

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.

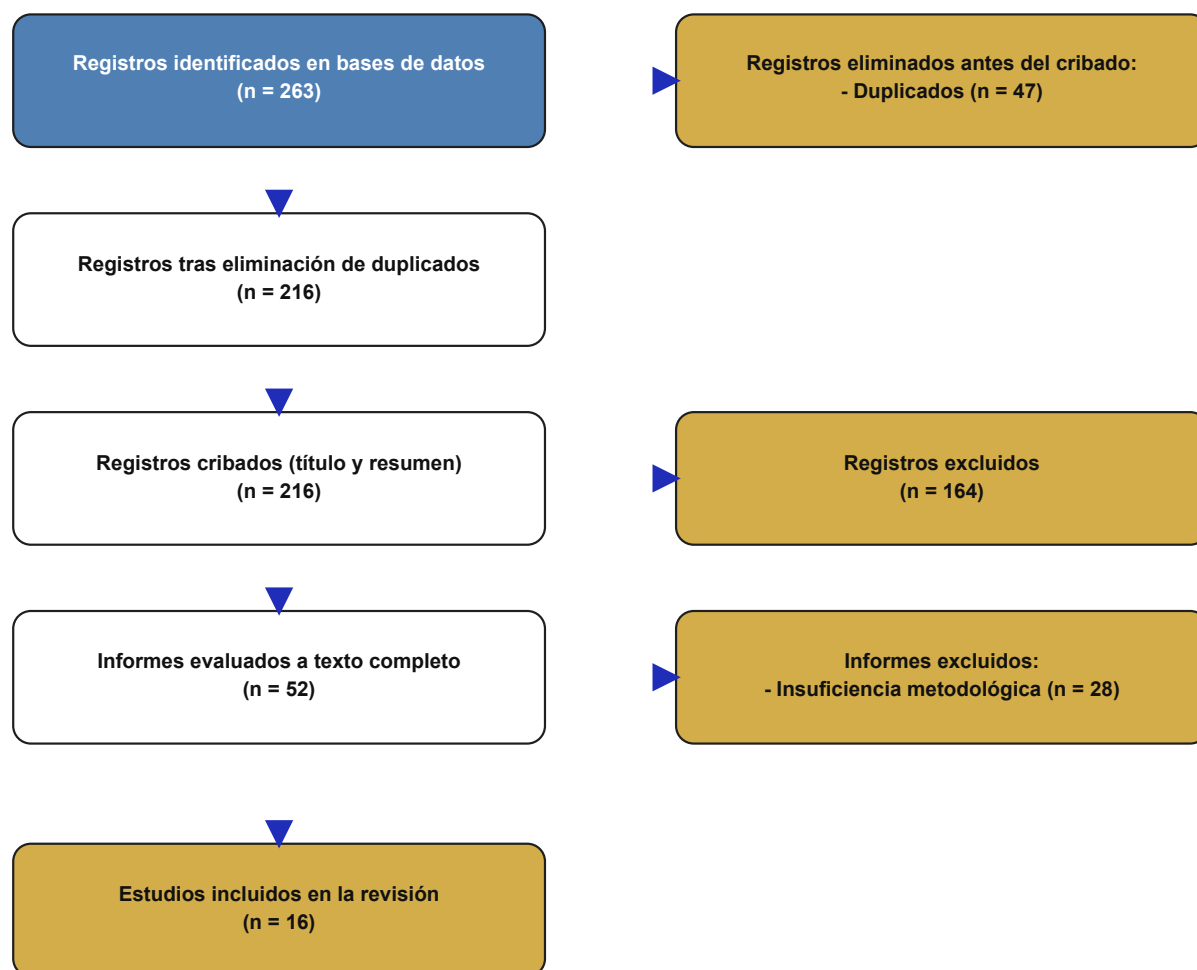


Figura 1

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* (wmlou) 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 (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>