies such as IoT, artificial intelligence, and big data will enable the optimization of production processes, improved

traceability, and accelerated development of varieties adapted to climate change.

Nevertheless, realizing this potential depends on overcoming structural limitations related to technological infrastructure, the development of specialized human capital, and data governance. In this regard, investment in interdisciplinary training, data standardization, and the strengthening of collaborative networks will be essential for consolidating a sustainable innovation system. Overall, the integration of ICTs, biotechnology, and biodiversity positions Ecuadorian floriculture as a strategic sector within the bioeconomy, with the capacity to promote a more resilient, competitive, and knowledge-based production model.

Conflict of interest statement

The authors of this article declare that they have no conflicts of interest.

Funding sources

This research was funded by National Funds through the Foundation for Science and Technology (FCT) under projects UID/00239/2025 (CEF) and LA/P/0092/2020 (Associated Labora-

tory TERRA), as well as by I.M. through the Scientific Employment Stimulus Program—Individual Call (CEEC Individual)—2021.01107.CEECIND/CP1689/CT0001.

Declaration of authorship contributions (CRediT):

Xavier Rojas Ruilova: Conceptualization; methodology; formal analysis; investigation; validation; writing – original draft; writing – review and editing; visualization; resources; supervision; project administration.

Génesis Vásquez: Conceptualization; methodology; formal analysis; data curation; investigation; validation; writing – original draft; writing – review and editing; visualization; software.

Isabel Marques: Conceptualization; methodology; formal analysis; investigation; validation; writing – original draft; writing – review and editing; resources; supervision; funding acquisition.

References

- Abbes, I. (2025). Strategic pathways for innovation and sustainability in digital transformation: Insights from leading global companies. *Social Sciences & Humanities Open*, 12, 101906.
<https://doi.org/10.1016/j.ssaho.2025.101906>
- Abril-Espin, E., Montes-Escobar, K., de la Hoz-M, J., Garcés-Fiallos, F. R., & Salas-Macias, C. A. (2024). Exploring global trends in scientific research on *Rubus glaucus* Benth: A comprehensive analysis integrating bibliometrics, LDA, and HJ-Biplot. *Journal of Berry Research*, 14(4), 287-300.
<https://doi.org/10.1177/187850932412849>
- Afonso, M., Paulo, M. J., Fonteijn, H., van den Helder, M., Zwinkels, H., Rijsbergen, M., van Hameren, G., Haegens, R., & Wehrens, R. (2024). Automatic trait estimation in floriculture using computer vision and deep learning. *Smart Agricultural Technology*, 7, 100383.
<https://doi.org/10.1016/j.atech.2023.100383>
- Anastasiou, E., Kasimati, A., Papadopoulos, G., Vatsanidou, A., Gemtou, M., Kantelhardt, J., Gabriel, A., Schwierz, F., Matavel, C.E., Meyer-Aurich, A., Maritan, E., Behrendt, K., Moroder, A., Bellingra-th-Kimura, S. D., Pedersen, S. M., Landi, A., Pesonen, L., Rojic, J., Kim, M., ... Denzer, H. (2025). Review and assessment of crop-related digital tools for agroecology. *Agronomy*, 15(11), 2600.
<https://doi.org/10.3390/agronomy15112600>
- Banco Central del Ecuador. (2024). *Resultados de comercio exterior: Abril 2024*.
https://contenido.bce.fin.ec/documentos/Estadisticas/SectorExterno/ComercioExterior/informes/ResultCE_042024.pdf
- Belbase, P., & Balaji Bhaskar, M.S. (2025). Sustainable cultivation of dragon fruit: integrated nutrient and pest management strategies for enhanced productivity and environmental stewardship. *Agro-nomy*, 15, 2514.
<https://doi.org/10.3390/agronomy15112514>
- Berman, A., Su, N., Li, Z., Landau, U., Chakraborty, J., Gerbi, N., Liu, J., Qin, Y., Yuan, B., Wei, W., Yanai, O., Mayrose, I., Zhang, Y., & Shani, E. (2025). Construction of multi-targeted CRISPR libraries in tomato to overcome functional redundancy at genome-scale level. *Nature Communica-tions*, 16(1), 1–14.
<https://doi.org/10.1038/s41467-025-59280-6>

- Caballero-Ramirez, D., Baez-Lopez, Y., Limon-Romero, J., Tortorella, G., & Tlapa, D., (2023). An assessment of human inspection and deep learning for defect identification in floral wreaths. *Horticulturae* 9(11). 1213.
<https://doi.org/10.3390/horticulturae9111213>
- Casigña Guaman, N. S., Chicaiza Reisancho, E. R., Cali Palacios, M. A., Fiallos Ulloa, L. A., & Uvidia Armijo, J. H. (2024). Flores y suelo: Un estudio ambiental sobre las actividades florícolas en Los Ilinizas, Cotopaxi. *Ciencia Latina Revista Científica Multidisciplinar*, 8(1), 8249–8262.
https://doi.org/10.37811/cl_rcm.v8i1.10153
- Chavarro, J. (2021). *Evolución y desafíos de la floricultura ecuatoriana en el futuro próximo*. Metroflor.
<https://www.metroflorcolombia.com/evolucion-y-desafios-de-la-floricultura-ecuatoriana-en-el-futuro-proximo/>
- Chen, H. Y., Sharma, K., Sharma, C., & Sharma, S. (2023). Integrating explainable artificial intelligence and blockchain to smart agriculture: Research prospects for decision making and improved security. *Smart Agricultural Technology*, 6, 100350. doi: 10.1016/J.ATECH.2023.100350
- Chen, Y., Li, C., Hsiao, Y., Ho, S. Y., Zhang, Z., Liao, C., Lee, B., Lin, S., Wu, W., Wang, J., Zhang, D., Liu, K., Liu, D., Zhao, X., Li, Y., Ke, S., Zhou, Z., Huang, M., Wu, Y., ... Tsai, W. (2022). OrchidBase 5.0: Updates of the orchid genome knowledgebase. *BMC Plant Biology*, 22(1), 557.
<https://doi.org/10.1186/s12870-022-03955-5>
- Colantonio, V., Ferrão, L. F. V., Tieman, D. M., Bliznyuk, N., Sims, C., Klee, H. J., Munoz, P., & Resende, M. F. R. (2022). Metabolomic selection for enhanced fruit flavor. *Proceedings of the National Academy of Sciences of the United States of America*, 119(7), e2115865119.
<https://doi.org/10.1073/pnas.2115865119>
- Cravero, A., Sepúlveda, S., Gutiérrez, F., & Muñoz, L. (2026). From precision agriculture to intelligent agricultural ecosystems: A systematic review of machine learning and big data applications. *Agronomy*, 16(5).
<https://doi.org/10.3390/agronomy16050516>
- Dai, Y., Huang, Z., Khan, N., & Labbo, M. S. (2025). Smart water management: governance innovation, technological integration, and policy pathways toward economic and ecological sustainability. *Water*, 17(13), 1932.
<https://doi.org/10.3390/w17131932>

- Danilevicz, M. F., Upadhyaya, S. R., Batley, J., Bennamoun, M., Bayer, P. E., & Edwards, D. (2025). Understanding plant phenotypes in crop breeding through explainable AI. *Plant Biotechnology Journal*, 23(10), 4200–4213.
<https://doi.org/10.1111/pbi.70208>
- de Carvalho, P. R. V., Naoum-Sawaya, J., & Elhedhli, S. (2022). Blockchain-enabled supply chains: An application in fresh-cut flowers. *Applied Mathematical Modelling*, 110, 841–858.
<https://doi.org/10.1016/j.apm.2022.06.011>
- de Leon Nazareno, D. O. (2024). Transformación digital como factor de cambio de la matriz productiva de Ecuador. *Economía y Desarrollo*, 168(2), 1–22.
https://doi.org/10.37811/cl_rcm.v8i4.12331?no
- Doll, N. M., Gilles, L. M., Gérentes, M. F., Richard, C., Just, J., Fierlej, Y., Borrelli, V. M. G., Gendrot, G., Ingram, G. C., Rogowsky, P. M., & Widiez, T. (2019). Single and multiple gene knockouts by CRISPR–Cas9 in maize. *Plant Cell Reports*, 38(4), 487–501.
<https://doi.org/10.1007/s00299-019-02378-1>
- Fan, Z., Hasing, T., Johnson, T. S., Garner, D. M., Barbey, C. R., Colquhoun, T. A., Sims, C. A., Resende, M. F. R., & Whitaker, V. M. (2021). Strawberry sweetness and consumer preference are enhanced by specific volatile compounds. *Horticulture Research*, 8(1), 66.
<https://doi.org/10.1038/s41438-021-00502-5>
- Ferrão, L. F. V., Dhakal, R., Dias, R., Tieman, D., Whitaker, V., Gore, M. A., Messina, C., & Resende, M. F. R. (2023). Machine learning applications to improve flavor and nutritional content of horticultural crops through breeding and genetics. *Current Opinion in Biotechnology*, 83, 102968.
<https://doi.org/10.1016/j.copbio.2023.102968>
- García Torres, I. A., Castillo León, R. E., Navas Espín, W. R., & Veintimilla Andrade, J. G. (2024). El uso de la inteligencia artificial en un invernadero. *Ciencia Latina Revista Científica Multidisciplinar*, 8(4), 910–930.
https://doi.org/10.37811/cl_rcm.v8i4.12331
- Gastelbondo, M., Micheal, V., Wang, Y., Chambers, A., & Wu, X. (2025). Comparative transcriptome profiling of vanilla (*Vanilla planifolia*) capsule development provides insights of vanillin biosynthesis. *BMC Plant Biology*, 25(1), 1–16.
<https://doi.org/10.1186/s12870-025-06360-w>

- Gómez-Lama Cabanás, C., & Mercado-Blanco, J. (2025). Groundbreaking technologies and the bio-control of fungal vascular plant pathogens. *Journal of Fungi*, 11(1), 77.
<https://doi.org/10.3390/jof11010077>
- Guaita-Pradas, I., Rodríguez-Mañay, L. O., & Marques-Perez, I. (2023). Competitiveness of Ecuador's flower industry in the global market in the period 2016–2020. *Sustainability*, 15(7), 5821.
<https://doi.org/10.3390/su15075821>
- Hasan, N., Choudhary, S., Naaz, N., Sharma, N., & Laskar, R. A. (2021). Recent advancements in molecular marker-assisted selection and applications in plant breeding programmes. *Journal of Genetic Engineering and Biotechnology*, 19(1) 128.
<https://doi.org/10.1186/s43141-021-00231-1>
- Hernández-Peña, R., Lorenzo-Manzanarez, J. L., Cruz-Ramírez, L. A., Reyes-López, D., Hernández-Domínguez, C., Pascual-Ramírez, F., & Ordaz-Ortiz, J. J. (2025). Unravelling vanillin biosynthesis: Integrative transcriptomic and metabolomic insights into pod development. *Journal of Agricultural and Food Chemistry*, 73(30), 19094.
<https://doi.org/10.1021/acs.jafc.5c05293>
- Hosny, K. M., El-Hady, W. M., & Samy, F. M. (2025). Technologies, protocols, and applications of internet of things in greenhouse farming: A survey of recent advances. *Information Processing in Agriculture*, 12(1), 91–111.
<https://doi.org/10.1016/j.inpa.2024.04.002>
- Khan, I. A., Cao, K., Guo, J., Li, Y., Wang, Q., Yang, X., Wu, J., Fang, W., & Wang, L. (2022). Identification of key gene networks controlling anthocyanin biosynthesis in peach flower. *Plant Science*, 316, 111151.
<https://doi.org/10.1016/j.plantsci.2021.111151>
- Kim, S. Y., Lee, H. Y., Park, C., Kim, D., Kim, J. B., Kim, S. H., Jeong, K. J., Pak, H. S., Jung, J. A., & Kim, T. S. (2024). Assessing amounts of genetic variability in key horticultural traits underlying core korean breeding lines of cut chrysanthemums. *Plants*, 13(5), 577.
<https://doi.org/10.3390/plants13050577>
- Koboldt, D. C., Steinberg, K. M., Larson, D. E., Wilson, R. K., & Mardis, E. R. (2013). The next-generation sequencing revolution and its impact on genomics. *Cell*, 155(1), 27–38.
<https://doi.org/10.1016/j.cell.2013.09.006>

- Kumar, V., & Verma, P. (2025). Advances in microbial biotechnology for sustainable wastewater reclamation: Recent trends and future prospects. *World Journal of Microbiology Biotechnology*, 41(12), 478.
<https://doi.org/10.1007/s11274-025-04674-3>
- Li, X., Li, Y., Sun, Y., Li, S., Cai, Q., Li, S., Sun, M., Yu, T., Meng, X., & Zhang, J. (2025). Integrating genetic diversity and agronomic innovations for climate-resilient maize systems. *Plants*, 14(10), 1552.
<https://doi.org/10.3390/plants14101552>
- Mañay, L. O. R., Guaita-Pradas, I., & Marques-Perez, I. (2022). Measuring the supply chain performance of the floricultural sector using the SCOR model and a multicriteria decision-making method. *Horticulturae*, 8(2), 168.
<https://doi.org/10.3390/horticulturae8020168>
- Mantilla, F., Mejía, G., & Tascón, D. (2025). The role of industry 4.0 technologies in the export flower industry: Insights from a systematic literature review and surveys in emerging economies. *Results in Engineering*, 25, 104507.
<https://doi.org/10.1016/j.rineng.2025.104507>
- Ministerio de Producción, Comercio Exterior e Inversiones. (2024, octubre 8). Ecuador reafirma su liderazgo en la industria florícola mundial con la inauguración de Expo Flor 2024.
<https://www.produccion.gob.ec/ecuador-reafirma-su-liderazgo-en-la-industria-floricola-mundial-con-la-inauguracion-de-expo-flor-2024/>
- Ministerio de Telecomunicaciones y de la Sociedad de la Información [MINTEL]. (2025). Política pública para la transformación digital del Ecuador 2025-2030.
https://www.gobiernoelectronico.gob.ec/wp-content/uploads/2025/03/INSTRUMENTO-Politica-Publica-para-la-Transformacion-Digital-Ecuador-2025-2030-MINTEL-signed_f.pdf
- Montalvo Rodríguez, S. P. (2025). Implementación de un sistema de gestión energética aplicado a la empresa “ESTRUCTIM”. *Arandu UTIC*, 12(1), 1946–1969.
<https://doi.org/10.69639/arandu.v12i1.720>
- Motoche-Monar, C., Ordoñez, J. E., Chang, O., Gonzales-Zubiate, F. A. (2023). gRNA Design: How its evolution impacted on CRISPR/Cas9 systems refinement. *Biomolecules*, 13(12), 1698.
<https://doi.org/10.3390/biom13121698>
- Nisio, A., Adamo, F., Acciani, G., & Attivissimo, F. (2020). Fast detection of olive trees affected by *Xylella fastidiosa* from UAVs using multispectral imaging. *Sensors*, 20(17), 4915.
<https://doi.org/10.3390/s20174915>

- Novielli, P., Romano, D., Pavan, S., Losciale, P., Stellacci, A. M., Diacono, D., Bellotti, R., & Tangaro, S. (2024). Explainable artificial intelligence for genotype-to-phenotype prediction in plant breeding: A case study with a dataset from an almond germplasm collection. *Frontiers in Plant Science*, 15, 1434229.
<https://doi.org/10.3389/fpls.2024.1434229>
- OECD. (2015). *Innovation, agricultural productivity and sustainability in Brazil* (OECD Food and Agricultural Reviews).
<https://doi.org/10.1787/9789264237056-en>.
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71.
<https://doi.org/10.1136/bmj.n71>
- Panahi, B., Mohammadzadeh Jalaly, H., & Hamid, R. (2024). Using next-generation sequencing approach for discovery and characterization of plant molecular markers. *Current Plant Biology*, 40, 100412.
<https://doi.org/10.1016/j.cpb.2024.100412>
- Pandiyar, P., Saravanan, S., Kannadasan, R., Krishnaveni, S., Alsharif, M. H., & Kim, M. K. (2024). A comprehensive review of advancements in green IoT for smart grids: Paving the path to sustainability. *Energy Reports*, 11, 5504–5531.
<https://doi.org/10.1016/j.egy.2024.05.021>
- Pang, S., Teng, S. W., Murshed, M., Bui, C., Karmakar, P., Li, Y., & Lin, H. (2024). A survey on evaluation of blockchain-based agricultural traceability. *Computers and Electronics in Agriculture*, 227, 109548.
<https://doi.org/10.1016/j.compag.2024.109450>
- Pei, X., Xie, J., Liang, C., & Utkina, A. O. (2026). Next-generation precision breeding in peanut (*Arachis hypogaea* L.) for disease and pest resistance: From multi-omics to AI-driven innovations. *Insects*, 17(1), 63.
<https://doi.org/10.3390/insects17010063>
- Peña-Holguín, R. R., Vaca-Coronel, C. A., Farías-Lema, R. M., Zapater-Castro, S. V., & Valenzuela-Cobos, J. D. (2025). Smart agriculture in Ecuador: Adoption of IoT technologies by farmers in Guayas to improve agricultural yields. *Agriculture*, 15(15), 1679.
<https://doi.org/10.3390/agriculture15151679>

- Pérez-Campdesuñer, R., Sánchez-Rodríguez, A., García-Vidal, G., Martínez-Vivar, R., & De Miguel-Guzmán, M. (2025). Artificial intelligence in Ecuadorian SMEs: Drivers and obstacles to adoption. *Information*, 16(6), 443.
<https://doi.org/10.3390/info16060443>
- Ramya, M., Park, P. H., Chuang, Y. C., Kwon, O. K., An, H. R., Park, P. M., Baek, Y. S., Kang, B. C., Tsai, W. C., & Chen, H. H. (2019). RNA sequencing analysis of *Cymbidium goeringii* identifies floral scent biosynthesis related genes. *BMC Plant Biology*, 19(1), 337.
<https://doi.org/10.1186/s12870-019-1940-6>
- Reynolds, C., Colmer, J., Rees, H., Khajouei, E., Rusholme-Pilcher, R., Kudoh, H., Dodd, A. N., & Hall, A. (2025). Machine learning models highlight environmental and genetic factors associated with the Arabidopsis circadian clock. *Nature Communications*, 16(1), 1–17.
<https://doi.org/10.1038/s41467-025-62196-w>
- Salgado-Velázquez, S., Barrios-Gómez, E., Hernández-Aragón, L., Hernández-Lara, P. U., Olvera-Rincón, F., Sumano-López, D., Inurreta-Aguirre, H. D., & Palma-Cancino, D. J. (2026). Advances in rice agronomic technologies in Latin America in the face of climate change. *Crops*, 6(1):8.
<https://doi.org/10.3390/crops6010008>
- Soussi, A., Zero, E., Ouammi, A., Zejli, D., Zahmoun, S., & Sacile, R. (2025). Smart greenhouse farming: A review towards near zero energy consumption. *Discover Cities*, 2(1), 1–29.
<https://doi.org/10.1007/s44327-025-00096-w>
- Soussi, A., Zero, E., Sacile, R., Trincherro, D., & Fossa, M. (2024). Smart sensors and smart data for precision agriculture: a review. *Sensors*, 24(8), 2647.
<https://doi.org/10.3390/s24082647>
- Su, J., Lu, Z., Zeng, J., Zhang, X., Yang, X., Wang, S., Zhang, F., Jiang, J., & Chen, F. (2024). Multi-locus genome-wide association study and genomic prediction for flowering time in chrysanthemum. *Planta*, 259(1), 13.
<https://doi.org/10.1007/s00425-023-04297-8>
- Thuy, T. Le, Nguyen, M. K., Bui, T. D., Yen, H. P. H., Hoai, N. T., Ngan, N. V. C., Pradiprao Khedulkar, A., Van, D. P., Halog, A., & Hoang, T. D. (2025). Blockchain-enabled water quality monitoring: A comprehensive review of digital innovations and challenges. *Water*, 17(17), 2522.
<https://doi.org/10.3390/w17172522>

- Vega, Y., Marques, I., Castro, S., & Loureiro, J. (2013). Outcomes of extensive hybridization and introgression in *Epidendrum* (Orchidaceae): Can we rely on species boundaries? *PLoS ONE*, 8(11), e80662.
<https://doi.org/10.1371/journal.pone.0080662>
- Verdezoto-Prado, J., Chicaiza-Ortiz, C., Mejía-Pérez, A.B. Freire-Torres, C., Viteri-Yáñez, M., Deng, L., Barba-Ostria, C., & Guamán, L. P. (2025). Advances in environmental biotechnology with CRISPR/Cas9: Bibliometric review and cutting-edge applications. *Discover Applied Sciences*, 7, 167.
<https://doi.org/10.1007/s42452-025-06609-x>
- Vernier, C., Loeillet, D., Thomopoulos, R., & Macombe, C. (2021). Adoption of ICTs in agri-food logistics: Potential and limitations for supply chain sustainability. *Sustainability*, 13(12), 6702.
<https://doi.org/10.3390/su13126702>
- Wang, T., Thomasson, J. A., Isakeit, T., Yang, C., & Nichols, R. L. (2020). A plant-by-plant method to identify and treat cotton root rot based on UAV remote sensing. *Remote Sensing*, 12(15), 2453.
<https://doi.org/10.3390/rs12152453>
- Yang, L., Wang, H., Zou, M., Chai, H., & Xia, Z. (2025). Artificial intelligence-driven plant bio-genomics research: A new era. *Tropical Plants*, 4(1), 15.
<https://doi.org/10.48130/tp-0025-0008>
- Yang, W., Egea, G., & Ghamkhar, K. (2022). Editorial: Convolutional neural networks and deep learning for crop improvement and production. *Frontiers in Plant Science*, 13, 1079148.
<https://doi.org/10.3389/fpls.2022.1079148>
- Zinke-Wehlmann, C., & Charvát, K. (2021). Introduction of smart agriculture. En *Big Data in Bioeconomy: Results from the European DataBio Project* (pp. 187–190).
https://doi.org/10.1007/978-3-030-71069-9_14

Revisión sistemática de literatura

**sobre soluciones computacionales aplicadas a la
agricultura: diagnóstico visual de enfermedades,
clasificación poscosecha y monitoreo inteligente
mediante IoT**

Luis Chamba-Eras¹

Sergio Jumbo-Gonza²

Walter Yaguana-Alejandro³

Geovanny Romero-Suquilanda⁴

Gerardo Herrera-Campoverde⁵

¹Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0000-0003-3069-9628>
lachamba@unl.edu.ec

²Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0000-0003-3069-9628>
sergio.jumbo@unl.edu.ec

³Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0009-0006-2614-8734>
walter.yaguana@unl.edu.ec

⁴Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0009-0004-7121-1574>
geovanny.romero@unl.edu.ec

⁵Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0009-0006-7925-2594>
gerardo.herrera@unl.edu.ec

DOI: 10.61854/rccedia.v1n1.007

Enviado: 01 de febrero de 2026

Aprobado: 06 de abril de 2026

Publicado: martes 14 de julio de 2026



Esta obra está bajo una licencia internacional
Creative Commons Atribución-NoComercial 4.0.

Resumen

La agricultura enfrenta desafíos crecientes en el diagnóstico de enfermedades, la evaluación de la calidad poscosecha y la gestión de fincas. Las soluciones computacionales basadas en inteligencia artificial, visión por computador e IoT apoyan la toma de decisiones. Este artículo presenta una revisión sistemática de literatura (RSL) que analiza y sintetiza la evidencia reciente sobre enfoques computacionales aplicados a (1) detección automática de enfermedades en hojas y frutos agrícolas, (2) clasificación superficial y evaluación de calidad poscosecha de granos y (3) monitoreo y gestión de fincas mediante plataformas web e IoT. La RSL siguió los lineamientos de Kitchenham y el protocolo PRISMA, aplicando criterios explícitos de búsqueda, selección, evaluación de calidad y síntesis. De 263 registros iniciales, se incluyeron 16 estudios primarios: 6 sobre diagnóstico visual de enfermedades (Eje A), 3 sobre clasificación poscosecha de granos (Eje B) y 7 sobre monitoreo agrícola mediante IoT y plataformas web (Eje C). Los resultados muestran que el aprendizaje profundo (redes neuronales convolucionales, mecanismos de atención y modelos preentrenados) domina el diagnóstico visual y la clasificación poscosecha. Se evidencia un énfasis en infraestructuras IoT para monitoreo, aunque con atención limitada a la usabilidad y a la aplicación sistemática de estándares como ISO 9241. A diferencia de revisiones previas, esta RSL estructura la evidencia por problemas concretos, integrando diagnóstico visual, clasificación y monitoreo en un análisis unificado. Finalmente, se identifican brechas en generalización de modelos, estandarización de los conjuntos de datos y validación en campo, orientando futuras investigaciones en computación aplicada a la agricultura.

Palabras clave:

aprendizaje profundo aplicado, clasificación poscosecha de granos, monitoreo agrícola IoT.

Introducción

La agricultura contemporánea enfrenta desafíos crecientes relacionados con la seguridad alimentaria, la sostenibilidad ambiental y la eficiencia productiva, intensificados por el cambio climático, la presión sobre los recursos naturales y la necesidad de optimizar los sistemas de producción. En este contexto, las soluciones computacionales adquieren un rol estratégico para apoyar procesos de diagnóstico, monitoreo y control agrícola, especialmente en escenarios donde los métodos tradicionales resultan costosos, subjetivos o poco escalables. Tecnologías como la inteligencia artificial (IA), la visión por computador, el aprendizaje profundo y las plataformas web integradas con sensores IoT son herramientas esenciales dentro del ámbito de la computación aplicada a la agricultura (Ouamane y otros, 2025; Yue y otros, 2025).

Uno de los problemas más abordados por la literatura reciente es la detección temprana de enfermedades en cultivos agrícolas, debido a su impacto directo en la productividad y la rentabilidad. En cultivos como el café, enfermedades foliares como la roya del cafeto (*Hemileia vastatrix*) representan una amenaza significativa para la producción. Diversos estudios evidencian que los métodos tradicionales de diagnóstico visual, basados en inspección manual, presentan limitaciones en términos de precisión, oportunidad y dependencia del conocimiento experto. Frente a estas restricciones, los enfoques basados en visión por computador y redes neuronales profundas han mostrado resultados prometedores para la detección automática de enfermedades foliares, alcanzando altos niveles de precisión en comparación con los métodos manuales (Faisal y otros, 2023; Muthusamy & Ramu, 2025).

De manera complementaria, la detección de enfermedades en frutos agrícolas, como las

mazorcas de cacao, ha sido abordada mediante modelos de aprendizaje profundo orientados al reconocimiento de patrones visuales asociados a defectos y patologías. La literatura reporta un uso extendido de redes neuronales convolucionales (CNN) entrenadas con imágenes de frutos, así como el empleo de técnicas de preprocesamiento y aumento de datos para mitigar la escasez de conjuntos de datos etiquetados. Sin embargo, también se identifican desafíos relacionados con la generalización de los modelos y la variabilidad de las condiciones de captura de imágenes en el campo, lo que limita su transferencia directa a escenarios reales de producción (Borromeo y otros, 2025; Yue y otros, 2025).

Otro eje relevante del ciclo productivo agrícola es la clasificación superficial y evaluación de la calidad de granos en etapas poscosecha, particularmente en cultivos como el maíz. En este dominio, los modelos preentrenados de aprendizaje profundo, como MobileNetV2 y EfficientNet, han sido ampliamente estudiados por su capacidad de equilibrar precisión y eficiencia computacional, facilitando su implementación en entornos con recursos limitados (Garg & Gill, 2024). La evidencia disponible sugiere que estos enfoques permiten automatizar la inspección visual de granos con resultados competitivos. No obstante, persisten interrogantes sobre la influencia de la calidad, la cantidad y la diversidad de los conjuntos de datos (*datasets*) en la capacidad de generalización de los modelos (Prakasa y otros, 2021; Pasaribu y otros, 2025; Kant, 2024).

En aplicaciones agrícolas basadas en visión por computador, uno de los desafíos recurrentes es la limitada disponibilidad y el desequilibrio de los conjuntos de datos, lo cual afecta la capacidad de generalización de los modelos

de aprendizaje profundo. Diversas estrategias han sido propuestas para mitigar este problema, como el aumento de datos mediante técnicas de generación sintética. En particular, el uso de redes generativas adversarias (GAN) ha sido explorado como un enfoque para enriquecer conjuntos de datos de imágenes agrícolas, aunque con resultados mixtos respecto a su impacto en el desempeño de los modelos (Rahman y otros, 2024; Pasaribu y otros, 2025).

Más allá del diagnóstico visual y la clasificación poscosecha, la gestión de fincas agrícolas constituye un componente esencial de la agricultura moderna. En este ámbito, las plataformas web basadas en sensores IoT permiten el monitoreo continuo de variables agrícolas y ambientales, apoyando la toma de decisiones informadas. No obstante, la literatura resalta que la efectividad de estas soluciones no depende únicamente de su funcionalidad técnica, sino también de aspectos relacionados con la usabilidad, la calidad del software y la interacción humano-computador. En este sentido, normas como la ISO 9241 han sido empleadas para evaluar plataformas web agrícolas desarrolladas en entornos simulados o de prototipo (Yeong y otros, 2024; Nugroho y otros, 2017).

Diversas revisiones sistemáticas previas han abordado parcialmente estas temáticas. Yue y otros (2025) realizaron una revisión sobre aprendizaje profundo aplicado al reconocimiento de enfermedades y plagas, concluyendo que CNN y *vision transformers* constituyen los enfoques dominantes. No obstante, también detectan escasez de evaluaciones en condiciones reales de campo. De manera similar, Rahman y otros (2024) revisaron el uso de GAN para aumento de datos en agricultura, identificando una brecha relevante en la evaluación de la calidad de las imágenes sintéticas generadas. Sin embargo, ninguna de estas revisiones integra de forma unificada el diagnósti-

co visual de enfermedades, la clasificación poscosecha y el monitoreo agrícola IoT en un análisis comparativo estructurado por problemas agrícolas concretos. Esta fragmentación temática y metodológica dificulta una comprensión integrada de las tendencias tecnológicas, las métricas de evaluación predominantes y las brechas de investigación desde la perspectiva de la computación aplicada.

En este contexto, el objetivo de este artículo es analizar y sintetizar sistemáticamente la literatura científica reciente sobre el uso de soluciones computacionales aplicadas a problemas agrícolas específicos. En particular, la revisión sistemática de literatura (RSL) se enfoca en: (1) la detección automática de enfermedades en hojas y frutos de cultivos agrícolas, con énfasis en café y cacao; (2) la clasificación superficial y evaluación de la calidad de granos agrícolas en contextos poscosecha, especialmente en maíz; y (3) el monitoreo y la gestión de fincas agrícolas mediante plataformas web basadas en sensores IoT, considerando criterios de usabilidad y calidad del software en entornos simulados o de prototipo.

El intervalo temporal de 2017 a 2025 fue seleccionado deliberadamente para capturar el período de mayor proliferación y madurez de arquitecturas modernas de aprendizaje profundo, como *vision transformers*, los modelos de atención y las arquitecturas ligeras preentrenadas, así como la expansión acelerada de infraestructuras IoT en entornos agrícolas. Este período coincide también con una creciente publicación de estudios de validación en condiciones semicontroladas y con el surgimiento de enfoques emergentes como los gemelos digitales agrícolas. No obstante, se reconoce que esta decisión introduce un potencial sesgo de selección hacia tecnologías recientes, excluyendo trabajos fundacionales anteriores que también son relevantes para comprender la evolución del campo.

Las principales contribuciones de este artículo son: (1) presentar una RSL estructurada por problemas agrícolas concretos, con trazabilidad PRISMA completa; (2) sintetizar enfoques, arquitecturas y métricas de evaluación utilizados en soluciones basadas en visión por computador y aprendizaje profundo; (3) analizar el equilibrio entre precisión y eficiencia computacional de modelos preentrenados aplicados a la clasificación superficial de granos; y (4) sistematizar prácticas de ingeniería de software y criterios de usabilidad reportados en plataformas web agrícolas basadas en IoT, con énfasis en la normativa ISO 9241.

El trabajo se articula en torno a las siguientes preguntas de investigación: RQ1, ¿qué enfoques de visión por computador y aprendizaje profundo se han reportado para la detección automática de enfermedades en hojas y frutos

de cultivos agrícolas, particularmente en café y cacao, y con qué métricas se evalúan?; RQ2, ¿qué conjuntos de datos, técnicas de preprocesamiento y arquitecturas de redes neuronales se utilizan con mayor frecuencia en sistemas de diagnóstico visual agrícola, y cuáles presentan mejores resultados en términos de precisión y robustez?; RQ3, ¿qué modelos preentrenados de aprendizaje profundo han demostrado un mejor equilibrio entre precisión y eficiencia computacional en la clasificación superficial y evaluación de calidad de granos agrícolas, con énfasis en el maíz, bajo restricciones de recursos computacionales?; y RQ4, ¿cómo se diseñan y evalúan las plataformas web para el monitoreo y la gestión de fincas agrícolas basadas en sensores IoT, y qué criterios de usabilidad, calidad del software y normativa, como ISO 9241, se consideran en entornos simulados o de prototipo?

Metodología

Diseño del estudio

Se desarrolló una RSL orientada a identificar, analizar y sintetizar evidencia científica sobre el uso de soluciones computacionales aplicadas a problemas agrícolas específicos. El trabajo adopta un enfoque explícito, reproducible y estructurado, siguiendo el proceso metodológico definido por Brereton y otros (2007), en el contexto de la computación y disciplinas afines, y alineado con el protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) para garantizar la trazabilidad y transparencia del proceso de selección.

Esta RSL tiene un carácter exploratorio-descriptivo, ya que su objetivo no es comparar cuantitativamente resultados experimentales homogéneos, sino identificar tendencias, enfoques tecnológicos, métricas de evaluación y brechas de investigación en el dominio analizado. El trabajo no contempla experimentación primaria ni implementación de nuevos modelos, fundamentándose exclusivamente en el análisis crítico de la literatura científica revisada por pares.

Estrategia de búsqueda bibliográfica

La estrategia de búsqueda bibliográfica se diseñó de manera sistemática para cubrir el dominio de la computación aplicada a la agricultura, con énfasis en el diagnóstico visual de enfermedades, la clasificación de la calidad poscosecha y el monitoreo inteligente de fincas agrícolas. Se consultaron las bases de datos científicas IEEE Xplore, Scopus, SpringerLink, ScienceDirect y ACM Digital Library, seleccionadas por su amplia cobertura de publicaciones en ciencias de la computación e ingeniería.

La construcción de las cadenas de búsqueda se realizó utilizando el enfoque PICOC (*population, intervention, comparison, outcome, context*). Se combinaron términos asociados a la población y contexto agrícola (*plant disease, coffee, cacao, maize, farm monitoring*) con términos relacionados con las intervenciones computacionales (*computer vision, deep learning, pretrained models, IoT, web platform, usability, ISO 9241*), empleando operadores booleanos *AND* y *OR*.

El proceso de búsqueda se llevó a cabo de forma iterativa, refinando progresivamente las cadenas de búsqueda a partir del análisis preliminar de los resultados obtenidos, con el objetivo de maximizar la relevancia y minimizar la recuperación de estudios no pertinentes. Las búsquedas se restringieron a títulos, resúmenes y palabras clave.

Criterios de inclusión y exclusión

Los estudios recuperados fueron evaluados mediante criterios de inclusión y exclusión definidos previamente:

Criterios de inclusión:

- Artículos científicos revisados por pares, publicados en revistas o conferencias.
- Estudios publicados entre 2017 y 2025, período que captura la mayor madurez de arquitecturas de aprendizaje profundo modernas.
- Trabajos que apliquen soluciones computacionales (IA, visión por computador, aprendizaje profundo, plataformas web o IoT) a problemas agrícolas específicos.
- Estudios que reporten métricas de evalua-

ción cuantitativas o criterios formales de evaluación de sistemas.

- Publicaciones disponibles en idioma inglés.

Criterios de exclusión:

- Artículos no revisados por pares (editoriales, resúmenes extendidos o documentos técnicos).
- Estudios puramente conceptuales sin validación experimental, simulada o evaluativa.
- Publicaciones duplicadas entre bases de datos.
- Estudios cuyo enfoque no esté claramente vinculado con aplicaciones agrícolas o computación aplicada.
- Estudios con información insuficiente para responder las preguntas de investigación (puntuación de calidad < 3, véase sección "Evaluación de la calidad de los estudios").

Proceso de selección de estudios y flujo PRISMA

El proceso de selección de estudios se llevó a cabo por dos investigadores de forma independiente, aplicando tres análisis secuenciales. Las discrepancias entre revisores fueron resueltas mediante consenso. El nivel de concordancia interobservador fue calculado mediante el coeficiente kappa de Cohen ($\kappa = 0,82$), indicando un acuerdo sustancial según los umbrales establecidos por Landis & Koch (1977).

En el primer análisis (título y resumen), se evaluaron 263 registros recuperados de las cinco bases de datos. Tras eliminar 47 duplicados ($N = 216$ únicos), se descartaron los trabajos cuyo dominio, enfoque o contexto no se alineaban con las preguntas de investigación, lo que resultó en 52 estudios preseleccionados. El segundo análisis consistió en una revisión focalizada de la introducción, la metodología y las conclusiones de esos 52 estudios, permitiendo evaluar el rigor metodológico y la coherencia entre los objetivos, los métodos y los resultados; 24 estudios superaron esta fase. En el tercer análisis, se realizó una lectura crítica completa con control de calidad sistemático, cuyo resultado fue la inclusión final de 16 estudios primarios. La Tabla 1 y la Figura 1 sintetizan el flujo de selección según el protocolo PRISMA 2020.

Tabla 1
*Flujo de selección de estudios
 según protocolo PRISMA*

Fase PRISMA	Descripción	N.º registros
Identificación	Registros recuperados de cinco bases de datos (IEEE Xplore, Scopus, SpringerLink, ScienceDirect, ACM)	263
Eliminación de duplicados	Registros eliminados por duplicación entre bases de datos	47
Cribado (análisis 1)	Evaluación por título y resumen; excluidos por dominio no relevante	216 cribados, 164 excluidos
Elegibilidad (análisis 2)	Revisión de introducción, metodología y conclusiones; excluidos por insuficiencia metodológica	52 evaluados, 28 excluidos
Incluidos (análisis 3)	Lectura crítica completa y evaluación de calidad (QC $\geq$ 3); estudios que conforman la síntesis final	16 incluidos

Nota: Elaboración propia.




Figura 1

Diagrama del flujo de selección de estudios según protocolo PRISMA

Evaluación de la calidad de los estudios

La evaluación de la calidad de los estudios incluidos se realizó mediante un instrumento de evaluación basado en cinco preguntas de calidad (*quality criteria*, QC), conforme a las recomendaciones de Kitchenham y otros (2010). Cada criterio fue puntuado de forma binaria (0 = no cumple; 1 = cumple), con un umbral mínimo de aceptación de 3 puntos sobre 5 para la inclusión en la síntesis final:

- QC1: ¿El objetivo o problema de investigación está claramente definido y delimitado?
- QC2: ¿Se describe adecuadamente la metodología utilizada (enfoque, datos, modelo o sistema)?
- QC3: ¿Se especifica el conjunto de datos (*dataset*) utilizado, incluyendo tamaño, fuente o características relevantes?
- QC4: ¿Se reportan métricas de evaluación cuantitativas (*accuracy*, *F1-score*, mAP, IoU, etc.) o criterios formales de evaluación del sistema?
- QC5: ¿Las conclusiones están respaldadas por los resultados experimentales o evaluativos reportados?

Cada estudio fue evaluado de forma independiente por los dos revisores y el puntaje final correspondió al promedio de ambas evaluaciones. Los ocho estudios excluidos en el tercer análisis presentaron puntuaciones inferiores a 3, principalmente por reportar resultados sin descripción de conjunto de datos (QC3) o sin métricas cuantitativas (QC4).

Estrategia de síntesis de la información

La síntesis de la información se realizó mediante un enfoque cualitativo-comparativo, estructurado en función de los tres ejes temáticos definidos. Para cada eje, se construyó una matriz de extracción homogénea que incluye: (1) identificación del estudio (autores, año, base de datos de origen); (2) cultivo o contexto agrícola; (3) problema abordado; (4) enfoque computacional y arquitectura; y (5) métricas de evaluación y valores reportados.

La síntesis temática se realizó mediante codificación axial inductiva de los datos extraídos, identificando patrones emergentes en cuanto a enfoques tecnológicos dominantes, tendencias metodológicas y brechas recurrentes. No se realizó un metaanálisis cuantitativo, debido a la heterogeneidad de enfoques, métricas y contextos experimentales reportados en los estudios analizados, lo que hace inviable la agregación estadística de resultados. Los patrones identificados se validaron mediante triangulación entre los dos investigadores revisores.

Amenazas a la validez

Como en toda RSL, este trabajo presenta amenazas potenciales a la validez, las cuales se abordan de acuerdo con la clasificación propuesta por Brereton y otros (2007). Las amenazas a la validez interna están relacionadas con posibles sesgos en la selección y evaluación de los estudios; estas fueron mitigadas mediante criterios explícitos, múltiples análisis independientes, control de calidad sistemático y cálculo de concordancia interobservador ($\kappa = 0,82$).

Las amenazas a la validez externa se asocian a la generalización de los hallazgos, dado que los estudios analizados corresponden

a contextos, cultivos y escenarios experimentales diversos. Las amenazas a la validez de construcción se relacionan con la interpretación de conceptos y métricas reportadas, mitigadas mediante una definición clara de los ejes de análisis y una síntesis comparativa estructurada.

Resultados

La Tabla 2 presenta los estudios primarios incluidos en esta RSL, organizados por eje temático. Estos estudios constituyen el corpus final sobre

el cual se construyen los resultados y el análisis presentados en las subsecciones siguientes.

Tabla 2
Estudios primarios incluidos en la RSL

Eje A: Diagnóstico visual de enfermedades en hojas y frutos: 6 estudios				
Estudio	Cultivo	Problema abordado	Enfoque computacional	Métricas reportadas
Faisal y otros (2023)	Café	Enfermedad foliar	CNN + fusión de características (MobileNetV3 + Swin Transformer)	Accuracy, Precision, Recall, F1-score
Muthusamy & Ramu (2025)	Café, Banana	Deficiencia de micronutrientes + enfermedad + severidad	CNN + atención (D-PAN)	Accuracy, Precision, Recall, F1-score, AUC

Abinaya y otros (2023)	Multicultivo	Segmentación y clasificación	Autoencoder + U-Net (CAAR-UNet)	Pixel Accuracy, wIoU, Dice, mBF1
Oumane y otros (2025)	Multicultivo	Detección de enfermedades	<i>Vision transformer</i>	<i>Accuracy, Precision, Recall, F1-score (no AUC)</i>
Noon y otros (2022)	Algodón	Detección + localización	YOLOX	<i>mAP, Precision</i>
Borromeo y otros (2025)	Cacao	Madurez y variedad del fruto	VGG16 + SSD MobileNet	<i>Accuracy</i>

Eje B: Clasificación superficial y calidad poscosecha: 3 estudios

Estudio	Cultivo	Problema abordado	Enfoque computacional	Métricas reportadas
Prakasa y otros (2021)	Maíz	Calidad de semillas	CNN + <i>features</i> (ResNet-50)	<i>F1-score</i> (principal), <i>Accuracy</i>
Pasaribu y otros (2025)	Maíz, yuca, arroz, caña de azúcar	Clasificación de plantas (impacto del aumento de datos con GAN)	MobileNetV2, EfficientNet-B0, ResNet-18	<i>Accuracy</i>
Kant (2024)	Arroz (transferible)	Clasificación de granos	MobileNetV2	<i>Accuracy</i> (0,99), <i>Precision, Recall, F1-score</i> (0,99)

Eje C: Monitoreo y gestión de fincas agrícolas (IoT + plataformas web): 7 estudios				
Estudio	Contexto	Problema abordado	Enfoque tecnológico	Criterios evaluados
Yeong y otros (2024)	Finca, maquinaria	Monitoreo agrícola	Plataforma web + IoT	Funcionalidad
Rao y otros (2019)	Agricultura general	Monitoreo ambiental	IoT	Validación funcional
Aliparo y otros (2022)	Finca agrícola	Nutrientes del suelo	IoT + sensores	Exactitud de medición
Yadav y otros (2025)	Agricultura general	Redes de sensores	IoT	Rendimiento
Bhadra y otros (2025)	Invernadero	Monitoreo en tiempo real	IoT + capacidad offline	Funcionalidad
Hewage y otros (2017)	Gestión agrícola	Gestión de fincas	Plataforma software	Arquitectura
Archambault (2024)	Agricultura digital	Simulación agrícola	Gemelos digitales	Modelado

Nota: Elaboración propia a partir de los estudios primarios incluidos

Resultados para RQ1: Enfoques de visión por computador y aprendizaje profundo para la detección de enfermedades en hojas y frutos agrícolas

Los seis estudios incluidos en el Eje A reportan de manera consistente el uso de aprendizaje profundo, principalmente mediante CNN y arquitecturas derivadas, como enfoque dominante para la detección automática de enfermedades en hojas y frutos agrícolas. Cuatro de los seis estudios emplean CNN como arquitectura base; los dos restantes incorporan *vision transformers* y YOLOX, respectivamente, evidenciando una diversificación metodológica emergente.

En el caso de enfermedades foliares en café, Faisal y otros (2023) reportan un modelo basado en fusión híbrida de características mediante la combinación de MobileNetV3 y Swin Transformer, junto con un autoencoder variacional (VAE), alcanzando un nivel de *accuracy* de 84,29 %, con *precision* de 84,67 %, *recall* de 84,29 % y *F1-score* de 83,64 % en la clasificación de enfermedades en el conjunto de datos RoCoLe de condiciones reales. Este conjunto de datos, de carácter público, comprende 1 560 imágenes de hojas de café robusta capturadas en condiciones de campo. Muthusamy & Ramu (2025) proponen el marco D-PAN (Dynamic Pyramid Attention Network) con mecanismos de atención dinámica, orientado no solo a la detección de enfermedades y deficiencias de

micronutrientes, sino también a la clasificación del nivel de severidad, reportando *accuracy* de 98,80 % para banana y 94,60 % para café (evaluado sobre el conjunto de datos Co-Leaf DB de Mendeley), con desempeño sólido en *accuracy*, *precision*, *recall* y *F1-score*.

Otros estudios amplían el enfoque hacia tareas de segmentación y clasificación, incorporando arquitecturas híbridas. Abinaya y otros (2023) emplean el modelo CAAR-UNet (Cascading Autoencoder with Attention Residual U-Net), evaluando el rendimiento mediante *mean pixel accuracy* (Am) de 95,26 % y *weighted mean Intersection over Union* (wmlIoU) de 0,7451, junto con el coeficiente de Dice y *mean Boundary F1-score* (mBF1), lo que evidencia el uso de métricas más allá de la clasificación tradicional cuando se requiere localización precisa de regiones afectadas.

En cuanto a arquitecturas emergentes, Ouamane y otros (2025) reportan el uso de *vision transformers* optimizados sobre el conjunto de datos público PlantVillage, alcanzando un nivel de *accuracy* de 99,77 %, *precision* de 99,61 %, *recall* de 99,69 % y *F1-score* de 99,64 %, evaluados también sobre los conjuntos de datos Taiwan Tomato y BananaLSD, confirmando su generalización. Asimismo, los enfoques basados en detección de objetos también están presentes en la literatura: Noon y otros (2022) emplean una variante mejorada de YOLOX para manejar múltiples niveles de severidad y enfermedades coexistentes en algodón, utilizando como métrica principal mAP, reportando 73,13 % en entrenamiento y 72,31 % en el conjunto de prueba.

Para el caso de frutos agrícolas, específicamente en cacao, Borromeo y otros (2025) reportan el uso de VGG16 con *transfer learning* para la clasificación visual de madurez y variedad de mazorcas, complementado con SSD MobileNet para detección de objetos, e implementado en una aplicación móvil. El máximo nivel de *accuracy*

reportado es de 88,9 % (combinando clasificación de variedad y madurez con el mayor número de mazorcas disponibles), disminuyendo a 76,7 % con el conjunto más reducido de datos. Aunque el estudio se centra en el estado de madurez y variedad, su inclusión evidencia el uso de visión por computador aplicada directamente a imágenes de mazorcas de cacao como parte de sistemas de inspección visual.

De manera global, los estudios incluidos en este eje emplean métricas de evaluación predominantemente orientadas a clasificación (*accuracy*, *precision*, *recall*, *F1-score*), con una adopción adicional de métricas de segmentación (IoU, Dice) y detección (mAP) cuando la tarea lo requiere.

Resultados para RQ2: Conjuntos de datos, arquitecturas y técnicas empleadas en sistemas de diagnóstico visual agrícola

Los seis estudios del Eje A reportan el uso predominante de conjuntos de datos basados en imágenes RGB capturadas en condiciones controladas o semicontroladas. La mayoría de los conjuntos de datos utilizados son específicos del dominio, aunque cabe destacar que algunos estudios emplean conjuntos de datos públicos de amplia difusión: Faisal y otros (2023) utilizan el conjunto de datos público RoCoLe (1 560 imágenes de hojas de café robusta en condiciones reales), mientras que Ouamane y otros (2025) emplean el conjunto de datos PlantVillage (público, con más de 87 000 imágenes). Los demás estudios construyen conjuntos de datos *ad hoc*, con tamaños que oscilan entre 102 y 1 112 imágenes originales (previo al aumento). Esta heterogeneidad limita la reutilización y comparación directa entre investigaciones y compromete la evaluación de la generalización de los modelos.

Las arquitecturas CNN profundas, incluyendo variantes como ResNet, EfficientNet y personalizaciones, aparecen en cuatro de los seis estudios. Los mecanismos de atención se incorporan en dos estudios (Muthusamy & Ramu, 2025; Abinaya y otros, 2023), permitiendo al modelo enfocarse en regiones relevantes para la tarea. Respecto a técnicas de preprocesamiento, todos los estudios reportan normalización de imágenes y aumento de datos (*data augmentation*), incluyendo rotación, volteo horizontal, recorte aleatorio y ajuste de brillo. Pasaribu y otros (2025) demuestran que el aumento sintético mejora el nivel de *accuracy* entre 3 y 8 puntos porcentuales en modelos ligeros.

En términos de desempeño, los estudios reportan valores de *accuracy* heterogéneos: desde 72,31 % (Noon y otros, 2022, en algodón con un conjunto de datos propio) y 84,29 % (Faisal y otros, 2023, en condiciones reales de campo), hasta 99,77 % (Ouamane y otros, 2025, con el conjunto de datos PlantVillage). Los valores de *accuracy* superiores al 90 % se concentran en estudios que emplean conjuntos de datos controlados o públicos de gran escala (Muthusamy & Ramu, 2025: 94,60–98,80 %; Abinaya y otros, 2023: 95,26 %; Borromeo y otros, 2025: 88,9 %). Sin embargo, estos valores deben interpretarse con cautela, pues fueron obtenidos en condiciones que pueden no ser directamente comparables y sin validación cruzada con datos de campo independientes, lo que limita la valoración de la robustez real de los modelos.

Resultados para RQ3: Modelos preentrenados para la clasificación superficial y evaluación de calidad de granos de maíz

Los tres estudios del Eje B evidencian un uso predominante de modelos de aprendizaje profundo aplicados a imágenes digitales para la clasificación y evaluación de calidad de granos. Prakasa y otros (2021) reportan un sistema basado en CNN con clasificadores de características para categorizar semillas de maíz (variedad BIMA-20 URI Hybrid) en dos clases (buenas y malas), utilizando un conjunto de datos de 232 imágenes capturadas en laboratorio. La métrica principal reportada es el F1-score, con el mejor resultado de 0,983 obtenido con ResNet-50, mientras que la mayoría de los métodos evaluados alcanzan $F1 > 0,90$. El estudio confirma que los enfoques basados en visión por computador permiten automatizar la inspección poscosecha con resultados consistentes.

Pasaribu y otros (2025) analizan el impacto del aumento sintético de datos mediante redes GAN (DCGAN y WGAN-GP) en los modelos MobileNetV2, EfficientNet-B0 y ResNet-18, aplicados a la clasificación de plantas (yuca, maíz, arroz y caña de azúcar). El hallazgo principal del estudio es que el uso de datos generados por GAN impactó negativamente el nivel de *accuracy* de clasificación, debido a la presencia de artefactos y a los altos valores de *Frechet inception distance* (FID). El mayor nivel de *accuracy* reportado fue 97,37 %, obtenido exclusivamente con el conjunto de datos original (245 imágenes), mientras que los modelos entrenados con datos GAN-aumentados experimentaron una reducción en el desempeño. WGAN-GP produjo imágenes visualmente más realistas que DCGAN, pero tampoco logró mejorar el nivel de *accuracy* de clasificación.

Aunque no se centra exclusivamente en maíz, Kant (2024) reporta la aplicación de MobileNetV2 con *transfer learning* para clasificación de cinco variedades de granos de arroz (Arborio, Basmati, Ipsala, Jasmine y Karacadag), obteniendo *accuracy*, *precision*, *recall* y *F1-score* de 0,99. La inclusión de este estudio permite observar la transferibilidad metodológica de arquitecturas ligeras preentrenadas hacia problemas de clasificación superficial de granos agrícolas, bajo escenarios de recursos limitados, lo cual resulta relevante para el contexto poscosecha del maíz.

De manera transversal, los estudios incluidos emplean como métrica principal el *F1-score* (Prakasa y otros, 2021) o el nivel de *accuracy* (Pasaribu y otros, 2025; Kant, 2024). Los modelos preentrenados de baja complejidad (MobileNetV2, EfficientNet-B0) muestran un alto nivel de *accuracy* con el conjunto de datos original (97,37 %), pero su ventaja respecto a arquitecturas más complejas (ResNet-18) resulta marginal cuando el conjunto de datos de entrenamiento es de calidad adecuada.

Resultados para RQ4: Plataformas web e IoT para el monitoreo y la gestión de fincas agrícolas

Los siete estudios del Eje C muestran que las soluciones de monitoreo y gestión de fincas agrícolas se diseñan predominantemente como sistemas IoT integrados con componentes de plataforma de software para adquisición, transmisión, almacenamiento y visualización de datos. Yeong y otros (2024) reportan una plataforma de monitoreo telemático orientada a maquinaria agrícola, con arquitectura software como capa de integración para sensores IoT. Rao y otros (2019) describen un sistema IoT integrado con UAV y redes de sensores ZigBee para el monitoreo ambiental en tiempo real, evaluado principalmente

por funcionalidad y escalabilidad. Aliparo y otros (2022) implementan un sistema IoT para monitoreo de nutrientes del suelo (NPK) con exactitud de medición como criterio evaluativo. Yadav y otros (2025) reportan redes de sensores inteligentes con conectividad IoT, centradas en rendimiento y latencia de transmisión de datos. Bhadra y otros (2025) implementan un sistema IoT con capacidad de monitoreo offline en invernaderos, priorizando la disponibilidad continua de datos.

En cuanto a plataformas web y componentes de gestión, Hewage y otros (2017) reportan un sistema de gestión de fincas agrícolas (FMIS) con prácticas ágiles de ingeniería de software orientadas a la planificación operativa. Archambault (2024) describe modelos de co-simulación y gemelos digitales para agricultura controlada, integrando representaciones computacionales del cultivo para apoyar la toma de decisiones.

Críticamente, ninguno de los siete estudios del Eje C reporta evaluaciones formales basadas explícitamente en la normativa ISO 9241. La evidencia se concentra en criterios de funcionamiento técnico, desempeño del sensado y conectividad. Esta brecha entre la funcionalidad técnica y la evaluación de usabilidad es persistente en todos los estudios del eje.

Discusión

RQ1: Enfoques de diagnóstico visual en hojas y frutos

Los resultados de la RQ1 confirman que el aprendizaje profundo basado en visión por computador se ha consolidado como el enfoque dominante para el diagnóstico automatizado de enfermedades en cultivos. La amplia adopción de CNN y sus variantes (cuatro de seis estudios en el Eje A) refleja su eficacia probada en capturar patrones visuales asociados a síntomas fitosanitarios. Sin embargo, esta dominancia plantea el riesgo de puntos ciegos metodológicos: los modelos CNN son conocidos por su sensibilidad a variaciones de dominio que no están representadas en el conjunto de datos de entrenamiento.

La aparición de *vision transformers* y detectores de objetos como YOLOX no es trivial: refleja una transición del campo hacia modelos con mayor capacidad de atención global y localización espacial, lo cual es particularmente relevante para escenarios agrícolas donde múltiples enfermedades coexisten o donde los límites de las regiones afectadas son difusos. No obstante, estos modelos demandan mayor capacidad computacional y datos de entrenamiento, lo que puede ser limitante para implementaciones en campo con hardware restringido.

Desde una perspectiva de transferencia tecnológica, el principal obstáculo identificado en la literatura es la brecha entre los entornos de evaluación y las condiciones reales de campo. Los valores de *accuracy* reportados varían considerablemente entre estudios: desde 72,31 % (Noon y otros, 2022, con un conjunto de datos propio de algodón) y 84,29 % (Faisal y otros, 2023, en condiciones reales de campo con el conjunto de datos público RoCoLe),

hasta 99,77 % (Ouamane y otros, 2025, con el conjunto de datos PlantVillage de gran escala). Esta heterogeneidad refleja la influencia crítica del conjunto de datos utilizado (tamaño, diversidad, condiciones de captura) sobre el desempeño reportado, y no necesariamente la superioridad de un enfoque arquitectónico sobre otro. Los modelos no se evalúan de forma sistemática frente a variaciones de iluminación natural, ángulos de captura, oclusiones por hojas adyacentes o imágenes tomadas con diferentes dispositivos móviles. Esta brecha de validez externa es el principal impedimento para la adopción masiva de estas tecnologías por agricultores reales.

RQ2: Datos, arquitecturas y robustez en sistemas de diagnóstico visual

El análisis comparativo de los seis estudios del Eje A evidencia una dependencia estructural de los conjuntos de datos contruidos *ad hoc* en cuatro de los seis estudios, cuyo tamaño y diversidad son insuficientes para entrenar modelos generalizables. Dos estudios emplean conjuntos de datos públicos: RoCoLe (Faisal y otros, 2023) y PlantVillage (Ouamane y otros, 2025), lo que favorece la reproducibilidad y comparación con otros trabajos. La totalidad de los estudios mitiga la escasez de datos mediante aumento de estos, lo que es una práctica ampliamente aceptada pero que no reemplaza la diversidad real de condiciones de campo. La ausencia de repositorios públicos estandarizados para enfermedades específicas de cultivos de la región andina (como la roya del cafeto o la moniliasis del cacao) es especialmente crítica.

Los valores de *accuracy* reportados deben interpretarse con cautela metodológica. Faisal y otros (2023) reportan 84,29 % en condiciones reales de campo, lo que contrasta con los 99,77 % de Ouamane y otros (2025) en un conjunto de datos controlado a gran escala, evidenciando que el contexto de evaluación es determinante para interpretar el desempeño reportado. La adopción de métricas complementarias como *F1-score* macro (para clases desbalanceadas), la curva ROC, la curva *precision-recall* y los protocolos de validación cruzada en conjuntos de datos independientes emergen como necesidades metodológicas urgentes para fortalecer la validez externa de los resultados.

RQ3: Precisión y eficiencia en la clasificación poscosecha de granos

Los resultados del Eje B presentan hallazgos matizados sobre el impacto del aumento sintético de datos. Prakasa y otros (2021) confirman que los modelos profundos logran $F1 > 0,90$ (mejor: 0,983 con ResNet-50) en clasificación de semillas de maíz. Kant (2024) demuestra que MobileNetV2 con *transfer learning* alcanza un nivel de *accuracy* de 0,99 en clasificación de granos de arroz, confirmando su viabilidad para aplicaciones poscosecha con recursos limitados. El equilibrio favorable entre precisión y eficiencia computacional de los modelos ligeros preentrenados los hace adecuados para entornos con restricciones de hardware y aplicaciones a pequeña y mediana escala.

Sin embargo, el estudio de Pasaribu y otros (2025) aporta un hallazgo crítico que contradice la asunción generalizada de que el aumento de datos sintéticos mejora el desempeño: el uso de datos generados por GAN (DCGAN y WGAN-

GP) redujo el nivel de *accuracy* de clasificación en comparación con el conjunto de datos original, con el mayor nivel de *accuracy* (97,37 %) obtenido con el conjunto original de 245 imágenes. Este resultado subraya que la calidad del dato sintético —medida por la ausencia de artefactos y por métricas como FID— es más determinante que la cantidad de imágenes generadas. El aumento de datos tradicional (rotaciones, *flips*, ajustes de brillo) sigue siendo la estrategia más confiable para conjuntos de datos pequeños.

Desde una perspectiva de computación aplicada, estos hallazgos refuerzan el potencial de los modelos preentrenados para apoyar procesos de inspección poscosecha automatizada. Sin embargo, también evidencian la necesidad de avanzar hacia evaluaciones más sistemáticas que consideren condiciones reales de operación y análisis de robustez.

RQ4: Monitoreo y gestión de fincas mediante IoT y plataformas web

El análisis crítico de los siete estudios del Eje C revela una desconexión sistemática entre el avance técnico de los sistemas IoT y su evaluación desde la perspectiva del usuario final. Los sistemas reportados priorizan la adquisición, transmisión y disponibilidad de datos, pero ninguno evalúa explícitamente la facilidad de uso, la carga cognitiva del agricultor o la adecuación de la interfaz a contextos rurales con baja alfabetización digital. Esta omisión es especialmente crítica si se considera que la usabilidad es un determinante clave de la adopción tecnológica en el sector agrícola.

La ausencia de evaluaciones formales basadas en ISO 9241 en el corpus analizado contrasta con la amplia disponibilidad de herramientas como el System Usability Scale (SUS), el cuestionario

NASA-TLX o el método de inspección heurística, que podrían integrarse fácilmente en los protocolos de evaluación de plataformas IoT agrícolas. El surgimiento de enfoques como los gemelos digitales (Archambault, 2024) representa una tendencia prometedora hacia simulación y soporte a la toma de decisiones, aunque aún en etapas exploratorias. Desde el marco conceptual de la agricultura 4.0, la convergencia de IoT, IA, computación en la nube y gemelos digitales está reconfigurando la gestión agrícola y las plataformas web deberían ser evaluadas dentro de este ecosistema socio-técnico más amplio.

Síntesis de implicaciones y brechas de investigación

De manera global, la discusión evidencia tres brechas transversales críticas. Primero, la brecha de validez externa: los modelos de aprendizaje profundo y los sistemas IoT se evalúan en entornos controlados y la transferencia a condiciones agrícolas reales requiere protocolos de evaluación más exigentes y conjuntos de datos de campo independientes. Segundo, la brecha de estandarización: la heterogeneidad de los conjuntos de datos, métricas y protocolos experimentales impide la comparación directa entre estudios y la identificación de enfoques óptimos; la creación de *benchmarks* públicos para cultivos agrícolas relevantes a nivel regional es una necesidad urgente. Tercero, la brecha de usabilidad: el diseño centrado en el usuario y la evaluación formal de usabilidad (ISO 9241, SUS, heurísticas de Nielsen) permanecen ausentes de las soluciones IoT analizadas, lo que compromete la adopción efectiva de estas tecnologías por parte de los actores agrícolas.

Limitaciones del trabajo

A pesar del rigor metodológico aplicado en esta RSL, es importante reconocer una serie de limitaciones que afectan directamente la interpretación de los resultados y la solidez de las conclusiones.

En primer lugar, la RSL se basa exclusivamente en estudios publicados en idioma inglés. Esta restricción introduce un sesgo idiomático que puede ser especialmente significativo en el contexto de la computación agrícola latinoamericana y andina, donde existe una base creciente de investigaciones publicadas en español y portugués en repositorios como Latindex, Redalyc o CLACSO. La exclusión de esta literatura gris y regional puede sesgar los hallazgos hacia enfoques tecnológicos desarrollados en contextos agrícolas distintos al latinoamericano, afectando la relevancia local de las conclusiones sobre generalización de modelos y usabilidad.

En segundo lugar, la alta heterogeneidad entre los 16 estudios incluidos, en términos de conjuntos de datos, protocolos experimentales y métricas de evaluación, limitó la posibilidad de realizar comparaciones cuantitativas directas o un metaanálisis estadístico. Esta limitación implica que las tendencias identificadas son de carácter cualitativo y no permiten establecer superioridad absoluta de un enfoque tecnológico sobre otro, lo que restringe la certeza de las conclusiones comparativas.

Una tercera limitación relevante es la dependencia de los conjuntos de datos contruidos *ad hoc* en los ejes de diagnóstico visual y clasificación poscosecha. La escasez de conjuntos de datos públicos y estandarizados hace que los resultados de *accuracy* reportados no puedan ser replicados ni comparados de forma independiente, lo que debilita la validez interna de las conclusiones sobre el desempeño de modelos específicos.

Cuarto, la mayoría de los estudios analiza-

dos evalúa sus propuestas en entornos controlados o semicontrolados, con validación limitada en condiciones reales de campo. Esto implica que las conclusiones sobre la efectividad de los modelos de aprendizaje profundo y de los sistemas IoT son válidas principalmente en el ámbito experimental, y no pueden extrapolarse directamente a escenarios de producción agrícola real sin consideraciones adicionales sobre la robustez y la adaptación al dominio.

Finalmente, en el eje de monitoreo IoT, la

evaluación limitada de usabilidad y la ausencia sistemática de aplicación de estándares como ISO 9241 impide extraer conclusiones sólidas sobre la experiencia de usuario de las plataformas web agrícolas. Esto constituye una limitación metodológica inherente al corpus analizado y no necesariamente refleja el estado del campo en su totalidad, sino el sesgo de publicación hacia aspectos técnicos por encima de los evaluativos.

Conclusiones

Esta RSL analizó y sintetizó la evidencia científica de 16 estudios primarios publicados entre 2017 y 2025, organizados en tres ejes temáticos sobre computación agrícola, con las siguientes conclusiones específicas derivadas del análisis comparativo:

Respecto a RQ1, los seis estudios del Eje A confirman que las CNN con mecanismos de atención constituyen la arquitectura dominante para el diagnóstico visual de enfermedades en hojas y frutos agrícolas. Los valores de *accuracy* varían ampliamente entre estudios: desde 72,31 % (Noon y otros, 2022) y 84,29 % (Faisal y otros, 2023) en condiciones de campo o con conjuntos de datos propios reducidos, hasta 99,77 % (Ouamane y otros, 2025) con el conjunto de datos público PlantVillage a gran escala. Esta variabilidad refleja la influencia del conjunto de datos más que la superioridad arquitectónica absoluta. Los *vision transformers* (Ouamane y otros, 2025) y los detectores de objetos como YOLOX (Noon y otros, 2022) emergen como alternativas competitivas para tareas de localización y clasificación con múltiples enfermedades coexistentes. Sin embargo,

ningún estudio reporta evaluaciones sistemáticas de robustez en condiciones reales de campo, lo que constituye la brecha más crítica del eje.

En cuanto a RQ2, la mayoría de los estudios del Eje A (cuatro de seis) depende de los conjuntos de datos *ad hoc*, aunque dos emplean conjuntos de datos públicos reconocidos (RoCoLe y PlantVillage). El uso generalizado de aumento de datos como mecanismo compensatorio es un hallazgo transversal. Los valores de *accuracy* reportados (72 % a 99,77 %) deben interpretarse en función del contexto de evaluación, pues no reflejan necesariamente el comportamiento en condiciones operativas reales. La estandarización de los conjuntos de datos y la adopción de protocolos de validación cruzada son recomendaciones concretas derivadas de este eje.

Con respecto a RQ3, los tres estudios del Eje B presentan evidencia mixta sobre el aumento de datos sintéticos. Prakasa y otros (2021) confirman que modelos profundos logran $F1 > 0,90$ (mejor: 0,983) en clasificación de maíz. Kant (2024) demuestra que MobileNetV2

alcanza *accuracy* de 0,99 en clasificación de granos de arroz con *transfer learning*. Pasaribu y otros (2025) revelan que el aumento de datos GAN redujo el nivel de *accuracy* frente al conjunto de datos original (97,37 %), cuestionando la efectividad del aumento sintético sin controles de calidad de imagen. No obstante, la ausencia de evaluaciones de eficiencia en *edge devices* y de robustez bajo variaciones de captura limita la validez práctica de estos hallazgos.

Finalmente, en respuesta a RQ4, los siete estudios del Eje C demuestran que las soluciones IoT agrícolas priorizan la funcionalidad técnica (adquisición, transmisión y disponibilidad de datos) sobre la evaluación centrada en el usuario. La ausencia total de evaluaciones basadas en ISO 9241 en el corpus analizado representa una brecha estructural entre el desarrollo tecnológico y la adopción efectiva por parte de los agricultores, especialmente en contextos de baja alfabetización digital.

Trabajos futuros

A partir de los hallazgos y limitaciones identificados, se delinean cuatro líneas prioritarias de trabajo futuro. La primera abarca el desarrollo y adopción de conjuntos de datos públicos, estandarizados y geográficamente diversos para enfermedades agrícolas de relevancia regional (roya del cafeto, moniliasis del cacao, defectos poscosecha de maíz), que permitan evaluar la generalización y reproducibilidad de los modelos de diagnóstico visual y clasificación. La segunda implica la validación de modelos directamente en condiciones reales de campo, incorporando variabilidad ambiental, ruido visual y restricciones operativas, con protocolos que incluyan métricas de robustez, eficiencia energética y tiempo de inferencia en dispositivos de borde.

La tercera comprende la integración sistemática de criterios de usabilidad (ISO 9241, SUS, heurísticas de Nielsen) desde las etapas tempranas de diseño de plataformas web e IoT agrícolas, incorporando metodologías de diseño participativo con agricultores. Finalmente, la cuarta línea asume la exploración de enfoques emergentes como los modelos fundacionales con *fine-tuning* para dominios agrícolas, la integración de gemelos digitales con IA predictiva, y la aplicación de técnicas de aprendizaje federado para preservar la privacidad de los datos agrícolas en sistemas de monitoreo distribuido.

Agradecimientos

Extendemos nuestro más sincero reconocimiento a la Universidad Nacional de Loja (UNL) y, en particular, a la carrera de Computación y al Grupo de Investigación en Tecnologías de la Información y Computación (GITIC) por su invaluable apoyo y los recursos proporcionados para la realización de esta investigación. Este artículo es el resultado de un esfuerzo académico desarrollado en el marco de la asignatura "Proyectos Tecnológicos 1", impartida durante el período académico comprendido entre septiembre 2025 y febrero 2026. Agradecemos la guía y el estímulo intelectual recibidos, que han sido fundamentales para la consecución de este trabajo y para nuestro crecimiento como investigadores en el campo de las ciencias de la computación

Declaración de conflictos de interés

Quienes firman este artículo declaran no tener conflictos de interés.

Fuentes de financiación (obligatorio)

Este trabajo forma parte del proyecto de investigación “Desarrollo de un marco de trabajo de Inteligencia Artificial para integrar y fortalecer las funciones sustantivas en la Universidad Nacional de Loja y su escalabilidad en

las Universidades Públicas de Ecuador” (código de proyecto: 32-DI-FEIRNR-2025) financiado totalmente por la UNL.

Declaración de uso de inteligencia artificial

Los autores declaran el uso de inteligencia artificial generativa en el proceso de investigación y redacción. De acuerdo con la taxonomía GAIDeT (2025), las siguientes tareas fueron delegadas a herramientas de IAG bajo plena supervisión humana:

- Generación de ideas, definición del objetivo de investigación, formulación de preguntas de investigación e hipótesis, redacción de la revisión de la literatura, diseño de la investigación, curaduría y organización de datos, análisis de datos, generación de texto, revisión y edición, síntesis de textos, formulación de conclusiones, traducción, identificación de limitaciones.

Las herramientas de IAG utilizadas fueron: ChatGPT 5.2 y NotebookLM.

La responsabilidad del manuscrito final recae íntegramente en los autores.

Las herramientas de IAG no figuran como autoras ni asumen responsabilidad alguna sobre los resultados finales.

Contribución de autoría (CRedit):

Luis Chamba-Eras: Conceptualización; metodología; validación; análisis formal; investigación; recursos; gestión de datos; redacción - borrador original; redacción - revisión y edición; supervisión; administración del proyecto.

Sergio Jumbo-Gonza: Validación; análisis formal; investigación; recursos; gestión de datos; redacción - revisión y edición; administración del proyecto.

Walter Yaguana-Alejandro: Validación; análisis formal; investigación; recursos; gestión de datos; redacción - revisión y edición; administración del proyecto;

Geovanny Romero-Suquilanda: Validación; análisis formal; investigación; recursos; gestión de datos; redacción - revisión y edición; administración del proyecto;

Gerardo Herrera-Campoverde: Validación; análisis formal; investigación; recursos; gestión de datos; redacción - revisión y edición; administración del proyecto;

Referencias

- Abinaya, S., Kumar, K. U., & Alphonse, A. S. (2023). Cascading autoencoder with attention residual u-net for multi-class plant leaf disease segmentation and classification. *IEEE Access*, 11, 98153-98170.
<https://doi.org/10.1109/ACCESS.2023.3312718>
- Aliparo, J., Santos, C. D., Sese, C. M., Trinidad, J. ver, Beano, M. G., Capuno, M. E. A., Medina, O., Sigue, A., & Soriano, A. (2022). IoT-based assessment and monitoring of NPK content and fertility condition of soil. En *TENCON 2022 - 2022 IEEE Region 10 Conference (TENCON)* (pp. 1-6).
<https://doi.org/10.1109/TENCON55691.2022.9978040>
- Archambault, P. (2024). Co-simulation and crop representation for digital twins of controlled environment agriculture systems. En *Proceedings of the ACM/IEEE 27th International Conference on Model Driven Engineering Languages and Systems* (pp. 196-199).
<https://doi.org/10.1145/3652620.3676879>
- Bhadra, T., Mujakkir-UI-Islam, & Alam, N. (2025). IoT-based real-time data monitoring of a green house farm with offline monitoring capability. En *2025 4th International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)* (pp. 111-116).
<https://doi.org/10.1109/ICREST63960.2025.10914444>
- Borromeo, K. O., Bonotan, M. R., Llagas, A. P., Juan, J. M. O., Sanchez, P. D. C., & Berro, N. K. A. (2025). Classification of cacao pods ripeness using convolutional neural networks. *Procedia Computer Science*, 257, 1197-1204.
<https://doi.org/10.1016/j.procs.2025.03.160>
- Brereton, P., Kitchenham, B. A., Budgen, D., Turner, M., & Khalil, M. (2007). Lessons from applying the systematic literature review process within the software engineering domain. *Journal of Systems and Software*, 80(4), 571-583.
<https://doi.org/10.1016/j.jss.2006.07.009>
- Faisal, M., Leu, J.-S., & Darmawan, J. T. (2023). Model Selection of Hybrid Feature Fusion for Coffee Leaf Disease Classification. *IEEE Access*, 11, 62281-62291.
<https://doi.org/10.1109/ACCESS.2023.3286935>
- GAIDeT. (2025). Generative Artificial Intelligence Disclosure Taxonomy (GAIDeT). <https://panbibliotekar.github.io/gaidet-declaration/>

- Garg, D., & Gill, K. S. (2024). *Revolutionizing rice quality control: MobileNetV2 for grain classification*. En *2024 2nd International Conference on Advances in Computation, Communication and Information Technology (ICAICCT)* (pp. 809-812).
<https://doi.org/10.1109/ICAICCT64383.2024.10912366>
- Hewage, P., Anderson, M., & Fang, H. (2017). An agile farm management information system framework for precision agriculture. En *Proceedings of the 9th International Conference on Information Management and Engineering* (pp. 75-80).
<https://doi.org/10.1145/3149572.3149583>
- Kant, V. (2024). Efficient rice grain classification using MobileNetV2: A deep learning approach. En *2024 4th International Conference on Technological Advancements in Computational Sciences (ICTACS)* (pp. 989-993).
<https://doi.org/10.1109/ICTACS62700.2024.10840597>
- Kitchenham, B., Pretorius, R., Budgen, D., Pearl Brereton, O., Turner, M., Niazi, M., & Linkman, S. (2010). Systematic literature reviews in software engineering – A tertiary study. *Information and Software Technology*, 52(8), 792-805.
<https://doi.org/10.1016/j.infsof.2010.03.006>
- Konakalla, S., Kunchala, L. V., & Yellampalli, S. S. (2021). Smart Agriculture using IoT & Filtering Technology. En *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-5).
<https://doi.org/10.1109/ICCCNT51525.2021.9579730>
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174.
<https://doi.org/10.2307/2529310>
- Muthusamy, S., & Ramu, S. P. (2025). A dynamic attention-guided deep learning framework (d-pan) with reduced complexity for fine grained severity-aware classification of micronutrient deficiency and disease detection in banana and coffee leaves. *IEEE Access*, 13, 153474-153497.
<https://doi.org/10.1109/ACCESS.2025.3599359>
- Noon, S. K., Amjad, M., Qureshi, M. A., & Mannan, A. (2022). Handling Severity Levels of Multiple Co-Occurring Cotton Plant Diseases Using Improved YOLOX Model. *IEEE Access*, 10, 134811-134825.
<https://doi.org/10.1109/ACCESS.2022.3232751>

- Nugroho, L. E., Pratama, A. G. H., Mustika, I. W., & Ferdiana, R. (2017). Development of monitoring system for smart farming using Progressive Web App. En *2017 9th International Conference on Information Technology and Electrical Engineering (ICITEE)* (pp. 1-5).
<https://doi.org/10.1109/ICITEED.2017.8250513>
- Ouamane, A., Chouchane, A., Himeur, Y., Miniaoui, S., Atalla, S., Mansoor, W., & Al-Ahmad, H. (2025). Optimized vision transformers for superior plant disease detection. *IEEE Access*, 13, 48552-48570.
<https://doi.org/10.1109/ACCESS.2025.3547416>
- Pasaribu, F. B., Dewi, L. J. E., Aryanto, K. Y. E., & Varnakovida, P. (2025). Effect of synthetic data augmentation on plant classification accuracy using MobileNetV2, EfficientNet-B0, and ResNet-18. En *2025 IEEE 5th International Conference on Software Engineering and Artificial Intelligence (SEAI)* (pp. 1-6).
<https://doi.org/10.1109/SEAI65851.2025.11108883>
- Prakasa, E., Prajitno, D. R., Nur, A., Sulisty, K. A., & Rachmawati, E. (2021). Quality categorisation of corn (*Zea mays*) seed using feature-based classifier and deep learning on digital images. En *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)* (pp. 498-505).
<https://doi.org/10.1109/3ICT53449.2021.9581464>
- Rahman, Z. U., Asaari, M. S. M., Ibrahim, H., Abidin, I. S. Z., & Ishak, M. K. (2024). Generative Adversarial Networks (GANs) for image augmentation in farming: A review. *IEEE Access*, 12, 179912-179943.
<https://doi.org/10.1109/ACCESS.2024.3505989>
- Rao, A., Shao, H., & Yang, X. (2019). The design and implementation of smart agricultural management platform based on UAV and wireless sensor network. En *2019 IEEE 2nd International Conference on Electronics Technology (ICET)* (pp. 248-252).
<https://doi.org/10.1109/ELTECH.2019.8839480>
- Yadav, S., T S, D., & Kokil, P. (2026). An IoT-enabled smart sensor system for real-time monitoring of soil and air conditions with integrated web-based farming guidance. *IEEE Sensors Journal*, 26(1), 1267-1275.
<https://doi.org/10.1109/JSEN.2025.3619663>
- Yeong, D. J., Panduru, K., & Walsh, J. (2024). Smart agriculture: Software platform for telematics monitoring in farm machinery. En *2024 35th Irish Signals and Systems Conference (ISSC)* (pp. 1-6).
<https://doi.org/10.1109/ISSC61953.2024.10602840>
- Yue, X., Qi, K., Na, X., Liu, Y., Yang, F., & Wang, W. (2025). Deep learning for recognition and detection of plant diseases and pests. *Neural Computing and Applications*, 37(17), 11265-11310. h
<https://doi.org/10.1007/s00521-025-11125-5>

A systematic literature review

**of computational solutions applied to agriculture:
visual disease diagnosis, postharvest classification,
and intelligent IoT-based monitoring**

Luis Chamba-Eras¹

Sergio Jumbo-Gonza²

Walter Yaguana-Alejandro³

Geovanny Romero-Suquilanda⁴

Gerardo Herrera-Campoverde⁵

¹Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0000-0003-3069-9628>
lachamba@unl.edu.ec

²Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0000-0003-3069-9628>
sergio.jumbo@unl.edu.ec

³Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0009-0006-2614-8734>
walter.yaguana@unl.edu.ec

⁴Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0009-0004-7121-1574>
geovanny.romero@unl.edu.ec

⁵Universidad Nacional de Loja, Facultad de la Energía, las Industrias y los Recursos Naturales No Renovables, Grupo de Investigación en Tecnologías de la Información y Computación, Carrera de Computación, Loja, Ecuador,
<https://orcid.org/0009-0006-7925-2594>
gerardo.herrera@unl.edu.ec

DOI: 10.61854/rccedia.v1n1.007

Sent: February 1, 2026

Approved: April 6, 2026

Published: Tuesday, July 14, 2026



This work is licensed under a Creative Commons
Attribution-NonCommercial 4.0 International License.

Abstract

Agriculture faces increasing challenges related to timely disease diagnosis, postharvest quality assessment, and efficient farm management. In this context, computational solutions based on artificial intelligence, computer vision, and IoT technologies have emerged as key tools to support agricultural decision-making. This paper presents a systematic literature review (SLR) aimed at analyzing and synthesizing recent scientific evidence on computational approaches applied to (1) automatic disease detection in agricultural leaves and fruits, (2) surface classification and postharvest quality assessment of grains, and (3) farm monitoring and management through web platforms and IoT. The SLR followed the Kitchenham guidelines and the PRISMA protocol, applying explicit criteria for study identification, selection, quality assessment, and synthesis. A total of 263 initial records were identified; after screening and quality assessment, 16 primary studies were included: 6 on visual disease diagnosis (Axis A), 3 on postharvest grain classification (Axis B), and 7 on IoT-based farm monitoring (Axis C). The results indicate that deep learning (convolutional neural networks, attention mechanisms, and pretrained models) dominates visual diagnosis and postharvest classification. In addition, IoT-based infrastructures are widely adopted for agricultural monitoring, although usability evaluation and systematic application of standards such as ISO 9241 remain limited. Unlike previous reviews focused on generic technologies or specific crops, this SLR structures evidence by concrete agricultural problems, integrating visual diagnosis, postharvest classification, and IoT monitoring into a unified comparative analysis. Finally, the review identifies research gaps related to model generalization, dataset standardization, and validation under real-field conditions, which define future research directions in computational agriculture.

Keywords:

applied deep learning, postharvest grain classification, IoT agricultural monitoring.

Introduction

Contemporary agriculture faces growing challenges related to food security, environmental sustainability, and productive efficiency, intensified by climate change, pressure on natural resources, and the need to optimize production systems. In this context, computational solutions play a strategic role in supporting agricultural diagnosis, monitoring, and control processes, especially in scenarios where traditional methods are costly, subjective, or difficult to scale. Technologies such as artificial intelligence (AI), computer vision, deep learning, and web platforms integrated with IoT sensors are essential tools within the field of computing applied to agriculture (Ouamane et al., 2025; Yue et al., 2025).

One of the problems most frequently addressed in the recent literature is the early detection of diseases in agricultural crops because of their direct impact on productivity and profitability. In crops such as coffee, foliar diseases such as coffee leaf rust (*Hemileia vastatrix*) represent a significant threat to production. Several studies show that traditional visual diagnostic methods based on manual inspection have limitations in terms of accuracy, timeliness, and dependence on expert knowledge. In response to these limitations, approaches based on computer vision and deep neural networks have shown promising results for the automatic detection of foliar diseases, achieving high levels of accuracy compared with manual methods (Faisal et al., 2023; Muthusamy & Ramu, 2025).

Similarly, disease detection in agricultural fruits, such as cocoa pods, has been addressed through deep learning models aimed at recognizing visual patterns associated with defects and diseases. The literature reports the widespread use of convolutional neural networks (CNNs) trained with fruit images, as well as the use of pre-processing and data augmentation techniques to mitigate the scarcity of labeled datasets. However, challenges related to model generalization and the variability of image acquisition conditions in the field have also been identified, limiting their direct transfer to real-world production scenarios (Borromeo et al., 2025; Yue et al., 2025).

Another relevant aspect of the agricultural production cycle is the surface classification and quality assessment of grains during postharvest stages, particularly in crops such as maize. In this domain, pretrained deep learning models such as MobileNetV2 and EfficientNet have been widely studied because of their ability to balance accuracy and computational efficiency, facilitating their implementation in resource-constrained environments (Garg & Gill, 2024). The available evidence suggests that these approaches enable the automation of visual grain inspection with competitive results. Nevertheless, questions remain regarding the influence of the quality, quantity, and diversity of datasets on the models' generalization capability (Prakasa et al., 2021; Pasaribu et al., 2025; Kant, 2024).

In agricultural applications based on computer vision, one of the recurring challenges is the limited availability and imbalance of datasets, which affect the generalization capability of deep learning models. Several strategies have been proposed to mitigate this problem, such as data augmentation through synthetic data generation techniques. In particular, the use of generative adversarial networks (GANs) has been explored as an approach to enrich agricultural image datasets, although with mixed results regarding their impact on model performance (Rahman et al., 2024; Pasaribu et al., 2025).

Beyond visual diagnosis and postharvest classification, farm management constitutes an essential component of modern agriculture. In this area, IoT sensor-based web platforms enable the continuous monitoring of agricultural and environmental variables, supporting informed decision-making. However, the literature highlights that the effectiveness of these solutions depends not only on their technical functionality but also on aspects related to usability, software quality, and human-computer interaction. In this regard, standards such as ISO 9241 have been used to evaluate agricultural web platforms developed in simulated or prototype environments (Yeong et al., 2024; Nugroho et al., 2017).

Several previous systematic reviews have partially addressed these topics. Yue et al. (2025) conducted a review of deep learning applied to disease and pest recognition, concluding that CNNs and vision transformers are the dominant

approaches. However, they also identified a lack of evaluations under real field conditions. Similarly, Rahman et al. (2024) reviewed the use of GANs for data augmentation in agriculture, identifying a significant gap in the evaluation of the quality of the generated synthetic images. Nevertheless, none of these reviews integrates visual disease diagnosis, postharvest classification, and IoT-based agricultural monitoring into a unified comparative analysis structured around specific agricultural problems. This thematic and methodological fragmentation hinders an integrated understanding of technological trends, predominant evaluation metrics, and research gaps from the perspective of applied computing.

In this context, the objective of this article is to systematically analyze and synthesize the recent scientific literature on the use of computational solutions applied to specific agricultural problems. In particular, the systematic literature review (SLR) focuses on: (1) the automatic detection of diseases in the leaves and fruits of agricultural crops, with an emphasis on coffee and cocoa; (2) the surface classification and quality assessment of agricultural grains in postharvest contexts, especially maize; and (3) the monitoring and management of agricultural farms through IoT sensor-based web platforms, considering usability and software quality criteria in simulated or prototype environments.

The time interval from 2017 to 2025 was deliberately selected to capture the period of greatest proliferation and maturity of modern

deep learning architectures, such as vision transformers, attention models, and lightweight pre-trained architectures, as well as the accelerated expansion of IoT infrastructures in agricultural environments. This period also coincides with the increasing publication of validation studies under semi-controlled conditions and the emergence of novel approaches such as agricultural digital twins. Nevertheless, it is acknowledged that this decision introduces a potential selection bias toward recent technologies, excluding earlier foundational studies that are also relevant for understanding the evolution of the field.

The main contributions of this article are: (1) to present an SLR structured around specific agricultural problems with complete PRISMA traceability; (2) to synthesize the approaches, architectures, and evaluation metrics used in computer vision- and deep learning-based solutions; (3) to analyze the balance between accuracy and computational efficiency of pretrained models applied to the surface classification of grains; and (4) to systematize software engineering practices and usability criteria reported in IoT-based agricultural web platforms, with an emphasis on the ISO 9241 standard.

This work is structured around the following research questions: RQ1, what computer vision and deep learning approaches have been reported for the automatic detection of diseases in the leaves and fruits of agricultural crops, particularly coffee and cocoa, and what metrics are used to evaluate them?; RQ2, which datasets, preprocessing techniques, and neural network architectures are most frequently used in agricultural visual diagnosis systems, and which achieve the best results in terms of accuracy and robustness?; RQ3, which pretrained deep learning models have demonstrated the best balance between accuracy and computational efficiency in the surface classification and quality assessment of agricultural grains, with an emphasis on maize, under computational resource constraints?; and RQ4, how are IoT sensor-based web platforms for agricultural farm monitoring and management designed and evaluated, and which usability, software quality, and regulatory criteria, such as ISO 9241, are considered in simulated or prototype environments?

Methods

Study design

A systematic literature review (SLR) was conducted to identify, analyze, and synthesize scientific evidence on the use of computational solutions applied to specific agricultural problems. The study adopts an explicit, reproducible, and structured approach, following the methodological process defined by Brereton et al. (2007) in the context of computing and related disciplines, and aligned with the PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) protocol to ensure the traceability and transparency of the selection process.

This SLR is exploratory-descriptive in nature, as its objective is not to quantitatively compare homogeneous experimental results, but rather to identify trends, technological approaches, evaluation metrics, and research gaps within the analyzed domain. The study does not include primary experimentation or the implementation of new models, relying exclusively on the critical analysis of peer-reviewed scientific literature.

Literature search strategy

The literature search strategy was systematically designed to cover the domain of computing applied to agriculture, with an emphasis on visual disease diagnosis, postharvest quality classification, and intelligent agricultural farm monitoring. The scientific databases IEEE Xplore, Scopus, SpringerLink, ScienceDirect, and ACM Digital Library were searched, as they were selected for their broad coverage of publications in computer science and engineering.

The search strings were constructed using the PICOC (population, intervention, comparison, outcome, context) approach. Terms associated with the agricultural population and context (plant disease, coffee, cacao, maize, farm monitoring) were combined with terms related to computational interventions (computer vision, deep learning, pretrained models, IoT, web platform, usability, ISO 9241), using the Boolean operators AND and OR.

The search process was carried out iteratively, progressively refining the search strings based on the preliminary analysis of the retrieved results, with the aim of maximizing relevance and minimizing the retrieval of non-relevant studies. Searches were restricted to titles, abstracts, and keywords.

Inclusion and exclusion criteria

The retrieved studies were evaluated using predefined inclusion and exclusion criteria:

Inclusion criteria:

- Peer-reviewed scientific articles published in journals or conference proceedings.
- Studies published between 2017 and 2025, a period that captures the greatest maturity of modern deep learning architectures.
- Studies applying computational solutions (AI, computer vision, deep learning, web platforms, or IoT) to specific agricultural problems.
- Studies reporting quantitative evaluation metrics or formal system evaluation criteria.
- Publications available in English.

Exclusion criteria:

- Non-peer-reviewed articles (editorials, extended abstracts, or technical reports).
- Purely conceptual studies without experimental, simulated, or evaluative validation.
- Duplicate publications across databases.
- Studies whose focus is not clearly related to agricultural applications or applied computing.
- Studies with insufficient information to answer the research questions (quality score < 3; see the section “Quality Assessment of the Studies”).

Study selection process and PRISMA flow

The study selection process was carried out independently by two researchers, applying three sequential analyses. Discrepancies between reviewers were resolved through consensus. The interobserver agreement level was calculated using

Cohen's kappa coefficient ($\kappa = 0.82$), indicating substantial agreement according to the thresholds established by Landis & Koch (1977).

In the first analysis (title and abstract), 263 records retrieved from the five databases were evaluated. After removing 47 duplicates ($N = 216$ unique records), studies whose domain, focus, or context did not align with the research questions were excluded, resulting in 52 preselected studies. The second analysis consisted of a focused review of the introduction, methodology, and conclusions of these 52 studies, allowing the evaluation of methodological rigor and the consistency between objectives, methods, and results; 24 studies passed this stage. In the third analysis, a complete critical reading with systematic quality control was conducted, resulting in the final inclusion of 16 primary studies. Table 1 and Figure 1 summarize the selection flow according to the PRISMA 2020 protocol.

Table 1
Study Selection Flow According to the PRISMA Protocol

PRISMA Phase	Description	No. of records
Identification	Records retrieved from five databases (IEEE Xplore, Scopus, SpringerLink, ScienceDirect, ACM)	263
Duplicate removal	Records removed due to duplication across databases	47
Screening (analysis 1)	Evaluation by title and abstract; excluded due to non-relevant domain	216 screened, 164 excluded
Eligibility (analysis 2)	Review of the introduction, methodology, and conclusions; excluded due to methodological insufficiency	52 evaluated, 28 excluded
Included (analysis 3)	Full critical reading and quality assessment (QC ≥ 3); studies comprising the final synthesis	16 included

Note: Prepared by the authors




Figure 1

Study Selection Flow Diagram According to the PRISMA Protocol

Quality assessment of the studies

The quality assessment of the included studies was conducted using an evaluation instrument based on five quality criteria (QC), following the recommendations of Kitchenham et al. (2010). Each criterion was scored in a binary manner (0 = does not meet; 1 = meets), with a minimum acceptance threshold of 3 out of 5 points for inclusion in the final synthesis:

- QC1: Is the research objective or problem clearly defined and delimited?
- QC2: Is the methodology adequately described (approach, data, model, or system)?
- QC3: Is the dataset specified, including its size, source, or relevant characteristics?
- QC4: Are quantitative evaluation metrics (accuracy, F1-score, mAP, IoU, etc.) or formal system evaluation criteria reported?
- QC5: Are the conclusions supported by the reported experimental or evaluative results?

Each study was independently evaluated by the two reviewers, and the final score corresponded to the average of both evaluations. The eight studies excluded in the third analysis obtained scores below 3, mainly because they reported results without describing the dataset (QC3) or without quantitative metrics (QC4).

Information synthesis strategy

The information was synthesized using a qualitative-comparative approach structured according to the three predefined thematic axes. For each axis, a homogeneous extraction matrix was constructed including: (1) study identifica-

tion (authors, year, source database); (2) crop or agricultural context; (3) problem addressed; (4) computational approach and architecture; and (5) evaluation metrics and reported values.

The thematic synthesis was conducted through inductive axial coding of the extracted data, identifying emerging patterns regarding dominant technological approaches, methodological trends, and recurring research gaps. No quantitative meta-analysis was performed because of the heterogeneity of approaches, metrics, and experimental contexts reported in the analyzed studies, which made the statistical aggregation of results unfeasible. The identified patterns were validated through triangulation between the two reviewer researchers.

Threats to validity

As with any SLR, this study presents potential threats to validity, which are addressed according to the classification proposed by Brereton et al. (2007). Threats to internal validity are related to potential biases in the selection and evaluation of studies; these were mitigated through explicit criteria, multiple independent analyses, systematic quality control, and the calculation of interobserver agreement ($\kappa = 0.82$).

Threats to external validity are associated with the generalizability of the findings, given that the analyzed studies correspond to diverse contexts, crops, and experimental scenarios. Threats to construct validity are related to the interpretation of the reported concepts and metrics and were mitigated through a clear definition of the analysis axes and a structured comparative synthesis.

Results

Table 2 presents the primary studies included in this SLR, organized by thematic axis. These studies constitute the final corpus on

which the results and analysis presented in the following subsections are based.

Table 2
Primary studies included in the SLR

Axis A. Visual Diagnosis of Diseases in Leaves and Fruits: 6 Studies				
Study	Crop	Problem addressed	Computational approach	Reported metrics
Faisal et al. (2023)	Coffee	Foliar disease	CNN + feature fusion (MobileNetV3 + Swin Transformer)	Accuracy, Precision, Recall, F1-score
Muthusamy & Ramu (2025)	Coffee, Banana	Micronutrient deficiency + disease + severity	CNN + attention (D-PAN)	Accuracy, Precision, Recall, F1-score, AUC

Abinaya et al. (2023)	Multiple crops	Segmentation and classification	Autoencoder + U-Net (CAAR-UNet)	Pixel Accuracy, wmlou, Dice, mBF1
Quamane et al. (2025)	Multiple crops	Disease detection	Vision transformer	Accuracy, Precision, Recall, F1-score (no AUC)
Noon et al. (2022)	Cotton	Detection + localization	YOLOX	mAP, Precision
Borromeo et al. (2025)	Cocoa	Fruit maturity and variety	VGG16 + SSD MobileNet	Accuracy

Axis B: Surface Classification and Postharvest Quality Assessment: 3 Studies

Study	Crop	Problem Addressed	Computational Approach	Reported Metrics
Prakasa et al. (2021)	Maize	Seed quality	CNN + features (ResNet-50)	F1-score (primary), Accuracy
Pasaribu et al. (2025)	Maize, cassava, rice, sugarcane	Plant classification (impact of GAN-based data augmentation)	MobileNetV2, EfficientNet-B0, ResNet-18	Accuracy
Kant (2024)	Rice (transferable)	Grain classification	MobileNetV2	Accuracy (0.99), Precision, Recall, F1-score (0.99)

Axis C: Agricultural Farm Monitoring and Management (IoT + Web Platforms): 7 Studies				
Study	Context	Problem Addressed	Technological Approach	Evaluation Criteria
Yeong et al. (2024)	Farm, machinery	Agricultural monitoring	Web platform + IoT	Functionality
Rao et al. (2019)	General agriculture	Environmental monitoring	IoT	Functional validation
Aliparo et al. (2022)	Agricultural farm	Soil nutrients monitoring	IoT + sensors	Measurement accuracy
Yadav et al. (2025)	General agriculture	Sensor networks	IoT	Performance
Bhadra et al. (2025)	Greenhouse	Real-time monitoring	IoT + offline capability	Functionality
Hewage et al. (2017)	Agricultural management	Farm management	Software platform	Architecture
Archambault (2024)	Digital agriculture	Agricultural simulation	Digital twins	Modeling

Note: Prepared by the authors based on the included primary studies.

Results for RQ1: Computer vision and deep learning approaches for the detection of diseases in agricultural leaves and fruits

The six studies included in Axis A consistently report the use of deep learning, primarily through CNNs and derived architectures, as the dominant approach for the automatic detection of diseases in agricultural leaves and fruits. Four of the six studies employ CNNs as the core architecture, while the remaining two incorporate vision transformers and YOLOX, respectively, demonstrating an emerging methodological diversification.

For coffee foliar diseases, Faisal et al. (2023) report a model based on hybrid feature fusion through the combination of MobileNetV3 and Swin Transformer, together with a variational autoencoder (VAE), achieving an accuracy of 84.29%, with a precision of 84.67%, recall of 84.29%, and F1-score of 83.64% for disease classification using the real-world RoCoLe dataset. This publicly available dataset comprises 1,560 images of Robusta coffee leaves captured under field conditions. Muthusamy & Ramu (2025) propose the Dynamic Pyramid Attention Network (D-PAN) framework with dynamic attention mechanisms, designed not only for disease and micronutrient deficiency detection but also for severity level classification, reporting an accuracy of 98.80% for banana and 94.60% for

coffee (evaluated on the Mendeley Co-Leaf DB dataset), with consistently strong performance in accuracy, precision, recall, and F1-score.

Other studies extend the approach to segmentation and classification tasks by incorporating hybrid architectures. Abinaya et al. (2023) employ the CAAR-UNet (Cascading Autoencoder with Attention Residual U-Net) model, evaluating performance using mean pixel accuracy (Am) of 95.26% and weighted mean Intersection over Union (wmIoU) of 0.7451, together with the Dice coefficient and mean Boundary F1-score (mBF1), demonstrating the use of metrics beyond traditional classification when precise localization of affected regions is required.

Regarding emerging architectures, Ouamane et al. (2025) report the use of optimized vision transformers on the public PlantVillage dataset, achieving an accuracy of 99.77%, precision of 99.61%, recall of 99.69%, and F1-score of 99.64%, also evaluated on the Taiwan Tomato and BananaLSD datasets, confirming their generalization capability. Likewise, object detection approaches are also represented in the literature: Noon et al. (2022) employ an improved YOLOX variant to handle multiple severity levels and coexisting diseases in cotton, using mAP as the primary evaluation metric, reporting 73.13% during training and 72.31% on the test set.

For agricultural fruits, specifically cocoa, Borromeo et al. (2025) report the use of VGG16 with transfer learning for the visual classification of pod maturity and variety, complemented by SSD MobileNet for object detection and implemented in a mobile application. The highest reported accuracy is 88.9% (combining variety and maturity classification with the largest available number of pods), decreasing to 76.7% when using the smallest dataset. Although the study focuses on maturity stage and variety, its inclusion demonstrates the application of com-

puter vision directly to cocoa pod images as part of visual inspection systems.

Overall, the studies included in this axis predominantly employ classification-oriented evaluation metrics (accuracy, precision, recall, F1-score), with additional adoption of segmentation metrics (IoU, Dice) and detection metrics (mAP) when required by the task.

Results for RQ2: Datasets, architectures, and techniques used in agricultural visual diagnosis systems

The six studies in Axis A predominantly report the use of RGB image datasets captured under controlled or semi-controlled conditions. Most of the datasets used are domain-specific; however, some studies employ widely used public datasets. Faisal et al. (2023) use the public RoCoLe dataset (1,560 images of Robusta coffee leaves under real field conditions), whereas Ouamane et al. (2025) use the public PlantVillage dataset (more than 87,000 images). The remaining studies construct ad hoc datasets ranging from 102 to 1,112 original images (prior to augmentation). This heterogeneity limits reuse and direct comparison across studies and compromises the assessment of model generalization.

Deep CNN architectures, including variants such as ResNet, EfficientNet, and customized models, appear in four of the six studies. Attention mechanisms are incorporated in two studies (Muthusamy & Ramu, 2025; Abinaya et al., 2023), allowing the model to focus on task-relevant regions. Regarding preprocessing techniques, all studies report image normalization and data augmentation, including rotation, horizontal flipping, random cropping, and brightness adjustment. Pasaribu et al. (2025) demonstrate that synthetic augmentation im-

proves accuracy by 3 to 8 percentage points in lightweight models.

In terms of performance, the reported accuracy values are heterogeneous, ranging from 72.31% (Noon et al., 2022, on cotton using a proprietary dataset) and 84.29% (Faisal et al., 2023, under real field conditions) to 99.77% (Ouaiane et al., 2025, using the PlantVillage dataset). Accuracy values above 90% are concentrated in studies using controlled or large-scale public datasets (Muthusamy & Ramu, 2025: 94.60–98.80%; Abinaya et al., 2023: 95.26%; Borromeo et al., 2025: 88.9%). However, these values should be interpreted with caution, as they were obtained under conditions that may not be directly comparable and without cross-validation using independent field data, limiting the assessment of the models' actual robustness.

Results for RQ3: Pretrained models for surface classification and quality assessment of maize grains

The three studies in Axis B demonstrate the predominant use of deep learning models applied to digital images for grain classification and quality assessment. Prakasa et al. (2021) report a CNN-based system with feature classifiers to categorize maize seeds (BIMA-20 URI Hybrid variety) into two classes (good and poor quality), using a dataset of 232 laboratory-acquired images. The primary reported metric is the F1-score, with the best result of 0.983 obtained using ResNet-50, while most evaluated methods achieve F1-scores greater than 0.90. The study confirms that computer vision-based approaches enable the automation of postharvest inspection with consistent results.

Pasaribu et al. (2025) analyze the impact of synthetic data augmentation using GANs (DCGAN and WGAN-GP) on MobileNetV2, EfficientNet-B0, and ResNet-18 models applied to plant classification (cassava, maize, rice, and sugarcane). The main finding is that GAN-generated data negatively affected classification accuracy because of image artifacts and high Frechet Inception Distance (FID) values. The highest reported accuracy was 97.37%, obtained exclusively with the original dataset (245 images), whereas models trained with GAN-augmented data experienced reduced performance. WGAN-GP generated visually more realistic images than DCGAN but also failed to improve classification accuracy.

Although not focused exclusively on maize, Kant (2024) reports the application of MobileNetV2 with transfer learning for the classification of five rice grain varieties (Arborio, Basmati, Ipsala, Jasmine, and Karacadag), achieving an accuracy, precision, recall, and F1-score of 0.99. The inclusion of this study highlights the methodological transferability of lightweight pretrained architectures to surface classification problems involving agricultural grains under resource-constrained scenarios, which is relevant to the maize postharvest context.

Across the included studies, the primary evaluation metric is either the F1-score (Prakasa et al., 2021) or accuracy (Pasaribu et al., 2025; Kant, 2024). Low-complexity pretrained models (MobileNetV2 and EfficientNet-B0) demonstrate high accuracy using the original dataset (97.37%), but their advantage over more complex architectures (ResNet-18) is marginal when the training dataset is of adequate quality.

Results for RQ4: Web platforms and iot for agricultural farm monitoring and management

The seven studies in Axis C show that agricultural farm monitoring and management solutions are predominantly designed as IoT systems integrated with software platform components for data acquisition, transmission, storage, and visualization. Yeong et al. (2024) report a telematics monitoring platform for agricultural machinery, using a software architecture as the integration layer for IoT sensors. Rao et al. (2019) describe an IoT system integrated with UAVs and ZigBee sensor networks for real-time environmental monitoring, evaluated primarily in terms of functionality and scalability. Aliparo et al. (2022) implement an IoT system for monitoring soil nutrients (NPK), using measurement accuracy as the evaluation

criterion. Yadav et al. (2025) report intelligent sensor networks with IoT connectivity, focusing on transmission performance and latency. Bhadra et al. (2025) implement an IoT system with offline monitoring capability for greenhouses, prioritizing continuous data availability.

Regarding web platforms and management components, Hewage et al. (2017) report a Farm Management Information System (FMIS) developed using agile software engineering practices to support operational planning. Archambault (2024) describes co-simulation models and digital twins for controlled agriculture, integrating computational representations of crops to support decision-making.

Critically, none of the seven studies in Axis C reports formal evaluations explicitly based on the ISO 9241 standard. The available evidence is concentrated on technical functionality, sensing performance, and connectivity criteria. This gap between technical functionality and usability evaluation is consistently observed across all studies in this axis.

Discussion

RQ1: Visual diagnosis approaches for leaves and fruits

The RQ1 results confirm that deep learning based on computer vision has become the dominant approach for the automated diagnosis of diseases in crops. The widespread adoption of CNNs and their variants (four of the six studies in Axis A) reflects their proven effectiveness in capturing visual patterns associated with phytosanitary symptoms. However, this dominance poses the risk of methodological blind spots: CNN models are known to be sensitive to domain variations that are not represented in the training dataset.

The emergence of vision transformers and object detectors such as YOLOX is not trivial; rather, it reflects the field's transition toward models with greater global attention capability and spatial localization, which is particularly relevant for agricultural scenarios where multiple diseases coexist or where the boundaries of affected regions are diffuse. Nevertheless, these models require greater computational capacity and larger training datasets, which may limit their deployment in field applications with constrained hardware.

From a technology transfer perspective, the main obstacle identified in the literature is the gap between evaluation environments and real field conditions. The reported accuracy values vary considerably across studies, ranging from 72.31% (Noon et al., 2022, using a proprietary cotton dataset) and 84.29% (Faisal et al., 2023, under real field conditions using the public RoCoLe dataset) to 99.77% (Ouamane et al., 2025, using the large-scale PlantVillage dataset). This heterogeneity reflects the critical influence of the dataset used (size, diversity,

acquisition conditions) on the reported performance, rather than necessarily indicating the superiority of one architectural approach over another. The models are not systematically evaluated against variations in natural lighting, acquisition angles, occlusions caused by adjacent leaves, or images captured using different mobile devices. This external validity gap is the main barrier to the widespread adoption of these technologies by farmers.

RQ2: Data, Architectures, and robustness in visual diagnosis systems

The comparative analysis of the six studies in Axis A reveals a structural dependence on ad hoc datasets in four of the six studies, whose size and diversity are insufficient for training generalizable models. Two studies use public datasets: RoCoLe (Faisal et al., 2023) and PlantVillage (Ouamane et al., 2025), facilitating reproducibility and comparison with other studies. All studies mitigate data scarcity through data augmentation, which is a widely accepted practice but does not replace the diversity of real field conditions. The absence of standardized public repositories for diseases specific to crops in the Andean region (such as coffee leaf rust and cocoa moniliasis) is particularly critical.

The reported accuracy values should be interpreted with methodological caution. Faisal et al. (2023) report an accuracy of 84.29% under real field conditions, whereas Ouamane et al. (2025) report 99.77% using a large-scale controlled dataset, demonstrating that the evaluation context is a determining factor when interpreting reported performance. The adoption of comple-

mentary metrics such as macro F1-score (for imbalanced classes), the ROC curve, the precision-recall curve, and cross-validation protocols using independent datasets emerges as an urgent methodological need to strengthen the external validity of the reported results.

RQ3: Accuracy and efficiency in postharvest grain classification

The results of Axis B present nuanced findings regarding the impact of synthetic data augmentation. Prakasa et al. (2021) confirm that deep learning models achieve F1-scores above 0.90 (best: 0.983 using ResNet-50) for maize seed classification. Kant (2024) demonstrates that MobileNetV2 with transfer learning achieves an accuracy of 0.99 in rice grain classification, confirming its feasibility for postharvest applications under limited-resource conditions. The favorable balance between accuracy and computational efficiency offered by lightweight pretrained models makes them suitable for environments with hardware constraints and for small- and medium-scale applications.

However, the study by Pasaribu et al. (2025) provides a critical finding that contradicts the widespread assumption that synthetic data augmentation improves performance: the use of GAN-generated data (DCGAN and WGAN-GP) reduced classification accuracy compared with the original dataset, with the highest accuracy (97.37%) obtained using the original dataset of 245 images. This result highlights that the quality of synthetic data—measured by the absence of artifacts and by metrics such as Frechet Inception Distance (FID)—is more important than the quantity of generated images. Traditional data augmentation (rotations, flips, brightness adjustments) remains the most reliable strategy for small datasets.

From an applied computing perspective, these findings reinforce the potential of pretrained models to support automated postharvest inspection processes. However, they also highlight the need for more systematic evaluations under real operating conditions and for robustness analyses.

RQ4: Farm Monitoring and Management Through IoT and Web Platforms

The critical analysis of the seven studies in Axis C reveals a systematic disconnect between the technical advancement of IoT systems and their evaluation from the end-user perspective. The reported systems prioritize data acquisition, transmission, and availability, yet none explicitly evaluates ease of use, farmers' cognitive workload, or interface suitability for rural contexts with limited digital literacy. This omission is particularly critical considering that usability is a key determinant of technology adoption in the agricultural sector.

The absence of formal evaluations based on ISO 9241 in the analyzed corpus contrasts with the broad availability of tools such as the System Usability Scale (SUS), the NASA-TLX questionnaire, and heuristic inspection methods, which could easily be integrated into the evaluation protocols of agricultural IoT platforms. The emergence of approaches such as digital twins (Archambault, 2024) represents a promising trend toward simulation and decision support, although these approaches remain at an exploratory stage. Within the conceptual framework of Agriculture 4.0, the convergence of IoT, AI, cloud computing, and digital twins is reshaping agricultural management, and web platforms should be evaluated within this broader sociotechnical ecosystem.

Synthesis of implications and research gaps

Overall, the discussion reveals three critical cross-cutting gaps. First, the external validity gap: deep learning models and IoT systems are evaluated under controlled environments, and their transfer to real agricultural conditions requires more rigorous evaluation protocols and independent field datasets. Second, the standardization gap: the heterogeneity of datasets, metrics, and experimental protocols prevents direct comparison among studies and the identification of optimal approaches; the creation of public benchmarks for regionally relevant agricultural crops is an urgent need. Third, the usability gap: user-centered design and formal usability evaluation (ISO 9241, SUS, Nielsen's heuristics) remain absent from the analyzed IoT solutions, compromising the effective adoption of these technologies by agricultural stakeholders.

Limitations of the study

Despite the methodological rigor applied in this SLR, it is important to acknowledge several limitations that directly affect the interpretation of the results and the strength of the conclusions.

First, the SLR is based exclusively on studies published in English. This restriction introduces a language bias that may be particularly significant in the context of Latin American and Andean agricultural computing, where a growing body of research is published in Spanish and Portuguese in repositories such as Latindex, Redalyc, and CLACSO. The exclusion of this regional and gray literature may bias the findings toward technological approaches developed in agricultural contexts different from those of Latin America, thereby affecting the local relevance of the conclusions regarding model generalization and usability.

Second, the high heterogeneity among the 16 included studies, in terms of datasets, experimental protocols, and evaluation metrics, limited the possibility of performing direct quantitative comparisons or a statistical meta-analysis. Consequently, the identified trends are qualitative in nature and do not allow the establishment of the absolute superiority of one technological approach over another, thereby limiting the certainty of the comparative conclusions.

A third relevant limitation is the dependence on ad hoc datasets in the visual diagnosis and postharvest classification axes. The scarcity of standardized public datasets means that the reported accuracy results cannot be independently replicated or compared, weakening the internal validity of the conclusions regarding the performance of specific models.

Fourth, most of the analyzed studies evaluate their proposed solutions under controlled or semi-controlled environments, with limited validation under real field conditions. Therefore, the conclusions regarding the effectiveness of deep learning models and IoT systems are primarily valid within the experimental setting and cannot be directly extrapolated to real agricultural production scenarios without additional considerations regarding robustness and domain adaptation.

Finally, within the IoT monitoring axis, the limited evaluation of usability and the systematic absence of standards such as ISO 9241 prevent the formulation of robust conclusions regarding the user experience of agricultural web platforms. This constitutes an inherent methodological limitation of the analyzed corpus and does not necessarily reflect the state of the field as a whole, but rather the publication bias toward technical aspects over evaluative ones.

Conclusions

This SLR analyzed and synthesized the scientific evidence from 16 primary studies published between 2017 and 2025, organized into three thematic axes on agricultural computing, leading to the following specific conclusions derived from the comparative analysis.

Regarding RQ1, the six studies in Axis A confirm that CNNs with attention mechanisms constitute the dominant architecture for the visual diagnosis of diseases in agricultural leaves and fruits. The reported accuracy values vary widely across studies, ranging from 72.31% (Noon et al., 2022) and 84.29% (Faisal et al., 2023) under field conditions or with small proprietary datasets, to 99.77% (Ouamane et al., 2025) using the large-scale public PlantVillage dataset. This variability reflects the influence of the dataset rather than the absolute superiority of any particular architecture. Vision transformers (Ouamane et al., 2025) and object detectors such as YOLOX (Noon et al., 2022) emerge as competitive alternatives for localization and classification tasks involving multiple coexisting diseases. However, none of the studies reports systematic robustness evaluations under real field conditions, representing the most critical gap within this axis.

Regarding RQ2, most of the studies in Axis A (four out of six) rely on ad hoc datasets, although two use well-established public datasets (RoCoLe and PlantVillage). The widespread use of data augmentation as a compensatory mechanism is a cross-cutting finding. The reported accuracy values (72% to 99.77%) should be interpreted in light of the evaluation context, as they do not necessarily reflect performance under real operating conditions. The standardization of datasets and the adoption of

cross-validation protocols are concrete recommendations derived from this axis.

With respect to RQ3, the three studies in Axis B provide mixed evidence regarding synthetic data augmentation. Prakasa et al. (2021) confirm that deep learning models achieve F1-scores above 0.90 (best: 0.983) in maize classification. Kant (2024) demonstrates that MobileNetV2 achieves an accuracy of 0.99 in rice grain classification using transfer learning. Pasaribu et al. (2025) reveal that GAN-based data augmentation reduced accuracy compared with the original dataset (97.37%), calling into question the effectiveness of synthetic augmentation without image quality control. Nevertheless, the absence of evaluations of efficiency on edge devices and robustness under variations in image acquisition limits the practical validity of these findings.

Finally, in response to RQ4, the seven studies in Axis C demonstrate that agricultural IoT solutions prioritize technical functionality (data acquisition, transmission, and availability) over user-centered evaluation. The complete absence of evaluations based on ISO 9241 in the analyzed corpus represents a structural gap between technological development and effective adoption by farmers, particularly in contexts with low levels of digital literacy.

Future work

Based on the identified findings and limitations, four priority directions for future work are proposed. The first involves the development and adoption of public, standardized, and geographically diverse datasets for regionally relevant agricultural diseases (coffee leaf rust, cocoa moniliasis, and postharvest maize defects) to enable the evaluation of the generalization and reproducibility of visual diagnosis and classification models. The second involves validating models directly under real field conditions by incorporating environmental variability, visual noise, and operational constraints, using protocols that include robustness metrics, energy efficiency, and inference time on edge devices.

The third direction involves the systematic integration of usability criteria (ISO 9241, SUS, Nielsen's heuristics) from the early stages of designing agricultural web and IoT platforms, incorporating participatory design methodologies involving farmers. Finally, the fourth direction focuses on exploring emerging approaches such as foundation models with fine-tuning for agricultural domains, the integration of digital twins with predictive AI, and the application of federated learning techniques to preserve the privacy of agricultural data in distributed monitoring systems.

Acknowledgments

We extend our sincere appreciation to the Universidad Nacional de Loja (UNL), and particularly to the Computer Science program and the Information Technology and Computing Research Group (GITIC), for their invaluable support and the resources provided for conducting this research. This article is the result of an academic effort developed within the framework of the course "Technological Projects 1," taught during the academic period from September 2025 to February 2026. We are grateful for the guidance and intellectual encouragement received, which have been fundamental to the completion of this work and to our growth as researchers in the field of computer science.

Conflict of interest statement

The authors declare that they have no conflicts of interest.

Funding sources

This work is part of the research project “Development of an Artificial Intelligence Framework to Integrate and Strengthen the Core Functions of the Universidad Nacional de Loja and Its Scalability to the Public Universities of

Ecuador” (Project Code: 32-DI-FEIRNR-2025), fully funded by the Universidad Nacional de Loja.

Declaration on the use of artificial intelligence

The authors declare the use of generative artificial intelligence during the research and writing process. According to the GAIDeT (2025) taxonomy, the following tasks were delegated to generative AI tools under full human supervision:

- Idea generation, definition of the research objective, formulation of research questions and hypotheses, writing of the literature review, research design, data curation and organization, data analysis, text generation, review and editing, text synthesis, formulation of conclusions, translation, and identification of limitations.

The generative AI tools used were ChatGPT 5.2 and NotebookLM.

Full responsibility for the final manuscript rests entirely with the authors.

The generative AI tools are not listed as authors and assume no responsibility for the final results.

Author contributions (CRediT):

Luis Chamba-Eras: Conceptualization; methodology; validation; formal analysis; investigation; resources; data curation; writing – original draft; writing – review and editing; supervision; project administration.

Sergio Jumbo-Gonza: Validation; formal analysis; investigation; resources; data curation; writing – review and editing; project administration.

Walter Yaguana-Alejandro: Validation; formal analysis; investigation; resources; data curation; writing – review and editing; project administration.

Geovanny Romero-Suquilanda: Validation; formal analysis; investigation; resources; data curation; writing – review and editing; project administration.

Gerardo Herrera-Campoverde: Validation; formal analysis; investigation; resources; data curation; writing – review and editing; project administration.

References

- Abinaya, S., Kumar, K. U., & Alphonse, A. S. (2023). Cascading autoencoder with attention residual u-net for multi-class plant leaf disease segmentation and classification. *IEEE Access*, 11, 98153-98170.
<https://doi.org/10.1109/ACCESS.2023.3312718>
- Aliparo, J., Santos, C. D., Sese, C. M., Trinidad, J. ver, Beano, M. G., Capuno, M. E. A., Medina, O., Sigue, A., & Soriano, A. (2022). IoT-based assessment and monitoring of NPK content and fertility condition of soil. En *TENCON 2022 - 2022 IEEE Region 10 Conference (TENCON)* (pp. 1-6).
<https://doi.org/10.1109/TENCON55691.2022.9978040>
- Archambault, P. (2024). Co-simulation and crop representation for digital twins of controlled environment agriculture systems. En *Proceedings of the ACM/IEEE 27th International Conference on Model Driven Engineering Languages and Systems* (pp. 196-199).
<https://doi.org/10.1145/3652620.3676879>
- Bhadra, T., Mujakkir-UI-Islam, & Alam, N. (2025). IoT-based real-time data monitoring of a green house farm with offline monitoring capability. En *2025 4th International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)* (pp. 111-116).
<https://doi.org/10.1109/ICREST63960.2025.10914444>
- Borrromeo, K. O., Bonotan, M. R., Llagas, A. P., Juan, J. M. O., Sanchez, P. D. C., & Berro, N. K. A. (2025). Classification of cacao pods ripeness using convolutional neural networks. *Procedia Computer Science*, 257, 1197-1204.
<https://doi.org/10.1016/j.procs.2025.03.160>
- Brereton, P., Kitchenham, B. A., Budgen, D., Turner, M., & Khalil, M. (2007). Lessons from applying the systematic literature review process within the software engineering domain. *Journal of Systems and Software*, 80(4), 571-583.
<https://doi.org/10.1016/j.jss.2006.07.009>
- Faisal, M., Leu, J.-S., & Darmawan, J. T. (2023). Model Selection of Hybrid Feature Fusion for Coffee Leaf Disease Classification. *IEEE Access*, 11, 62281-62291.
<https://doi.org/10.1109/ACCESS.2023.3286935>
- GAIDeT. (2025). Generative Artificial Intelligence Disclosure Taxonomy (GAIDeT). <https://panbibliotekar.github.io/gaidet-declaration/>

- Garg, D., & Gill, K. S. (2024). *Revolutionizing rice quality control: MobileNetV2 for grain classification. En 2024 2nd International Conference on Advances in Computation, Communication and Information Technology (ICAICCIT)* (pp. 809-812).
<https://doi.org/10.1109/ICAICCIT64383.2024.10912366>
- Hewage, P., Anderson, M., & Fang, H. (2017). An agile farm management information system framework for precision agriculture. *En Proceedings of the 9th International Conference on Information Management and Engineering* (pp. 75-80).
<https://doi.org/10.1145/3149572.3149583>
- Kant, V. (2024). Efficient rice grain classification using MobileNetV2: A deep learning approach. *En 2024 4th International Conference on Technological Advancements in Computational Sciences (ICTACS)* (pp. 989-993).
<https://doi.org/10.1109/ICTACS62700.2024.10840597>
- Kitchenham, B., Pretorius, R., Budgen, D., Pearl Brereton, O., Turner, M., Niazi, M., & Linkman, S. (2010). Systematic literature reviews in software engineering – A tertiary study. *Information and Software Technology*, 52(8), 792-805.
<https://doi.org/10.1016/j.infsof.2010.03.006>
- Konakalla, S., Kunchala, L. V., & Yellampalli, S. S. (2021). Smart Agriculture using IoT & Filtering Technology. *En 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-5).
<https://doi.org/10.1109/ICCCNT51525.2021.9579730>
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174.
<https://doi.org/10.2307/2529310>
- Muthusamy, S., & Ramu, S. P. (2025). A dynamic attention-guided deep learning framework (d-pan) with reduced complexity for fine grained severity-aware classification of micronutrient deficiency and disease detection in banana and coffee leaves. *IEEE Access*, 13, 153474-153497.
<https://doi.org/10.1109/ACCESS.2025.3599359>
- Noon, S. K., Amjad, M., Qureshi, M. A., & Mannan, A. (2022). Handling Severity Levels of Multiple Co-Occurring Cotton Plant Diseases Using Improved YOLOX Model. *IEEE Access*, 10, 134811-134825.
<https://doi.org/10.1109/ACCESS.2022.3232751>

- Nugroho, L. E., Pratama, A. G. H., Mustika, I. W., & Ferdiana, R. (2017). Development of monitoring system for smart farming using Progressive Web App. En *2017 9th International Conference on Information Technology and Electrical Engineering (ICITEE)* (pp. 1-5).
<https://doi.org/10.1109/ICITEED.2017.8250513>
- Ouamane, A., Chouchane, A., Himeur, Y., Miniaoui, S., Atalla, S., Mansoor, W., & Al-Ahmad, H. (2025). Optimized vision transformers for superior plant disease detection. *IEEE Access*, 13, 48552-48570.
<https://doi.org/10.1109/ACCESS.2025.3547416>
- Pasaribu, F. B., Dewi, L. J. E., Aryanto, K. Y. E., & Varnakovida, P. (2025). Effect of synthetic data augmentation on plant classification accuracy using MobileNetV2, EfficientNet-B0, and ResNet-18. En *2025 IEEE 5th International Conference on Software Engineering and Artificial Intelligence (SEAI)* (pp. 1-6).
<https://doi.org/10.1109/SEAI65851.2025.11108883>
- Prakasa, E., Prajitno, D. R., Nur, A., Sulisty, K. A., & Rachmawati, E. (2021). Quality categorisation of corn (*Zea mays*) seed using feature-based classifier and deep learning on digital images. En *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)* (pp. 498-505).
<https://doi.org/10.1109/3ICT53449.2021.9581464>
- Rahman, Z. U., Asaari, M. S. M., Ibrahim, H., Abidin, I. S. Z., & Ishak, M. K. (2024). Generative Adversarial Networks (GANs) for image augmentation in farming: A review. *IEEE Access*, 12, 179912-179943.
<https://doi.org/10.1109/ACCESS.2024.3505989>
- Rao, A., Shao, H., & Yang, X. (2019). The design and implementation of smart agricultural management platform based on UAV and wireless sensor network. En *2019 IEEE 2nd International Conference on Electronics Technology (ICET)* (pp. 248-252).
<https://doi.org/10.1109/ELTECH.2019.8839480>
- Yadav, S., T S, D., & Kokil, P. (2026). An IoT-enabled smart sensor system for real-time monitoring of soil and air conditions with integrated web-based farming guidance. *IEEE Sensors Journal*, 26(1), 1267-1275.
<https://doi.org/10.1109/JSEN.2025.3619663>
- Yeong, D. J., Panduru, K., & Walsh, J. (2024). Smart agriculture: Software platform for telematics monitoring in farm machinery. En *2024 35th Irish Signals and Systems Conference (ISSC)* (pp. 1-6).
<https://doi.org/10.1109/ISSC61953.2024.10602840>
- Yue, X., Qi, K., Na, X., Liu, Y., Yang, F., & Wang, W. (2025). Deep learning for recognition and detection of plant diseases and pests. *Neural Computing and Applications*, 37(17), 11265-11310. h
<https://doi.org/10.1007/s00521-025-11125-5>

ARTÍCULO ILUSTRADO

/ Illustrated article

AGRICULTURE 4.0 INNOVACIÓN AND PATENTS

1 367 international PCT applications (2005–2025)
reveal precision agriculture driven by artificial intelligence, remote sensing, automation, and agricultural decision-making platforms.



INNOVATION

- Accelerated growth since 2013
- The United States, China, and Europe lead technological protection
- From 39 996 initial records, 1 367 international PCT patent applications were identified

WHERE IS PRECISION AGRICULTURE HEADING?

- Artificial intelligence and data analytics
- Sensors and remote sensing
- Automation and precise field application
- Sustainability and climate adaptation


CONCLUSIONS

Agriculture 4.0 continues to expand.

Innovation is converging toward intelligent, integrated systems.

Competitiveness will depend on interoperability and validation under real-world conditions.

Agriculture 4.0 is becoming established as an expanding technological ecosystem, where the integration of data, artificial intelligence, and automation drives innovation and global competitiveness.



INFORMACIÓN PARA AUTORES

/ Information for Authors

INFORMACIÓN PARA AUTORES

Sobre la revista

La Revista Científica CEDIA, especializada en tecnologías de la información y comunicación (TIC), publica investigaciones originales, revisiones sistemáticas y análisis críticos sobre innovación tecnológica, IA, big data, IoT, blockchain, computación en la nube, e-learning, transformación digital en educación, ciberseguridad, gestión de datos e inclusión digital, entre otros. Su objetivo principal es difundir el conocimiento de vanguardia y las aplicaciones prácticas en el campo de las TIC, vinculando avances teóricos con soluciones concretas.

Proceso editorial

Todos los envíos se someten a un riguroso sistema de revisión por pares en modalidad doble ciego.

- Preselección editorial: (alrededor de 3 semanas): verificación de originalidad, adecuación al ámbito TIC y cumplimiento del formato y las normas de la revista.
- Evaluación por pares en modalidad doble ciego: (8 a 10 semanas): cada manuscrito es evaluado por dos especialistas externos. En caso de desacuerdo, se recurre a un tercer revisor.
- Aceptación y correcciones (4 a 6 semanas): si el artículo es aceptado con recomendaciones, los autores disponen de 2 semanas para incorporarlas. El equipo editorial puede solicitar rondas adicionales de corrección si es necesario.
- Notificación: todas las decisiones se comunican por correo electrónico.

Políticas editoriales

Derechos de autor y propiedad intelectual: los autores firman una cesión no exclusiva; conservan los derechos morales de su trabajo y conceden a CEDIA el derecho de primera publicación. Todos los artículos se publican bajo licencia Creative Commons Atribución 4.0 Internacional (CC BY 4.0). No se permite reproducir figuras, tablas o textos protegidos sin permiso escrito. Solo se incluyen como autores quienes hayan contribuido al diseño, redacción, revisión y aprobación final del manuscrito. Deben declararse conflictos de intereses, fuentes de financiación y uso de IA. En investigaciones con humanos, se exige consentimiento informado por escrito y la declaración ética que corresponda.

Políticas antiplagio: la revista utiliza StrikePlagiarism para verificar la originalidad de los manuscritos. Se rechazarán envíos con similitudes superiores al 15 % (excluyendo citas y referencias). Las prácticas identificadas como plagio o autoplagio conllevan la desautorización del manuscrito e inhabilitación para futuras publicaciones.

Acceso abierto y reutilización de contenidos: acceso abierto sin costos APC. Todo el contenido bajo licencia CC BY 4.0. Se permite leer, descargar, copiar, distribuir, imprimir, buscar, compartir y adaptar el material citando la fuente. La difusión del contenido se realiza únicamente a través de la versión final oficial con DOI. No se permite depositar versiones no oficiales fuera del repositorio de CEDIA.

Depósito de datos de investigación: los datos de investigación deben estar disponibles en repositorios FAIR (Zenodo, Figshare, IEEE Dataport, Mendeley Data) con licencia CC BY-NC-SA 4.0. En el manuscrito se debe incluir un apartado “Disponibilidad de los datos depositados” con nombre del repositorio, URL, DOI y descripción de los datos. Los autores deben conservar los datos primarios durante al menos 3 años tras la publicación.

Desautorización de artículos: la revista puede emitir correcciones, expresiones de preocupación o retractaciones en casos de mala praxis (plagio, datos falsificados, infracciones de derechos de autor, conflictos no declarados, errores graves). El proceso sigue las guías de COPE. Los artículos retractados se conservan en el archivo digital con un sello de “retractado”.

Preservación de archivos digitales: los contenidos se preservan mediante DOI (Crossref), formatos PDF/A, HTML y XML-JATS, almacenamiento descentralizado en repositorios de CEDIA y metadatos estandarizados (Dublin Core, OAI-PMH).

Uso de inteligencia artificial: no se aceptan manuscritos generados totalmente por IA. Se admite el uso de IA como herramienta de apoyo (revisión de estilo, corrección, sugerencias, análisis preliminar) bajo supervisión humana. El uso debe declararse en un apartado específico con nombre y versión de la herramienta, secciones del manuscrito donde se aplicó y propósito. Queda prohibida la generación sustancial de textos, la creación o alteración de datos con IA y el tratamiento de datos sensibles en plataformas sin seguridad. Si se usa IA con relevancia metodológica, debe describirse en la sección “Métodos”. La omisión de esta declaración se considera falta editorial.

Exención de responsabilidad: los autores son los únicos responsables del contenido del manuscrito, incluida la veracidad de los datos, la originalidad, el cumplimiento ético y la obtención de permisos para materiales de terceros. Las opiniones expresadas no reflejan necesariamente la postura de CEDIA ni del equipo editorial. Los autores se comprometen a indemnizar a CEDIA y a la revista por cualquier reclamación derivada de la violación de estas garantías.

Envío y contacto

Los manuscritos se reciben a través de la plataforma OJS.

Conoce a profundidad nuestras políticas y normas editoriales y revisa todos los requisitos de envío en el sitio web de la revista: <https://cientifica.cedia.edu.ec/>

Para más información, contáctanos: cientifica@cedia.org.ec

INFORMATION FOR AUTHORS

About the journal

Revista Científica CEDIA, specializing in information and communication technologies (ICT), publishes original research articles, systematic reviews, and critical analyses on technological innovation, artificial intelligence, big data, the Internet of Things (IoT), blockchain, cloud computing, e-learning, digital transformation in education, cybersecurity, data management, digital inclusion, and related topics. Its primary objective is to disseminate cutting-edge knowledge and practical applications in the field of ICT, bridging theoretical advances with concrete solutions.

Editorial process

All submissions undergo a rigorous double-blind peer review process.

- Editorial screening (approximately 3 weeks): verification of originality, relevance to the ICT scope, and compliance with the journal's formatting requirements and submission guidelines.
- Double-blind peer review (8 to 10 weeks): each manuscript is evaluated by two external specialists. In the event of conflicting recommendations, a third reviewer is invited.
- Acceptance and revisions (4 to 6 weeks): if a manuscript is accepted subject to revisions, authors are given 2 weeks to address the reviewers' comments. The editorial team may request additional rounds of revision if necessary.
- Notification: all editorial decisions are communicated via email.

Editorial policies

Copyright and intellectual property: authors sign a non-exclusive copyright transfer agreement, retain the moral rights to their work, and grant CEDIA the right of first publication. All articles are published under the Creative Commons Attribution 4.0 International (CC BY 4.0) license. The reproduction of copyrighted figures, tables, or text without written permission is prohibited. Only individuals who have contributed to the design, writing, revision, and final approval of the manuscript may be listed as authors. Conflicts of interest, funding sources, and the use of artificial intelligence must be disclosed. Research involving human participants requires written informed consent and the corresponding ethics statement.

Anti-plagiarism policy: the journal uses StrikePlagiarism to verify the originality of submitted manuscripts. Submissions with similarity scores exceeding 15% (excluding quotations and references) will be rejected. Identified cases of plagiarism or self-plagiarism will result in the rejection of the manuscript and disqualification from future submissions.

Open access and content reuse: the journal provides open access with no article processing charges (APCs). All content is published under the CC BY 4.0 license. Users are permitted to read, download, copy, distribute, print, search, share, and adapt the material, provided the original source is properly cited. Content may only be disseminated through the official final version assigned a DOI. Depositing unofficial versions outside the CEDIA repository is not permitted.

Research data deposition: research data must be made available in FAIR-compliant repositories (Zenodo, Figshare, IEEE DataPort, or Mendeley Data) under the CC BY-NC-SA 4.0 license. Manuscripts must include a section entitled “Availability of Deposited Data,” specifying the repository name, URL, DOI, and a description of the deposited dataset. Authors are required to retain the primary research data for at least 3 years after publication.

Article retraction: the journal may issue corrections, expressions of concern, or retractions in cases of research misconduct (including plagiarism, data fabrication, copyright infringement, undisclosed conflicts of interest, or significant errors). The process follows the guidelines established by COPE. Retracted articles remain available in the digital archive with a “Retracted” watermark.

Digital preservation: published content is preserved through DOI registration (Crossref), PDF/A, HTML, and XML-JATS formats, decentralized storage in CEDIA repositories, and standardized metadata (Dublin Core and OAI-PMH).

Use of artificial intelligence: manuscripts generated entirely by artificial intelligence are not accepted. The use of AI as a support tool (for language editing, proofreading, suggestions, or preliminary analysis) is permitted under human supervision. Its use must be disclosed in a dedicated section, specifying the name and version of the tool, the manuscript sections where it was used, and its purpose. The substantial generation of text, the creation or manipulation of data using AI, and the processing of sensitive data on unsecured AI platforms are prohibited. If AI plays a methodologically relevant role, its use must be described in the “Methods” section. Failure to disclose the use of AI constitutes editorial misconduct.

Disclaimer: authors are solely responsible for the content of their manuscripts, including the accuracy of the data, originality, ethical compliance, and obtaining permission to use third-party materials. The opinions expressed do not necessarily reflect the views of CEDIA or the editorial team. Authors agree to indemnify CEDIA and the journal against any claims arising from violations of these warranties.

Submission and contact

Manuscripts must be submitted through the OJS platform.

Learn more about our editorial policies and guidelines and review all submission requirements on the journal's website: <https://cientifica.cedia.edu.ec/>

For further information, please contact us at: cientifica@cedia.org.ec

CALL FOR PAPERS

CIENTÍFICA

Revista de Investigación en Tecnologías
de Información y Comunicación Aplicadas

cedia

**Sabemos que tu
investigación busca
inspirar, transformar
y derribar barreras.**

Queremos
acompañarte en
ese **camino.**



*¡Publiquemos juntos
tu artículo científico!*

Temática

**Tecnologías de
la información y
la comunicación
en la industria
de las refinerías.**

CONVOCATORIA
ABIERTA
Segundo Número

Primera llamada:
hasta el 31 de agosto de 2026.

@cediaeditorial



 cientifica.cedia.edu.ec

CALL FOR PAPERS

Comparte tu investigación con el mundo y forma parte de una comunidad que impulsa la innovación y el conocimiento desde Ecuador hacia el mundo.

El segundo número de la Revista Científica CEDIA explorará la ciencia e innovaciones en el impacto transversal de las Tecnologías de la Información y Comunicación (TIC) en la industria de las refinerías.

Postula tus artículos científicos, revisiones, estudios de caso e investigaciones orientadas al estudio, diseño, optimización e integración de sistemas de refinación capaces de transformar materias primas fósiles, biológicas o renovables en combustibles, energía, productos químicos y materiales de valor agregado.

CONVOCATORIA ABIERTA

- Primera llamada: hasta el 31 de agosto de 2026.
- Segunda llamada y cierre de convocatoria: hasta el 15 de septiembre de 2026.

ÁREAS TEMÁTICAS

- *PETROREFINERÍAS Y VALORIZACIÓN DE RECURSOS FÓSILES*
- *BIOREFINERÍAS Y APROVECHAMIENTO INTEGRAL DE BIOMASA*
- *ELECTROREFINERÍAS Y CONVERSIÓN ELECTROCATALÍTICA*

CALL FOR PAPERS

Share your research with the world and become part of a community that advances innovation and knowledge from Ecuador to the world.

The second issue of Revista Científica CEDIA will explore scientific advances and innovations related to the cross-cutting impact of information and communication technology (ICT) on the refinery industry.

Submit your original research articles, review papers, case studies, and manuscripts focused on the study, design, optimization, and integration of refining systems capable of transforming fossil, biological, or renewable feedstocks into fuels, energy, chemicals, and value-added materials.

OPEN CALL

- First submission deadline: until august 31, 2026.
- Second submission deadline and final call closing: until september 15, 2026.

THEMATIC AREAS

- *PETROLEUM REFINERIES AND FOSSIL RESOURCE VALORIZATION*
- *BIOREFINERIES AND INTEGRATED BIOMASS UTILIZATION*
- *ELECTROREFINERIES AND ELECTROCATALYTIC CONVERSION*



cientifica.cedia.edu.ec

REDES DE LA EDITORIAL



@cediaeditorial



@CEDIAec



@CEDIAec

CIENTÍFICA

Revista de Investigación en Tecnologías
de Información y Comunicación Aplicadas

cedia