



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA

**Food**UPV  
INSTITUTO DE INGENIERIA DE ALIMENTOS

# UNIVERSITAT POLITÈCNICA DE VALÈNCIA

## Instituto Universitario de Investigación de Ingeniería de Alimentos (FoodUPV)

Aplicaciones de la inteligencia artificial en poscosecha de  
productos hortofrutícolas: contribución al control de calidad  
y seguridad alimentaria

Trabajo Fin de Máster

Máster Universitario en Gestión de la Seguridad y Calidad  
Alimentaria

AUTOR/A: Mallebrera Albert, Francisco

Tutor/a: Fuentes López, Ana

Cotutor/a: Martín Esparza, María Eugenia

Cotutor/a externo: Conesa Domínguez, Claudia

CURSO ACADÉMICO: 2024/2025

# APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN POSCOSECHA DE PRODUCTOS HORTOFRUTÍCOLAS: CONTRIBUCIÓN AL CONTROL DE CALIDAD Y SEGURIDAD ALIMENTARIA

Francisco Mallebrera Albert<sup>1</sup>, María Eugenia Martín Esparza<sup>2</sup>, Fuentes López, Ana<sup>2</sup>

## RESUMEN

La etapa poscosecha representa una fase crítica en la cadena agroalimentaria, con impacto en calidad, seguridad y sostenibilidad. En este contexto, la inteligencia artificial (IA) se presenta como una herramienta clave para optimizar procesos y apoyar la toma de decisiones en tiempo real. Este trabajo tiene como objetivo analizar de forma sistemática las aplicaciones de la IA en poscosecha, con especial atención a su contribución al control de calidad y la seguridad alimentaria. Para ello, se realizó una revisión bibliográfica siguiendo la metodología PRISMA. Tras el proceso de búsqueda y aplicar los criterios de inclusión y exclusión establecidos, se seleccionaron 25 artículos. Los estudios analizados evidenciaron que la visión artificial es la tecnología más consolidada aplicada a la clasificación automática y la detección temprana de defectos, mientras que los sensores inteligentes, modelos predictivos e internet de las cosas (IoT) refuerzan la evaluación de parámetros internos, la estimación de vida útil y la trazabilidad. En conclusión, los hallazgos muestran que la IA tiene capacidad real para mejorar la eficiencia, reducir pérdidas y reforzar la seguridad en la etapa poscosecha. Su implementación a lo largo de la cadena alimentaria exige superar limitaciones como falta de datos, validación en condiciones reales y estandarización de protocolos.

**PALABRAS CLAVE:** Inteligencia artificial, poscosecha, control de calidad, sensores inteligentes, visión artificial, modelos predictivos.

## ABSTRACT

The postharvest stage represents a critical phase in the agri-food chain, with implications for quality, safety, and sustainability. In this context, artificial intelligence (AI) has emerged as a key tool to optimize processes and support real-time decision-making. This study aims to systematically analyse the

---

<sup>1</sup> SPE3, S.L. Dr. Manuel Candela 26, 11<sup>a</sup>, 46021 Valencia, Spain; <sup>2</sup> Instituto Universitario de Ingeniería de Alimentos-FoodUPV, Universitat Politècnica de València. Camino de Vera s/n, 46022, Valencia, Spain

applications of AI in postharvest, with particular emphasis on its contribution to quality control and food safety. A bibliographic review was conducted following the PRISMA methodology, resulting in the selection of 25 articles after applying inclusion and exclusion criteria. The reviewed studies indicate that computer vision is the most established technology, primarily applied to automatic classification and early defect detection. In parallel, smart sensors, predictive models, and the Internet of Things (IoT) enhance the evaluation of internal parameters, shelf-life estimation, and traceability. Overall, the findings demonstrate that AI holds significant potential to improve efficiency, minimize losses, and strengthen food safety in the postharvest stage. However, its implementation throughout the agri-food chain requires overcoming limitations such as the lack of data, validation under real-life conditions, and standardization of protocols.

**KEY WORDS:** Artificial intelligence, postharvest, quality control, smart sensors, computer vision, predictive models.

## RESUM

L'etapa de postcollita representa una fase crítica en la cadena agroalimentària, amb impacte en la qualitat, la seguretat i la sostenibilitat. En este context, la intel·ligència artificial (IA) es presenta com una eina clau per a optimitzar processos i donar suport a la presa de decisions en temps real. Este treball té com a objectiu analitzar de manera sistemàtica les aplicacions de la IA en postcollita, amb especial atenció a la seua contribució al control de qualitat i a la seguretat alimentària. Per a això, es va realitzar una revisió bibliogràfica seguint la metodologia PRISMA. Després del procés de cerca i d'aplicar els criteris d'inclusió i exclusió establits, es van seleccionar 25 articles. Els estudis analitzats van evidenciar que la visió artificial és la tecnologia més consolidada, aplicada principalment a la classificació automàtica i a la detecció primerenca de defectes, mentres que els sensors intel·ligents, els models predictius i l'Internet de les Coses (IoT) reforcen l'avaluació de paràmetres interns, l'estimació de la vida útil i la traçabilitat. En conclusió, els resultats mostren que la IA té una capacitat real per a millorar l'eficiència, reduir pèrdues i reforçar la seguretat en l'etapa de postcollita. La seua implementació al llarg de la cadena alimentària exigix superar limitacions com falta de dades, validació en condicions reals i estandardització de protocols.

**PARAULES CLAU:** Intel·ligència artificial, postcollita, control de qualitat, sensors intel·ligents, visió artificial, models predictius.

## 1. INTRODUCCIÓN

La etapa poscosecha constituye una de las fases más críticas dentro de la cadena agroalimentaria, especialmente en el caso de frutas y hortalizas frescas, debido a que se trata de alimentos altamente perecederos y muy sensibles a factores ambientales. A lo largo de este periodo, los productos pueden sufrir deterioro por procesos fisiológicos, microbiológicos o físicos, afectando no solo su calidad comercial, sino también su seguridad alimentaria y su aceptación por parte del consumidor. Se estima que una parte significativa de las pérdidas de alimentos a nivel mundial ocurre en esta fase, lo que convierte a la gestión poscosecha en un área clave para la mejora de la sostenibilidad y la eficiencia del sistema agroalimentario (Kanjilal et al., 2025).

En este escenario, la optimización de los procesos poscosecha se ha convertido en una prioridad tanto para la industria agroalimentaria como para los organismos reguladores y los investigadores. La mejora de la eficiencia, la sostenibilidad y la seguridad de los productos frescos implica una combinación de tecnologías, estrategias logísticas y sistemas de control integrados. En este contexto, la digitalización del sector hortofrutícola ha comenzado a generar transformaciones sustanciales, permitiendo una trazabilidad más precisa, una monitorización en tiempo real de las condiciones de almacenamiento y transporte, y una toma de decisiones más informada en cada punto de la cadena (Wang et al., 2024; Hassoun et al., 2023).

Entre las tecnologías emergentes, la inteligencia artificial (IA) está desempeñando un papel destacado al permitir el desarrollo de sistemas avanzados capaces de evaluar en tiempo real parámetros clave relacionados con la calidad, la vida útil y la seguridad del producto. La IA facilita el procesamiento de grandes volúmenes de datos complejos, la identificación de patrones no lineales y la predicción del comportamiento futuro del producto ante distintas condiciones de conservación (Ahmed et al., 2024; Yang et al., 2024). En este sentido, la IA se posiciona como una herramienta para optimizar la conservación de frutas y hortalizas mediante estrategias predictivas basadas en datos multifuente, reduciendo así las pérdidas poscosecha (Cheng et al., 2025; Zou et al., 2025). Además, la IA permite automatizar procesos tradicionalmente manuales y subjetivos, como la clasificación por calibre o madurez, la detección de daños externos o internos, o la estimación del tiempo restante de conservación (Arango et al., 2021; El-Mesery et al., 2025).

Entre las aplicaciones más relevantes aplicadas al sector hortofrutícola se encuentran los sistemas de visión artificial asistidos por redes neuronales profundas empleados para la clasificación automática de frutas, el análisis hiperespectral para la detección no destructiva de madurez o defectos internos, y el uso de sensores inteligentes como narices electrónicas o sensores

dieléctricos conectados a modelos de Machine Learning (ML) para estimar parámetros como la firmeza, el contenido de agua o el riesgo de podredumbre (Barbosa Júnior et al., 2025; Wieme et al., 2022; Kiani et al., 2023). En productos como el ajo, se han utilizado modelos de regresión y redes neuronales para predecir parámetros de calidad, como la vida útil en función de las condiciones de almacenamiento y del tipo de envasado (El-Mesery et al., 2025).

Otro campo en expansión es la predicción de la evolución del producto a lo largo del tiempo. Algoritmos como redes neuronales artificiales, modelos de regresión o técnicas de aprendizaje profundo se han empleado para predecir la pérdida de peso del producto durante el almacenamiento, los cambios de textura o la reducción del valor nutricional en función de las condiciones de conservación y del historial del lote (Cheng et al., 2025; Zou et al., 2025). Este tipo de modelos permiten una gestión proactiva basada en datos y constituyen una herramienta clave para reducir las mermas del sector.

Además, se han desarrollado soluciones de IA capaces de caracterizar el estado fisiológico del producto a través del análisis de señales visuales o espectrales, lo que permite evaluar el grado de madurez, senescencia o deterioro de forma objetiva. Esta aproximación puede aplicarse tanto antes del envasado como durante la logística, permitiendo una asignación más precisa de los lotes en función de su estado real (Wieme et al., 2022; Yang et al., 2024).

En el ámbito de la seguridad alimentaria, tecnologías como los gemelos digitales, la trazabilidad inteligente o la fusión de sensores en tiempo real permiten detectar desviaciones críticas, anticipar la degradación del producto y garantizar el cumplimiento de los estándares durante el transporte y almacenamiento (Hassoun et al., 2023; Zou et al., 2025). Estas plataformas integran datos ambientales, sensoriales e históricos para generar alertas tempranas y facilitar decisiones automatizadas. La IA también introduce mejoras en la trazabilidad, la vigilancia de riesgos y la detección de contaminaciones, incluso en tiempo real (Sim et al., 2023).

A pesar de estos avances, la implementación de estas tecnologías aún se enfrenta a retos importantes, como la escasez de bases de datos amplias y representativas, la heterogeneidad y variabilidad natural de los productos hortofrutícolas, la falta de estandarización en los criterios de calidad y la dificultad de acceso tecnológico por parte de pequeños productores. Además, cuestiones como la interoperabilidad entre plataformas, los problemas de seguridad de los datos y la necesidad de validación de los modelos en condiciones reales de operación siguen siendo puntos críticos. A pesar de ello, la literatura científica actual evidencia un creciente número de soluciones validadas tanto en condiciones experimentales como industriales. La integración de IA con sistemas ciberfísicos, la sensorización distribuida y la conectividad mediante Internet de

las Cosas (IoT) están sentando las bases para un modelo de gestión poscosecha más automatizado, objetivo y sostenible, alineado con los Objetivos de Desarrollo Sostenible (ODS) relacionados con la producción responsable, la innovación tecnológica y la seguridad alimentaria (Zou et al., 2025; Hassoun et al., 2023).

El presente trabajo tiene como objetivo analizar el estado actual de las aplicaciones de la IA en el ámbito poscosecha de productos hortofrutícolas, con especial énfasis en su contribución al control de calidad y la seguridad alimentaria. Para ello, se ha realizado una revisión bibliográfica sistemática basada exclusivamente en literatura científica reciente y seleccionada por su aplicabilidad tecnológica. El análisis se estructura en función de los enfoques tecnológicos más relevantes, sus ventajas, limitaciones y potencial de implementación en condiciones reales.

Este trabajo presenta una vinculación directa con el Objetivos de Desarrollo Sostenible (ODS), en concreto contribuye al ODS 9 (Industria, Innovación e Infraestructura) ya que se centra en el estudio de las aplicaciones de la IA para el impulso a la innovación tecnológica en la industria agroalimentaria y al ODS 12 (Producción y Consumo Responsables) por la contribución de la IA para la promoción de modelos productivos responsables y sostenibles (**ANEXO I**).

## **2. MATERIALES Y MÉTODOS**

### **2.1. Diseño del estudio**

La presente investigación se ha desarrollado a partir de una revisión bibliográfica sistemática siguiendo la metodología PRISMA orientada a conocer el estado actual del conocimiento sobre la aplicación de la inteligencia artificial en la etapa poscosecha, con especial atención a su impacto en el control de calidad y la seguridad alimentaria. Para ello, se diseñó una estrategia de búsqueda que combinó tanto enfoques generales como estudios centrados en tecnologías concretas, como la visión artificial, los sensores inteligentes, los modelos predictivos y los sistemas de monitorización en tiempo real. Esta aproximación permitió abarcar desde una visión global del campo hasta casos aplicados de interés tecnológico.

### **2.2. Bases de datos consultadas**

Para la recopilación de información se emplearon las bases de datos científicas *ScienceDirect*, *PubMed* y *Scopus*, consideradas referentes en el ámbito académico y técnico. De manera complementaria, se utilizó *Google Scholar* para ampliar la cobertura y recuperar estudios relevantes no indexados en las plataformas anteriores. La selección final se basó exclusivamente en artículos revisados por pares publicados en los últimos cinco años (2020–2025).

### 2.3. Estrategia de búsqueda

Las búsquedas se realizaron en inglés, combinando términos clave como: “*artificial intelligence*”, “*postharvest*”, “*quality control*”, “*food safety*”, “*computer vision*”, “*smart sensors*” y “*predictive models*”.

Los operadores booleanos utilizados fueron AND y OR, lo que permitió ampliar y refinar las combinaciones de búsqueda. A modo de ejemplo, se utilizaron las siguientes expresiones:

- "artificial intelligence" AND "postharvest" AND "quality control"
- "artificial intelligence" AND "postharvest" AND "food safety"
- "artificial intelligence" AND "postharvest" AND "computer vision"
- "artificial intelligence" AND "postharvest" AND "smart sensors"
- "artificial intelligence" AND "postharvest" AND "predictive models"

Esta combinación de términos permitió recuperar tanto estudios de carácter general como investigaciones enfocadas en soluciones tecnológicas específicas, lo que facilitó un análisis completo y estructurado de las principales aplicaciones de la inteligencia artificial en procesos poscosecha.

Adicionalmente, para completar el número de artículos necesarios para el análisis, se realizaron búsquedas complementarias en Google Scholar empleando las siguientes cadenas de búsqueda:

- ("smart sensors" OR "electronic nose" OR "gas sensors" OR "temperature sensors") AND ("postharvest" OR "fresh produce") AND ("artificial intelligence" OR "machine learning")
- ("smart packaging" OR "intelligent packaging") AND ("postharvest" OR "fresh produce") AND ("artificial intelligence" OR "machine learning")

### 2.4. Criterios de inclusión, exclusión y selección final de artículos

Durante el primer cribado de los artículos recuperados en la búsqueda bibliográfica, se emplearon herramientas de inteligencia artificial como SciSpace y ChatGPT. Para ello, se cargaron los listados de publicaciones junto con sus resúmenes, lo que permitió realizar una preselección automática conforme a los criterios de inclusión y exclusión definidos.

Los criterios de inclusión y exclusión aplicados durante el proceso de selección bibliográfica se muestran en la **TABLA 1**. A continuación, se desarrollan los aspectos considerados en cada uno de ellos:

- Artículos científicos revisados por pares, priorizando investigaciones originales.
- Trabajos centrados en productos hortofrutícolas tras su recolección.
- Estudios con aplicación directa o experimental en procesos poscosecha.

- Documentos técnicos relevantes para la evaluación de calidad y la gestión de riesgos.

Respecto a los criterios de exclusión, se descartaron todos los estudios enfocados en la etapa de producción en campo (fase en árbol o plantación), así como aquellos centrados exclusivamente en aspectos agronómicos o genéticos sin relación con la poscosecha. También se eliminaron artículos repetidos, poco relevantes o con un enfoque exclusivamente teórico sin aplicaciones reales o tecnológicas.

**TABLA 1.** Criterios de inclusión y exclusión empleados en la revisión bibliográfica

CRITERIOS	INCLUSIÓN	EXCLUSIÓN
<b>Período</b>	Artículos publicados entre 2020 y 2025	Publicaciones anteriores a 2020
<b>Tipo de documento</b>	Artículos científicos revisados por pares	Artículos de revisión, tesis, informes no revisados, resúmenes de conferencias sin datos completos
<b>Idioma</b>	Inglés (preferentemente)	Otros idiomas no comprensibles o sin traducción disponible
<b>Título y resumen</b>	Referencia a IA aplicada a poscosecha, calidad o seguridad alimentaria	IA solo mencionada sin aplicación, estudios centrados en precosecha o sin enfoque tecnológico
<b>Texto completo</b>	Accesible, con datos y metodología clara	No disponible en acceso completo, insuficiente calidad o sin aplicación práctica

### 3. RESULTADOS Y DISCUSIÓN

#### 3.1. Bases de datos consultadas

Tal y como se ha indicado anteriormente, la selección de artículos para este trabajo se realizó siguiendo la metodología PRISMA, considerando 3 bases de datos consultadas y *Google Scholar*, de manera complementaria para ampliar la cobertura y recuperar estudios relevantes no indexados en las plataformas anteriores.

Durante el proceso de búsqueda se identificaron 935 publicaciones a través de las bases de datos *ScienceDirect* (n = 825), *PubMed* (n = 76) y *Scopus* (n = 36), combinando distintas estrategias de búsqueda basadas en palabras clave relacionadas con inteligencia artificial, poscosecha, calidad y seguridad alimentaria.

En una primera fase, se aplicó un filtro temporal para garantizar la actualidad de los trabajos, excluyéndose 108 artículos publicados antes de 2020, conforme al criterio metodológico previamente establecido. Posteriormente, se eliminaron 338 registros duplicados que coincidían entre plataformas o aparecían varias veces en distintas combinaciones de búsqueda.

A continuación, se procedió al cribado de los 489 artículos únicos restantes, mediante una revisión sistemática de sus títulos y resúmenes. Esta etapa combinó un prefiltrado automático inicial, realizado con la herramienta *SciSpace* y *ChatGPT*, con una revisión manual posterior. Durante este proceso se priorizaron aquellos estudios que mostraban una aplicación tecnológica real de la inteligencia artificial, excluyéndose los trabajos que:

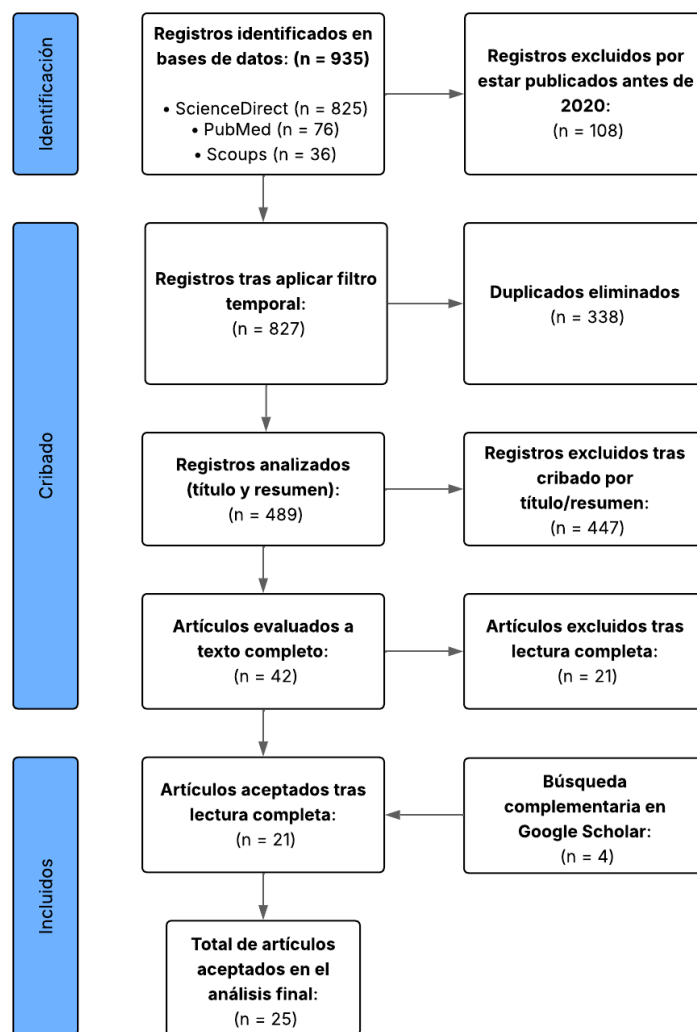
- Estaban centrados exclusivamente en la etapa de producción en campo.
- Abordaban productos no hortofrutícolas.
- Utilizaban el término “IA” de forma genérica o sin describir su implementación concreta.
- Carecían de vinculación directa con procesos de control de calidad o seguridad alimentaria en poscosecha.

Este cribado permitió reducir la muestra a 42 artículos potencialmente válidos, los cuales fueron evaluados a texto completo. De ellos, se excluyeron 21 artículos adicionales por diversos motivos, entre ellos: falta de validación experimental, escasa aplicabilidad tecnológica, ausencia de datos propios o una orientación excesivamente teórica sin casos reales.

Posteriormente, se realizó una búsqueda complementaria en *Google Scholar*, que permitió incorporar 4 artículos adicionales que cumplían los criterios de inclusión.

Finalmente, se incluyeron 25 artículos que cumplían de forma estricta con todos los criterios de inclusión establecidos. Aunque el criterio general fue incluir únicamente estudios originales con datos experimentales propios, de manera excepcional se aceptaron dos artículos de revisión por su alto rigor científico y su relevancia para contextualizar tendencias y tecnologías clave en el ámbito de estudio. Su incorporación permite aportar una visión global complementaria a la obtenida a partir de las investigaciones originales. Estos estudios constituyen el cuerpo principal de evidencia para el análisis cualitativo del capítulo de resultados y fueron clasificados por áreas tecnológicas de aplicación (visión artificial, sensores inteligentes, modelos predictivos, trazabilidad y sistemas integrados con IoT).

En la FIGURA 1 se muestra el diagrama de flujo donde se muestran las fases principales de la revisión sistemática realizada. Este esquema recoge los criterios de inclusión y exclusión definidos previamente (**TABLA 1**) y el cribado sistemático conforme al diagrama PRISMA. Los estudios seleccionados abordan distintos enfoques de aplicación de la inteligencia artificial en procesos poscosecha de productos hortofrutícolas, con una amplia variedad de objetivos, tecnologías empleadas y niveles de desarrollo.



**FIGURA 1.** Diagrama de flujo del proceso de selección bibliográfica siguiendo la metodología PRISMA.

La información relevante de cada uno de estos artículos se detalla en la TABLA II.1 (ANEXO II). La revisión cualitativa de esta información permitió identificar patrones comunes, áreas tecnológicas recurrentes y enfoques metodológicos representativos. A continuación, se muestra la información más relevante clasificada en función de las principales tecnologías de IA identificadas, con el fin de facilitar su comprensión y destacar las contribuciones más significativas en cada ámbito. Cada subapartado recoge ejemplos concretos de los artículos analizados, incluyendo datos técnicos, resultados experimentales y enfoques tecnológicos aplicados. Esta organización temática permite mostrar de forma estructurada el estado actual de la inteligencia artificial aplicada a la poscosecha, así como valorar sus beneficios potenciales y principales barreras de implementación.

### 3.2. Visión artificial aplicada al control de calidad

La visión artificial se ha consolidado como una herramienta clave para el control de calidad en poscosecha, ofreciendo inspecciones más objetivas, rápidas y reproducibles que la evaluación humana. Mediante el uso de cámaras RGB, multiespectrales, hiperespectrales o técnicas avanzadas como rayos X en modo *dark-field*, combinadas con algoritmos de aprendizaje automático y profundo, es posible evaluar atributos como color, tamaño, forma, firmeza o la presencia de defectos superficiales e internos de manera no destructiva. Estas tecnologías permiten procesar grandes volúmenes de producto en tiempo real, mejorando la eficiencia operativa y asegurando una calidad uniforme en los lotes destinados al mercado. En este contexto, Arango et al. (2021) demostraron la eficacia de integrar imágenes RGB e infrarrojo cercano para la detección de magulladuras en manzanas, alcanzando precisiones superiores al 97 % en la clasificación de frutos dañados. De forma similar, Gulzar y Ünal (2025) aplicaron redes neuronales convolucionales a imágenes NIR para la detección temprana de hematomas en ciruelas, logrando tasas de acierto cercanas al 97 % incluso a las pocas horas de producirse el daño. Estos resultados confirman que el uso de longitudes de onda no visibles permite identificar defectos antes de que sean perceptibles al ojo humano, facilitando la retirada temprana del producto afectado y reduciendo pérdidas.

En la identificación de defectos internos, He et al. (2024) evaluaron el uso de imágenes de rayos X en modo *dark-field* junto con modelos de aprendizaje automático para la detección de pardeamiento interno en manzanas Braeburn. Esta técnica superó la capacidad diagnóstica de la radiografía convencional, ofreciendo una mayor sensibilidad para detectar alteraciones estructurales tempranas y mostrando potencial para su integración en líneas de procesamiento industrial.

El potencial de la visión artificial se extiende también a la predicción de parámetros de calidad y vida útil. Cheng et al. (2025) desarrollaron modelos basados en CNN a partir de imágenes en color para estimar la pérdida de peso y los cambios de textura en uvas de mesa durante el almacenamiento. Estos modelos alcanzaron coeficientes de determinación superiores a 0,80 para la pérdida de peso y 0,97 para la textura, además de evidenciar que temperaturas de almacenamiento más bajas contribuyen a preservar mejor la calidad del fruto. Barbosa Júnior et al. (2025) aplicaron modelos SVM y *Random Forest* a imágenes RGB para clasificar arándanos según defectos, como daños por compresión, deshidratación o coloración no uniforme, con precisiones superiores al 92 %, lo que confirma su viabilidad para la inspección automatizada de frutos de pequeño calibre.

En un ámbito más metodológico, Durojaiye et al. (2024) evaluaron el uso de imágenes hiperespectrales combinadas con técnicas de aprendizaje profundo para detectar defectos internos y externos de productos agrícolas con alta precisión, señalando la necesidad de analizar grandes conjuntos de datos y de las técnicas de preprocesado avanzadas para mejorar la robustez de los modelos. Yang et al. (2024) propusieron un enfoque guiado por conocimiento para espectroscopía en línea, que permitió reducir la incertidumbre de predicción hasta en un 27 % sin necesidad de modificar el hardware, mejorando la repetibilidad y fiabilidad de las mediciones. Kabadurmus et al. (2023), por su parte, desarrollaron un sistema de visión artificial para la clasificación de frutas basado en imágenes hiperespectrales y aprendizaje automático, logrando altos niveles de exactitud y mostrando la aplicabilidad de estas técnicas en entornos industriales con clasificación en tiempo real.

Otros trabajos como el de Ahmed et al. (2024) exploraron la incorporación de técnicas de inteligencia artificial explicable en sistemas de visión, utilizando mapas de activación y análisis SHAP para identificar las características visuales más determinantes en la clasificación de cada fruto. Este tipo de estrategias no solo mejora la interpretabilidad de los modelos, sino que también aumenta la confianza de los operarios en entornos industriales.

La visión artificial ha demostrado un alto potencial para la evaluación precisa y en tiempo real de atributos de calidad en poscosecha, optimizando la uniformidad y reduciendo pérdidas por defectos no detectados de forma manual. No obstante, su alcance se amplía cuando se combina con soluciones capaces de monitorizar parámetros internos del producto y condiciones ambientales durante la manipulación y el almacenamiento, como es el caso de los sensores inteligentes, analizados en el siguiente apartado.

### **3.3. Sensores inteligentes para evaluación de calidad interna**

A diferencia del control de calidad externo, la evaluación de atributos internos en frutas y hortalizas, como la firmeza, el contenido de sólidos solubles o la presencia de defectos internos, plantea mayores desafíos debido a que no son visibles externamente. En este contexto, los sensores inteligentes ofrecen soluciones no destructivas capaces de monitorizar parámetros internos del producto y condiciones ambientales críticas durante la manipulación y el almacenamiento, aportando datos que complementan la información obtenida mediante inspección visual.

Entre estas tecnologías, Broekman y Steyn (2021) desarrollaron el sistema *smAvo*, que integra sensores inerciales y de presión en aguacates para monitorizar, en tiempo real, las fuerzas y vibraciones a las que el fruto se ve sometido durante el procesado en centrales de envasado. Esta información permitió identificar puntos críticos de daño mecánico y proponer ajustes en las

líneas para minimizar pérdidas de calidad. En un enfoque complementario, Canatan et al. (2025) implementaron un sistema de cámaras visibles combinado con sensores de temperatura de alta resolución para el seguimiento continuo de la temperatura superficial en frutas refrigeradas, generando mapas térmicos en tiempo real que facilitan la detección de variaciones en el enfriamiento y la optimización del control de frío.

El potencial de los sensores inteligentes también se extiende a la predicción del estado interno y la vida útil de los productos. Kanjilal et al. (2025) desarrollaron una plataforma de análisis de datos a gran escala para el seguimiento del proceso de maduración de plátanos, integrando sensores de temperatura, humedad y colorimetría con modelos de predicción sensorial. Este sistema permitió predecir cambios en la firmeza y el sabor, mejorando la uniformidad en la entrega al mercado. De forma similar, Rajini y Voola (2025) diseñaron una solución basada en IoT y *machine learning* para monitorizar en tiempo real el grado de madurez y el inicio de la degradación en bananas, utilizando sensores de color y de gases como el etileno, con alertas automáticas para la gestión logística.

En plantas aromáticas, Kiani et al. (2023) aplicaron tecnología de nariz electrónica (*e-nose*) acoplada con algoritmos de inteligencia artificial para evaluar la calidad y modelar el perfil aromático de *Mentha spicata*. El sistema logró correlaciones elevadas entre las lecturas de los sensores y los resultados de análisis químicos convencionales, evidenciando su potencial para predecir características sensoriales de forma no destructiva. En esta misma línea, Zhou et al. (2025) evaluaron la dinámica poscosecha de compuestos aromáticos en diez cultivares de lirio cortado mediante la combinación de cromatografía de gases acoplada a microextracción en fase sólida (*HS-SPME-GC-MS*) y nariz electrónica. El estudio identificó 51 compuestos orgánicos volátiles, con predominio de monoterpenoides en la mayoría de cultivares y de bencenoides/fenilpropanoides en algunos específicos. Los datos obtenidos por la nariz electrónica mostraron buena correlación con los resultados de GC-MS ( $r = 0,79$ ,  $p < 0,01$ ) y, a través de modelos de *Random Forest* y análisis discriminante de mínimos cuadrados parciales (PLS-DA), se determinaron sensores y compuestos clave para diferenciar la calidad de la fragancia en distintas etapas de envejecimiento. Además, el análisis de regresión PLS reveló asociaciones significativas entre sensores específicos y compuestos volátiles relevantes, lo que permite su uso como indicadores rápidos de calidad aromática. Esta integración de sensores electrónicos y análisis multivariante ofrece una herramienta eficiente y no destructiva para el control de atributos sensoriales en flores cortadas, con potencial para extenderse a otros productos hortofrutícolas con alto valor sensorial.

Asimismo, Kumar y Rawat (2024) propusieron un dispositivo IoT con sensores múltiples para controlar la calidad de diversos alimentos, evaluando parámetros

como temperatura, humedad y concentración de gases, con transmisión de datos en tiempo real a través de una aplicación móvil, lo que facilita la toma de decisiones en la gestión poscosecha. Otra aplicación relevante es la desarrollada por Zhou et al. (2025), quienes propusieron un sistema de envasado inteligente para uvas de mesa, incorporando sensores de gas y temperatura capaces de registrar las condiciones internas del envase durante el transporte. Esta información, combinada con modelos de predicción, permitió estimar la vida útil y la pérdida de calidad de forma más precisa, mejorando la planificación logística y reduciendo mermas.

Los avances en sensores inteligentes están ampliando significativamente la capacidad para evaluar parámetros internos y ambientales en tiempo real, ofreciendo información que complementa la obtenida mediante inspección visual.

### **3.4. Modelos predictivos para estimación de vida útil y parámetros de calidad**

La estimación precisa de la vida útil poscosecha de los productos hortofrutícolas, así como la predicción de parámetros críticos de calidad (firmeza, textura, pérdida de peso o compuestos bioactivos) es esencial para optimizar la calidad final y reducir las pérdidas a lo largo de la cadena de suministro. Los modelos predictivos basados en inteligencia artificial han demostrado ser herramientas eficaces para este propósito, superando muchas de las limitaciones de los métodos convencionales, que suelen requerir mediciones destructivas o prolongados tiempos de análisis.

En este ámbito, Liu et al. (2025) desarrollaron un modelo de *Machine Learning* (ML) para predecir el deterioro de uvas de mesa durante el almacenamiento, integrando datos de temperatura, humedad y parámetros fisicoquímicos como sólidos solubles y firmeza inicial. El sistema, entrenado y validado con más de 500 muestras, alcanzó valores de  $R^2$  superiores a 0,95 y errores medios absolutos inferiores al 5 % en la estimación de la vida útil. Además, permitió simular distintos escenarios de conservación, mostrando que un control más estricto de la temperatura podía prolongar la vida útil en hasta 3 días.

De manera similar, Cheng et al. (2025) emplearon modelos de regresión y redes neuronales para predecir la pérdida de peso y los cambios de textura en uvas a partir de información de color y condiciones ambientales. Los modelos de Red Neuronal Profunda (DNN) alcanzaron coeficientes de determinación de hasta 0,96 para la textura y 0,94 para el peso, superando el rendimiento de los modelos de regresión múltiple. Además, se observó que la inclusión de parámetros derivados del color en distintos espacios cromáticos mejoraba la capacidad de predicción, especialmente en condiciones de humedad variable.

El-Mesery et al. (2025) aplicaron técnicas de ML para modelar el comportamiento de parámetros fisicoquímicos en ajo bajo diferentes condiciones de almacenamiento y tipos de envase. Utilizando algoritmos como *Random Forest* y redes neuronales artificiales, alcanzaron correlaciones de hasta 0,97 para firmeza y 0,95 para contenido de compuestos fenólicos. Los autores señalaron que la selección de variables, como la temperatura y el tipo de material de envasado, fue determinante para mejorar la capacidad predictiva, lo que sugiere que la integración de datos logísticos y de procesado puede optimizar estos modelos.

En el caso de Kanjilal et al. (2025), se desarrollaron modelos de predicción sensorial para bananas, integrando colorimetría, temperatura y humedad con registros históricos de comportamiento poscosecha. Este enfoque permitió anticipar cambios en textura y sabor con hasta 5 días de antelación, facilitando la programación de la distribución y mejorando la uniformidad de calidad en el punto de venta. La validación en entornos comerciales mostró una reducción de mermas del 12 % frente a la planificación tradicional.

Yang et al. (2024) propusieron un modelo predictivo basado en espectroscopía guiada por conocimiento, combinando datos espectrales con información experta sobre las longitudes de onda más relevantes para la estimación de sólidos solubles y firmeza. Este enfoque redujo la incertidumbre de predicción en un 15 % respecto a modelos de caja negra y mejoró la interpretabilidad de los resultados, lo que facilita su aceptación en entornos industriales.

Finalmente, Kumar y Rawat (2024) desarrollaron un sistema IoT que integra sensores de temperatura, humedad y gases con algoritmos de predicción para evaluar la frescura y detectar deterioro en tiempo real. Los datos se transmiten mediante una aplicación móvil, permitiendo la supervisión remota y la generación de alertas automáticas. Las pruebas demostraron que la combinación de sensores con modelos de ML incrementaba en un 20 % la precisión de detección frente a sistemas basados solo en umbrales fijos.

Los resultados de estos estudios evidencian que la integración de modelos predictivos con datos provenientes de sensores y sistemas de visión artificial permite anticipar cambios de calidad y vida útil con un alto grado de fiabilidad. Esta capacidad de predicción facilita una gestión logística más dinámica y adaptada al estado real del producto, y se ve reforzada cuando se combina con sistemas de trazabilidad avanzados que aseguran el seguimiento continuo de la información.

### 3.5. IA aplicada a la seguridad alimentaria y trazabilidad

La inteligencia artificial adquiere cada vez mayor relevancia en la mejora de la seguridad alimentaria y la trazabilidad de productos hortofrutícolas durante la poscosecha. Estas aplicaciones combinan algoritmos de aprendizaje automático con redes de sensores y plataformas digitales para permitir la detección temprana de riesgos, el seguimiento continuo de las condiciones de almacenamiento y transporte, y la verificación de la autenticidad de los lotes.

En el ámbito de la seguridad alimentaria, Sim et al. (2023) demostraron el potencial de la espectroscopía hiperespectral combinada con modelos de *support vector regression* para predecir la composición isotópica y los niveles de elementos traza en café, con el objetivo de verificar su origen geográfico. Aunque el estudio se centró en café, la metodología podría ser extrapolable a otros productos hortofrutícolas y muestra cómo la IA puede emplearse para la autenticación de alimentos y la detección de fraudes. Los modelos desarrollados alcanzaron coeficientes de determinación superiores a 0,9 en la predicción de parámetros clave, lo que confirma su capacidad para complementar métodos analíticos más lentos y costosos.

En cuanto a la trazabilidad inteligente, Hassoun et al. (2023) describen un marco de "Traceability 4.0" que integra IA, sensores IoT y Blockchain para monitorizar en tiempo real variables críticas como temperatura, humedad y composición gaseosa durante el transporte de productos frescos. Este enfoque garantiza que cada registro ambiental quede asociado de forma inmutable al historial del lote, aumentando la transparencia y reduciendo el riesgo de manipulaciones. Entre los beneficios observados destacan la reducción de costes en retiradas de productos y la minimización del desperdicio gracias a una gestión dinámica de la calidad.

Por su parte, Rajini y Voola (2025) desarrollaron una plataforma IoT y ML para evaluar la madurez y predecir el deterioro de plátanos en entornos de almacenamiento y transporte. El sistema incorporaba sensores de temperatura y gases, cuyos datos se procesaban mediante modelos como *Random Forest* y *Gradient Boosting*, alcanzando precisiones superiores al 95 % en la clasificación de estados de maduración. Además, la plataforma generaba alertas predictivas de riesgo de pérdida de calidad, lo que facilita la toma de decisiones para optimizar la rotación de inventario.

En un contexto complementario, Kanjilal et al. (2025) aplicaron análisis de datos a gran escala para monitorizar la uniformidad en el proceso de maduración comercial de plátanos, integrando información de temperatura de pulpa y color superficial obtenida mediante sensores y visión artificial. Sus modelos predictivos permitieron anticipar desviaciones en la maduración y ajustar los parámetros de

almacenamiento, contribuyendo tanto a la estandarización de la calidad como a la reducción de pérdidas.

Finalmente, Canatan et al. (2025) propusieron un sistema de monitorización continua de la temperatura superficial de frutas refrigeradas mediante cámaras visibles integradas en cámaras de almacenamiento. Las imágenes se procesaban con modelos de visión artificial y aprendizaje automático, detectando zonas con riesgo de variaciones térmicas que podrían comprometer la seguridad y calidad del producto. Esta información permite implementar acciones correctivas de forma inmediata, reduciendo la exposición a condiciones que favorezcan el desarrollo microbiano o el deterioro prematuro.

Estos desarrollos ponen de manifiesto que la integración de IA con sistemas de detección y trazabilidad avanzada no solo refuerza la seguridad alimentaria, sino que también genera un flujo continuo de información estratégica para la gestión poscosecha. La capacidad de conectar estos datos con soluciones de envasado inteligente abre nuevas oportunidades para prolongar la vida útil y mantener la calidad de los productos.

### **3.6. Monitorización poscosecha en tiempo real: IA + IoT**

La integración de envases inteligentes en la etapa poscosecha está transformando la forma en que se monitoriza y preserva la calidad de los productos hortofrutícolas. Estos sistemas incorporan sensores y dispositivos capaces de registrar y comunicar en tiempo real parámetros críticos, como temperatura, humedad, concentración de gases o compuestos volátiles, lo que permite una gestión más precisa de la conservación y la trazabilidad.

Yin et al. (2024) desarrollaron un modelo de predicción inteligente de la frescura de uvas de mesa durante su transporte, combinando indicadores de rendimiento del envase con variables ambientales registradas por sensores. El sistema integraba datos de temperatura, humedad y tiempo de tránsito con un algoritmo de ML capaz de estimar la calidad residual y la vida útil del lote. Sus resultados mostraron que el modelo mejoró la precisión de predicción de frescura en un 15 % respecto a métodos convencionales, facilitando decisiones logísticas más ajustadas para reducir pérdidas.

En un enfoque complementario, Zhang et al. (2025) propusieron un sistema de envasado inteligente basado en películas biodegradables modificadas con *Metal-Organic Frameworks* (MOFs) luminiscentes, capaces de detectar cambios de pH y CO<sub>2</sub> asociados a la pérdida de frescura en fruta cortada. El sistema permitía una lectura visual directa o cuantitativa mediante aplicación móvil, mostrando una alta correlación ( $R^2 > 0,98$ ) entre parámetros de color y características fisicoquímicas como dureza y sólidos solubles totales. Esta

tecnología demostró un elevado potencial para el seguimiento en tiempo real de la calidad, especialmente en productos de cuarta gama.

Por otra parte, Zhang et al. (2022) desarrollaron un envase activo con sensores de gases que permitía monitorizar la concentración de etileno y CO<sub>2</sub>, asociados a la maduración y al deterioro, en productos como tomates y fresas. La información recogida se procesaba mediante redes neuronales artificiales para predecir el momento óptimo de comercialización y activar de forma automática mecanismos de absorción de gases. Este sistema demostró ser eficaz para extender la vida útil y mantener la calidad sensorial de los frutos, reduciendo la incidencia de pérdidas por sobremaduración.

Kumar y Rawat (2024) diseñaron un prototipo de envase inteligente con sensores integrados y conectividad IoT, capaz de transmitir datos a una aplicación móvil para el seguimiento en tiempo real del estado del producto. El sistema incorporaba algoritmos de IA para interpretar variaciones en temperatura, humedad y niveles de gases, generando alertas preventivas y recomendaciones de manejo. Además de su aplicación en frutas y hortalizas, los autores destacaron su potencial para otros alimentos perecederos, especialmente en entornos con cadenas logísticas complejas o de larga distancia.

Los avances en envases inteligentes muestran que la combinación de sensores, IoT e inteligencia artificial no solo mejora la trazabilidad y garantiza un mayor control de la vida útil, sino que también permite dar respuestas inmediatas ante condiciones adversas, optimizando la gestión de la calidad en toda la cadena de suministro. Estas capacidades sientan las bases para la implementación de sistemas poscosecha más interconectados y eficientes.

### **3.7. Limitaciones actuales e inteligencia artificial explicable**

Aunque la inteligencia artificial ha demostrado ser una herramienta eficaz y versátil en la poscosecha, los trabajos revisados también reflejan una serie de limitaciones técnicas y operativas que dificultan su aplicación a gran escala. Uno de los principales retos es la variabilidad intrínseca de los productos hortofrutícolas, tanto por sus características biológicas como por las condiciones de almacenamiento. Esta variabilidad puede reducir la reproducibilidad de las predicciones, especialmente en modelos de clasificación automática o de estimación de parámetros de calidad. Factores como ligeras variaciones en la orientación del producto, la iluminación o la temperatura durante la medición pueden modificar la respuesta de los sensores y, por tanto, la interpretación de los modelos (Yang et al., 2024). Para abordar este problema, Yang et al. (2024) desarrollaron una red neuronal convolucional guiada por conocimiento (*Knowledge-Guided CNN*) aplicada a cítricos, diseñada para penalizar la variabilidad angular durante el entrenamiento. El modelo consiguió reducir en un 27 % la varianza de las predicciones respecto a una CNN convencional,

manteniendo un RMSE prácticamente constante, lo que representa un paso importante hacia la generalización de modelos en entornos industriales.

Otra limitación recurrente es la falta de transparencia de los modelos, especialmente en arquitecturas profundas, donde no siempre es evidente qué variables o patrones determinan la decisión final. Esta falta de explicabilidad dificulta su adopción en sectores como el agroalimentario, donde es necesario justificar por qué un lote es rechazado o clasificado como no apto. En este sentido, Ahmed et al. (2024) combinaron técnicas de *Inteligencia Artificial Explicable* con imágenes hiperespectrales para evaluar la calidad interna de boniatos. Utilizando algoritmos SHAP (*Shapley Additive Explanations*), identificaron las longitudes de onda con mayor peso en la predicción de atributos como materia seca o firmeza, generando mapas de calidad interpretables que aumentan la confianza en el sistema y facilitan su integración en procesos reales.

Asimismo, Wieme et al. (2022) señalaron que muchos conjuntos de datos utilizados en investigación son limitados en tamaño y diversidad, lo que compromete la capacidad de los modelos para mantener su rendimiento frente a productos con características distintas o defectos poco frecuentes. En el caso de tecnologías emergentes, como los sensores multiespectrales compactos o sistemas *e-nose*, aún existen barreras relacionadas con la calibración cruzada, el coste de implementación y la integración en las líneas de procesado.

En los estudios analizados, la superación de estas limitaciones requiere una combinación de mejoras en los algoritmos y en los sistemas de sensorización, junto con una validación exhaustiva en entornos operativos reales. Adaptar los desarrollos a la variabilidad de los productos, aumentar la transparencia de los modelos y disponer de bases de datos más amplias y representativas son pasos clave para que la inteligencia artificial en poscosecha avance hacia soluciones fiables y aplicables en contextos industriales diversos.

#### **4. CONCLUSIONES**

La revisión sistemática realizada ha permitido analizar en profundidad el estado actual y las tendencias emergentes en la aplicación de la inteligencia artificial (IA) en el ámbito poscosecha, con especial atención al control de calidad y la seguridad alimentaria en productos hortofrutícolas. El análisis de 25 estudios recientes confirma que la IA se ha consolidado como una herramienta estratégica para optimizar múltiples etapas del proceso poscosecha, desde la inspección visual y la clasificación automática hasta la gestión inteligente de la cadena logística.

En la actualidad, la tecnología más consolidada es la visión artificial basada en redes neuronales convolucionales, utilizada principalmente para la detección

temprana de defectos externos, la clasificación por grado de madurez y la evaluación de daños superficiales. Los sensores inteligentes, combinados con algoritmos de aprendizaje automático, destacan como soluciones prometedoras para la evaluación no destructiva de atributos internos como la firmeza, el contenido de azúcares o el perfil aromático. En el ámbito de los modelos predictivos, la IA se posiciona como una herramienta eficaz para predecir la vida útil y reducir las pérdidas durante el almacenamiento y transporte. La integración de datos ambientales, fisicoquímicos y de sensorización permite realizar predicciones más precisas que los métodos convencionales, abriendo la puerta a estrategias de gestión más eficientes.

La IA aporta también valor en seguridad alimentaria, facilitando la detección rápida de riesgos y contaminaciones. Las aplicaciones basadas en IoT tienen un gran potencial para la monitorización continua y la automatización de la gestión poscosecha. Sin embargo, la adopción industrial sigue limitada por problemas de explicabilidad, falta de bases de datos representativas, ausencia de protocolos estandarizados y una brecha clara entre validación experimental y aplicación real, a lo que se suma el acceso desigual entre grandes empresas y pequeños productores. Finalmente, la integración de la IA en la poscosecha tiene capacidad real para mejorar la eficiencia, optimizar la calidad de los productos y reforzar la seguridad alimentaria. Asimismo, muchas de estas técnicas muestran potencial de transferibilidad entre distintos productos hortofrutícolas, aunque la variabilidad biológica obliga a desarrollar modelos específicos para cada caso. Su adopción a gran escala dependerá de avances técnicos en algoritmos y sensorica, de la validación en entornos reales, de la estandarización de protocolos y de la formación de los usuarios finales.

## 5. BIBLIOGRAFÍA

- Ahmed, T., Wijewardane, N. K., Lu, Y., Jones, D. S., Kudenov, M., Williams, C., Villordon, A., & Kamruzzaman, M. (2024). Advancing sweetpotato quality assessment with hyperspectral imaging and explainable artificial intelligence. *Computers and Electronics in Agriculture*, 220, 108855. <https://doi.org/10.1016/J.COMPAG.2024.108855>
- Arango, J. D., Staar, B., Baig, A. M., & Freitag, M. (2021). Quality control of apples by means of convolutional neural networks - Comparison of bruise detection by color images and near-infrared images. *Procedia CIRP*, 99, 290–294. <https://doi.org/10.1016/J.PROCIR.2021.03.043>
- Barbosa Júnior, M. R., Santos, R. G. dos, Sales, L. de A., Vargas, R. B. S., Deltsidis, A., & Oliveira, L. P. de. (2025). Image-based and ML-driven analysis for assessing blueberry fruit quality. *Heliyon*, 11(3), e42288. <https://doi.org/10.1016/J.HELIVON.2025.E42288>

- Broekman, A., & Steyn, W. J. M. (2021). smAvo: Packhouse optimization using smart avocados in South Africa. *Computers and Electronics in Agriculture*, 191, 106507. <https://doi.org/10.1016/J.COMPAG.2021.106507>
- Canatan, M., Muñoz-Carpena, R., & Boz, Z. (2025). Continuous surface temperature monitoring of refrigerated fresh produce through visible and thermal infrared sensor fusion. *Postharvest Biology and Technology*, 222, 113354. <https://doi.org/10.1016/J.POSTHARVBIO.2024.113354>
- Cheng, X., Zhou, Y., Huo, Z., Li, R., Xu, S., Qi, H., Zhu, J., Wang, F., & Bi, Y. (2025). Predicting postharvest weight loss and texture changes in table grapes using fruit color and machine learning. *Future Foods*, 12, 100703. <https://doi.org/10.1016/J.FUFO.2025.100703>
- Durojaiye, A. I., Olorunsogo, S. T., Adejumo, B. A., Babawuya, A., & Muhamad, I. I. (2024). Deep learning techniques for the exploration of hyperspectral imagery potentials in food and agricultural products. *Food and Humanity*, 3, 100365. <https://doi.org/10.1016/J.FOOHUM.2024.100365>
- El-Mesery, H. S., ElMesiry, A. H., Husein, M., Hu, Z., & Salem, A. (2025). Artificial intelligence and machine learning models for predicting and evaluating the influence of shelf-life environments and packaging materials on garlic (*Allium Sativum* L) physicochemical and phytochemical compositions. *Food Chemistry: X*, 29, 102731. <https://doi.org/10.1016/J.FOCHX.2025.102731>
- Gulzar, Y., & Ünal, Z. (2025). Time-Sensitive Bruise Detection in Plums Using PlmNet with Transfer Learning. *Procedia Computer Science*, 257, 127–132. <https://doi.org/10.1016/J.PROCS.2025.03.019>
- Hassoun, A., Kamiloglu, S., Garcia-Garcia, G., Parra-López, C., Trollman, H., Jagtap, S., Aadil, R. M., & Esatbeyoglu, T. (2023). Implementation of relevant fourth industrial revolution innovations across the supply chain of fruits and vegetables: A short update on Traceability 4.0. *Food Chemistry*, 409, 135303. <https://doi.org/10.1016/J.FOODCHEM.2022.135303>
- He, J., van Doorselaer, L., Tempelaere, A., Vignero, J., Saeys, W., Bosmans, H., Verboven, P., & Nicolai, B. (2024). Nondestructive internal disorders detection of 'Braeburn' apple fruit by X-ray dark-field imaging and machine learning. *Postharvest Biology and Technology*, 214, 112981. <https://doi.org/10.1016/J.POSTHARVBIO.2024.112981>
- Kabadurmus, O., Kayikci, Y., Demir, S., & Koc, B. (2023). A data-driven decision support system with smart packaging in grocery store supply chains during outbreaks. *Socio-Economic Planning Sciences*, 85, 101417. <https://doi.org/10.1016/J.SEPS.2022.101417>
- Kanjilal, R., Saenz, J. E., & Uysal, I. (2025). Large-scale data-driven uniformity analysis and sensory prediction of commercial banana ripening process. *Postharvest Biology and Technology*, 219, 113203. <https://doi.org/10.1016/J.POSTHARVBIO.2024.113203>

- Kiani, S., Rahimzadeh, H., Kalantari, D., & Moradi-Sadr, J. (2023). Aroma modeling and quality evaluation of spearmint (*Mentha spicata* subsp. *spicata*) using electronic nose technology coupled with artificial intelligence algorithms. *Journal of Applied Research on Medicinal and Aromatic Plants*, 35, 100473. <https://doi.org/10.1016/J.JARMAP.2023.100473>
- Kumar, P., & Rawat, S. (2024). Design And Development of an Application to Preserve Various Eatables Using IoT. *Procedia Computer Science*, 241, 415–420. <https://doi.org/10.1016/J.PROCS.2024.08.057>
- Liu, Y., Jiang, K., Qin, Y., Brennan, M., Brennan, C., Cao, J., Wang, Z., & Soteyome, T. (2025). Prediction of the postharvest quality of *Boletus* wild mushrooms stored with mesoporous silica nanoparticles antibacterial film using Long Short-Term Memory model combined with the Northern Goshawk Optimization (NGO-LSTM). *Food Chemistry*, 463, 141490. <https://doi.org/10.1016/J.FOODCHEM.2024.141490>
- Rajini, M., & Voola, P. (2025). Developing an IoT and ML-driven platform for fruit ripeness evaluation and spoilage detection: A case study on bananas. *e-Prime – Advances in Electrical Engineering, Electronics and Energy*, 11, 100896. <https://doi.org/10.1016/j.prime.2025.100896>
- Sim, J., Dixit, Y., MCGoverin, C., Oey, I., Frew, R., Reis, M. M., & Kebede, B. (2023). Support vector regression for prediction of stable isotopes and trace elements using hyperspectral imaging on coffee for origin verification. *Food Research International*, 174, 113518. <https://doi.org/10.1016/J.FOODRES.2023.113518>
- Wieme, J., Mollazade, K., Malounas, I., Zude-Sasse, M., Zhao, M., Gowen, A., Argyropoulos, D., Fountas, S., & van Beek, J. (2022). Application of hyperspectral imaging systems and artificial intelligence for quality assessment of fruit, vegetables and mushrooms: A review. *Biosystems Engineering*, 222, 156–176. <https://doi.org/10.1016/J.BIOSYSTEMSENG.2022.07.013>
- Yang, J., Sun, Z., Tian, S., Jiang, H., Feng, J., Ting, K. C., Lin, T., & Ying, Y. (2024). Enhancing spectroscopy-based fruit quality control: A knowledge-guided machine learning approach to reduce model uncertainty. *Postharvest Biology and Technology*, 216, 113009. <https://doi.org/10.1016/J.POSTHARVBIO.2024.113009>
- Yin, M., Huo, L., Li, N., Zhu, H., Zhu, Z., & Hu, J. (2024). Packaging performance evaluation and freshness intelligent prediction modeling in grape transportation. *Food Control*, 165, 110684. <https://doi.org/10.1016/J.FOODCONT.2024.110684>
- Zhang, W., Wang, K., & Chen, C. (2022). Artificial Neural Network Assisted Multiobjective Optimization of Postharvest Blanching and Drying of Blueberries. *Foods*, 11(21), 3347. <https://doi.org/10.3390/foods11213347>
- Zhang, Z., Wang, C., Jayan, H., Gao, M., El-Seedi, H. R., Zou, X., & Guo, Z. (2025). Novel pH-sensitive organic ligand-based luminescent MOFs modified CMC-Na/SA films for real-time monitoring of fruit freshness. *Food Packaging and Shelf Life*, 49, 101521. <https://doi.org/10.1016/J.FPSL.2025.101521>

- Zhou, Y., Chen, Y., Dong, J., Wang, Q., Yan, F., Tan, J., Xu, Y., Zhu, G., Fan, Y., & Ye, Y. (2025). Postharvest fragrance dynamics of different scented cut lilies: Insights from HS–SPME–GC–MS and electronic nose. *Postharvest Biology and Technology*, 222, 113378. <https://doi.org/10.1016/j.postharvbio.2024.113378>
- Zou, Y., Wu, J., Meng, X., Wang, X., & Manzardo, A. (2025). Digital twin integration for dynamic quality loss control in fruit supply chains. *Journal of Food Engineering*, 397, 112577. <https://doi.org/10.1016/J.JFOODENG.2025.112577>

## ANEXO II

**Tabla II.1.** Tabla de resultados de la revisión sistemática sobre aplicaciones de la inteligencia artificial en poscosecha.

REFERENCIA	PRODUCTO EVALUADO	OBJETIVO	TECNOLOGÍA DE IA APLICADA	APLICACIÓN POSCOSECHA	HERRAMIENTA O TÉCNICA	RESULTADOS
Ahmed et al. (2024)	Boniato	Evaluar calidad interna mediante imagen hiperespectral e IA explicable	XAI + Machine Learning	Clasificación de calidad interna	Imagen hiperespectral	Alta precisión en detección y clasificación; identificación de longitudes de onda clave
Arango et al. (2021)	Manzana	Detectar magulladuras mediante imágenes RGB e infrarrojas	Convolutional Neural Network (CNN)	Detección de defectos externos	Imágenes multiespectrales	Precisión >97% en detección de magulladuras
Barbosa Júnior et al. (2025)	Arándano	Evaluar calidad externa con análisis basado en imagen	Machine Learning	Clasificación de calidad externa	Visión artificial	Modelos eficientes en detección de defectos
Broekman & Steyn (2021)	Aguacate	Cuantificar estrés mecánico en packhouse	Sensores inerciales + análisis estadístico	Identificar puntos críticos de daño	smAvo 5 (IMU)	Se midieron picos >100 g; DIS clasificó 24 packhouses y guió mejoras
Canatan et al. (2025)	Manzana, pimiento, brócoli	Monitorizar temperatura superficial continua	Fusión RGB+IR + YOLOv4-Tiny	Control térmico en retail y almacén	FLIR Lepton + Jetson Nano	RMSE <0,9 °C; identifica zonas calientes y reduce pérdidas
Cheng et al. (2025)	Uva de mesa ('Flame Seedless', 'Shine Muscat')	Predecir pérdida de peso y textura a partir del color del fruto	CNN	Monitorizado no destructivo de refrigeración	Colorimetría + Deep CNN	R <sup>2</sup> > 0,80 (peso) y > 0,97 (textura); almacenamiento a 3 °C minimiza deterioro

Durojaiye et al. (2024)	Alimentos (visión general)	Desarrollar HSI de bajo coste e IA embebida	Redes profundas, SVM, RF	Inspección rápida de calidad y autenticidad	DIY HSI + ML	Configuraciones COTS con precisión comparable a sistemas comerciales
El-Mesery et al. (2025)	Ajo	Predecir impacto de envase y entorno sobre calidad	Redes neuronales artificiales (ANN), Random Forest	Predicción de parámetros fisicoquímicos	Modelos ML	Alta precisión en predicción de condiciones óptimas
Gulzar & Ünal (2025)	Ciruela ('Friar')	Detectar hematomas a 12 h y 72 h con NIR	CNN (PImNet + TL)	Clasificación de daños tempranos	NIR imaging 900 nm	Exactitud 97 %; supera EfficientNetB3 en daños recientes
Hassoun et al. (2023)	Frutas y hortalizas	Implementar trazabilidad 4.0 en la cadena de suministro	Blockchain + IoT + big data	Trazabilidad	Sensores + software de trazabilidad	Sistema más seguro y transparente
He et al. (2024)	Manzana 'Braeburn'	Diagnóstico de desórdenes internos tempranos	Clasificadores ML sobre X-ray dark-field	Clasificación inline para sorting	Radiografía dark-field + ML	+10 % precisión vs. X-ray convencional; útil para líneas de alta velocidad
Kabadurmus et al. (2023)	Pimiento	Clasificar fresca y defectos visuales	YOLOv5 + TL	Selección y descarte automatizado	Visión RGB alta resolución	mAP > 95 % a 30 FPS; viable para packlines
Kanjilal et al. (2025)	Banano (contenedor marino)	Analizar uniformidad de maduración y O <sub>2</sub> /CO <sub>2</sub>	LSTM, RF, XGBoost	Control dinámico de atmósfera	Sensórica contenedor + ML	LSTM RMSE 0,03 en O <sub>2</sub> ; mejora consistencia de color y T
Kiani et al. (2023)	Hierbabuena seca	Modelar aroma y graduar calidad	ANN, PLS-DA, fuzzy clustering	Clasificación por % de aceite esencial	E-nose + quimiometría	Rp <sup>2</sup> = 0,97; sensibilidad 97 %, especificidad 86 %

Kumar & Rawat (2024)	Mango 'Alphonso'	Estimar madurez interna no destructiva	SVR, KNN, CNN híbrido	Determinación de punto óptimo de consumo	NIR portátil	SVR+GA reduce RMSE a 0,45 °Brix vs métodos clásicos
Liu et al. (2025)	Setas Boletus	Predecir vida útil con film antibacteriano	LSTM optimizado (NGO)	Pronóstico de deterioro	Variables físico-químicas en línea	Precisión > 94 % en predicción de días comercializables
Rajini & Voola (2025)	Banano (retail)	IoT + ML para detectar madurez y pudrición	CatBoost, RF, SVM	Alertas de calidad en almacén	SHT40, SGP30, ESP32	CatBoost 98 % exactitud; pérdidas -15 %
Sim et al. (2023)	Café verde (22 orígenes)	Predecir isótopos y elementos traza con HSI-NIR	SVR (RBF)	Verificación de origen	HSI 700-1700 nm	R <sup>2</sup> = 0,70-0,99 para 11 marcadores
Wieme et al. (2022)	Frutas, hortalizas y setas	Aplicación de imagen hiperespectral + IA para evaluar calidad	IA clásica + deep learning	Control de calidad no destructivo	HSI	Alta precisión y aplicabilidad práctica
Yang et al. (2024)	Mandarina y naranja	Reducir incertidumbre en espectroscopía SSC	KGCNN (pérdida guiada)	Clasificación robusta online	Vis/NIR + CNN guiada	Varianza -27 % vs CNN; RMSE ↑1,7 %
Yin et al. (2024)	Uva de mesa (transporte)	Evaluar envases y predecir frescura	SVM, GA-ANN	Selección de embalaje y shelf-life	HACCP + sensores vibr/Temp/RH	GA-ANN 94 % precisión; vibración factor crítico

Zhang et al. (2022)	Arándanos	Optimizar escaldado y secado con ANN	Artificial Neural Network (ANN)	Optimización de proceso térmico	Modelado ANN	Procesos optimizados con varios objetivos simultáneos
Zhang et al. (2025)	Mango Narcissus (fruta cortada)	Monitorizar frescura con envase inteligente basado en MOFs	App móvil + análisis de color	Smart packaging y vida útil	Película CMC-Na/SA con MOFs pH-sensibles y CO <sub>2</sub> -responsivos	R <sup>2</sup> > 0,98 para dureza y TSS; detección visual/cuanti- tativa de frescura a 4 °C
Zhou et al. (2025)	Lirio cortado	Evaluar la dinámica de compuestos aromáticos poscosecha y diferenciar calidad de fragancia	Random Forest + PLS-DA + regresión PLS	Control de calidad aromática y clasificación por fragancia	HS-SPME-GC-MS + nariz electrónica	51 VOCs identificados; sensores y compuestos clave correlacionados (r = 0,79, p < 0,01); método rápido y eficiente para evaluar fragancia poscosecha
Zou et al. (2025)	Fruta en general	Implementar gemelo digital para control dinámico de calidad	Digital twin + IA	Control logístico predictivo	Modelos digitales + IA	Reducción de mermas y optimización logística