

# Influence of Computer Vision for prediction of harvest in high stem fruits: Systematic review

Zatta Silva César Augusto<sup>1</sup>, José Félix Pingo Lozada<sup>1</sup>, Garcia Peña Lorena Yasmín, estudiante<sup>2</sup>, Torres Dionisio Dorian Hesseler, estudiante<sup>3</sup>

<sup>1</sup>Universidad Tecnológica del Perú, Perú, [C20237@utp.edu.pe](mailto:C20237@utp.edu.pe), [C28097@utp.edu.pe](mailto:C28097@utp.edu.pe)

<sup>2,3</sup> Universidad Tecnológica del Perú, Perú, [U20222176@utp.edu.pe](mailto:U20222176@utp.edu.pe), [U20228815@utp.edu.pe](mailto:U20228815@utp.edu.pe)

**Abstract**– The accelerated development of computer vision globally is having a significant impact on fruit harvest estimation, leading to increased efficiency and significant reduction in food waste. Furthermore, this technology faces notable resistance and lack of knowledge in the agricultural sector. The objective of this review is to analyze artificial vision methods in predicting the harvest of high-stemmed fruits. Therefore, a non-experimental descriptive design was applied, belonging to a systematic review without meta-analysis. Based on the defined criteria (inclusion and exclusion), 26 open access articles were chosen from the electronic databases Scopus, Scielo and Redalyc, which address the use of VA to predict the harvest of high-stemmed fruits. The findings indicated that, most studies used near-infrared (NIR) spectroscopy and RGB image processing to estimate harvest, achieving average accuracies of 95% (citrus fruits) and 75% (apples) respectively. Furthermore, the use of UAVs with RGB and YoloV3 image sensors made it possible to achieve accuracies greater than 90%, enabling predictions made between 4 and 6 months before the harvest. It was concluded that the most used VA methods were RGB image sensor, spectrometry (NIR), unmanned aerial vehicles (UAV) and YOLOv3, which demonstrated accuracies greater than 75% in predicting the maturity of high-stemmed fruits. The choice of the method will depend mainly on whether you want to analyze the internal or external part of the fruit or both, therefore, it is important to recognize the variation in the pigmentation of the shell of the high-stemmed fruit in its growth stages.

**Keywords**– Computer Vision (VA), prediction, harvest, fruits, tall stem.

# Influencia de Visión Artificial para predicción de cosecha en frutos de tallo alto: Revisión sistemática

Zatta Silva César Augusto<sup>1</sup>, José Félix Pingo Lozada<sup>1</sup>, Garcia Peña Lorena Yasmín, estudiante<sup>2</sup>, Torres Dionisio Doriana Hesseler, estudiante<sup>3</sup>

<sup>1</sup>Universidad Tecnológica del Perú, Perú, C20237@utp.edu.pe, C28097@utp.edu.pe

<sup>2,3</sup> Universidad Tecnológica del Perú, Perú, U20222176@utp.edu.pe, U20228815@utp.edu.pe

**Resumen**– El desarrollo acelerado de la visión artificial a nivel mundial está teniendo un impacto significativo en la estimación de la cosecha de frutos, lo que conduce a una mayor eficiencia y reducción significativa de los desechos de alimentos. Además, esta tecnología se enfrenta a una notable resistencia y falta de conocimiento en el sector agrícola. La presente revisión tiene como objetivo analizar los métodos de visión artificial en la predicción de la cosecha de frutos de tallo alto. Para ello, se aplicó un diseño descriptivo no experimental, perteneciente a una revisión sistemática sin metaanálisis. Con base en los criterios (inclusión y exclusión) definidos, se eligieron 26 artículos de acceso abierto provenientes de las bases de datos electrónicas Scopus, Scielo y Redalyc, los cuales abordan el uso de VA para predecir la cosecha de frutos de tallo alto. Los hallazgos indicaron que, la mayoría de estudios utilizaron espectroscopía de infrarrojo cercano (NIR) y procesamiento de imágenes RGB para estimar la cosecha, logrando precisiones promedio del 95% (frutos cítricos) y 75% (manzanas) respectivamente. Además, el uso de UAV con sensores de imágenes RGB y YoloV3 permitió alcanzar precisiones superiores al 90%, posibilitando predicciones realizadas entre 4 y 6 meses antes de la cosecha. Se concluyó que los métodos de VA más utilizados fueron sensor de imágenes RGB, espectrometría (NIR), vehículos aéreos no tripulados (UAV) y YOLOv3, los cuales demostraron precisiones superiores al 75% en la predicción de la madurez de los frutos de tallo alto. La elección del método dependerá principalmente si se quiere analizar la parte interna, externa del fruto o ambos, por lo cual, es importante reconocer la variación de la pigmentación del cascarrón del fruto de tallo alto en sus etapas de crecimiento.

**Palabras clave**– Visión Artificial (VA), predicción, cosecha, frutos, tallo alto.

## I. INTRODUCCIÓN

El desarrollo acelerado de la agricultura inteligente a nivel global ha tenido un impacto significativo en el mejoramiento de procesos tales como el diagnóstico de plagas en las siembras, condiciones climáticas, fertilización de suelos y en la predicción de la cosecha de frutos. Siendo esta última, un factor crucial para la industria agrícola, ya que contribuye a la toma de mejores decisiones sobre la logística de recolección y la comercialización futura, optimizando la productividad y reduciendo el desecho de alimentos [1]. En continentes altamente desarrollados como Asia y Europa, la aplicación de técnicas y herramientas de inteligencia artificial ha permitido a las empresas estimar el rendimiento de los cultivos y predecir el mejor momento para la cosecha de frutos para maximizar las ganancias [2].

En este contexto, es fundamental comprender que la maduración de los frutos es un factor crucial en la adopción de las tecnologías. La maduración de las frutas es un fenómeno físico-químico complejo que resulta de una serie de cambios fisiológicos y bioquímicos, los cuales determinan la textura, color, aroma y sabor de las frutas maduras [3]. Esto, se puede evidenciar fácilmente en frutos de altura, aquellos que crecen en plantas o árboles que poseen tallos largos y robustos, elevando los frutos por encima del suelo [4]. Esta característica permite que los frutos estén alejados del suelo, lo cual puede ofrecer ventajas como mejor exposición a la luz solar y protección contra enfermedades del suelo.

Últimamente, se ha evidenciado una inclinación creciente en el desarrollo de tecnologías emergentes como la visión artificial para optimizar la eficiencia de la predicción en la agricultura ya que sus aplicaciones han demostrado ser herramientas eficaces para mejorar las predicciones, facilitando una planificación más precisa y la minimización de pérdidas [5].

La visión artificial es un sistema utilizado para capturar imágenes digitales del fruto o vegetal a tiempo real. Este sistema analiza propiedades externas e internas del alimento, identificando generalmente cambios o variaciones en el color, forma, textura y otras características del alimento, identificando con precisión la cosecha de los alimentos de forma anticipada [6]. Así pues, en el marco del análisis de la visión artificial en la predicción de cosecha de frutos de tallo alto, [7] desarrolló en Europa un modelo de visión artificial y aprendizaje profundo para la estimación del rendimiento y tamaño de frutos cítricos mediante UAV. Se monitorearon un total de 20 árboles de una plantación comercial de cítricos utilizando imágenes capturadas desde un vehículo aéreo no tripulado (UAV) obteniendo un error estándar promedio de 6,59%, resultados que sugieren la posibilidad de estimaciones de rendimiento para frutas cítricas o incluso otros tipos de frutas.

Sin embargo, en Perú, se están implementando de a pocos, tecnologías como la visión artificial en el sector agrícola. Esto se debe, a que aún se continúan utilizando métodos empíricos de inspección manual y visual en sus procesos de cultivo y cosecha de frutos, que son ineficientes, porque requiere personal profesional calificado, consumen mucho tiempo, son menos precisos y pueden llegar a perjudicar las frutas [8]. Según [9] mientras que, en algunos países desarrollados como

Estados Unidos, entre el 20% y el 80% de las comunidades agrícolas utilizan inteligencia artificial en sus procesos, en América Latina, la agricultura inteligente tiene pocas aplicaciones, ya que su utilización muchas veces se limita al inadecuado acceso a la tecnología en el proceso productivo, la falta de capacitación y la resistencia al cambio en la mejora de sus prácticas agrícolas. Asimismo, de acuerdo a [10], el mercado peruano ha perdido aproximadamente un 35% en la producción de hortalizas y frutas por las interrupciones en la cadena de producción, debido a diversos factores, principalmente por las prácticas deficientes originadas en el campo de cultivo como respuesta al desconocimiento del agricultor, quien suele aplicar de forma inadecuada o excesiva los productos químicos en sus cultivos, perjudicando el periodo normal de maduración de los frutos. Esto provoca que los alimentos se deterioren más rápido de lo habitual durante el proceso de recolección.

En este contexto, el procesamiento digital de imágenes (VA), combinado con modelos matemáticos y enfoques de aprendizaje automático permitiría el desarrollo de modelos de predicción para minimizar el desperdicio de fruta [5]. Al respecto, existe un volumen creciente de publicaciones que se centran en la aplicación de la VA para estimar el rendimiento del fruto. Sin embargo, carecen de una visión panorámica y un análisis de la influencia de los métodos de VA para predecir la cosecha de frutos de tallo alto, ya que, no se dispone de estudios que sintetizan de manera sistemática sus resultados.

La presente revisión, pretende estudiar el impacto de la visión artificial en la agricultura, en específico en la estimación de los frutos, con el fin de optimizar la eficiencia de la cosecha, reducir el daño, desecho de los frutos y mejorar la calidad general de los mismos. Por lo tanto, el objetivo de esta investigación es analizar los métodos de visión artificial que generan predicción en cosecha de frutos de tallo alto. De esta manera, se busca que el sector agrícola incremente su interés en comprender el impacto de la visión artificial en la estimación de las cosechas de frutos alto y se involucre en estos procesos, evaluando si esta herramienta les pueda brindar las soluciones esperadas. Para esto, la investigación, ofrece una perspectiva completa y estructurada de las soluciones presentes en la literatura, convirtiéndolas en el enfoque de una RSL meticulosamente llevada a cabo sobre el tema.

Bajo este enfoque, el documento está estructurado de la siguiente forma: La sección Metodología, presenta la estrategia PICO y PRISMA utilizados para la investigación, la primera describe en detalle las preguntas de investigación y el proceso de selección del material bibliográfico. La sección Resultados, organiza los resultados recopilados enfocados en la descripción y análisis de métodos de visión artificial para predicción de cosecha en frutos de tallo alto. En la sección Discusión, se analizan los resultados de las eficiencias de los métodos de visión artificial para estimar la maduración de frutos realizando un comparativo de los métodos. Finalmente, en las Conclusiones, se resumen los principales

descubrimientos de la información consultada, las limitaciones de la investigación y se sugieren direcciones futuras para investigaciones que aborden el tema propuesto.

## II. METODOLOGÍA

### *Estrategia de búsqueda*

La presente revisión sistemática de literatura tuvo como finalidad analizar cómo influyen los métodos de visión artificial en la predicción de la cosecha de frutos de tallo alto. Para esto, se efectuó la búsqueda de información mediante bases de datos electrónicas, usando diferentes términos de búsqueda, además de términos de inclusión y exclusión. Para identificar de manera efectiva estudios pertinentes que aborden este tema de investigación, se empleó la estrategia PICO en la búsqueda de información. Dicha estrategia propuesta, se alinea con la pregunta de revisión y sus preguntas asociadas, las cuales fueron previamente definidas a partir del marco PICO.

TABLA I. TABLA PICO

P Problema/ Población	I Intervención	C Comparación	O Resultados
Frutos de tallo alto	Visión Artificial	Métodos de predicción	Precisión de la cosecha
PI: ¿Qué métodos de visión artificial generan predicción en cosecha de frutos de tallo alto?			
PI1: ¿Qué frutos de tallo alto se producen en la agricultura? PI2: ¿De qué manera se utiliza la visión artificial en la agricultura? PI3: ¿Qué métodos de visión artificial se utilizan actualmente para predecir la cosecha de frutos? PI4: ¿Qué tan eficiente es la visión artificial para predecir la cosecha de frutos de tallo alto?			

### *Ecuación de búsqueda*

Para la búsqueda sistemática de literatura se utilizaron tres bases de datos: Scopus, Scielo y Redalyc. Scopus constituye un pilar fundamental en la investigación académica, brindando a los investigadores las herramientas necesarias para evaluar e identificar literatura relevante para sus estudios. Al ofrecer acceso a un vasto repositorio de literatura académica, Scopus se ha consolidado como un aliado invaluable para mantenerse actualizado sobre los últimos avances de las investigaciones en cualquier campo de interés.

En este sentido, se identificó variedad de estudios que han aplicado métodos de visión artificial para predecir la cosecha de cultivos, en específico, frutos de tallo alto.

TABLA II. ECUACIÓN DE BÚSQUEDA

Componente PICO		Términos		Ecuación de Búsqueda
P	Problema/ Población	Fruto de tallo alto, frutos de altura, cultivos de huerto, frutos, árboles frutales.	Tall stem fruit, tall fruit, garden crops, fruit, fruit trees	"Tall Stem Fruit" OR "tall fruit" OR "Garden Crops" OR "Fruit" OR "Fruit trees"

I	Intervención	Visión por computadora, aprendizaje profundo, análisis de imágenes, aprendizaje automático.	Computer vision, machine learning, image analysis, automatic learning	"Computer Vision" OR "Machine learning" OR "Image analysis" OR "Automatic learning"
C	Comparación	Predicción, estimación de cosecha, previsión de cosecha, métodos de predicción, estimación	Prediction, crop estimation, harvest forecast, prediction methods, estimation	"Prediction" OR "Crop estimation" OR "harvest forecast" OR "Prediction methods" OR "estimation"
O	Resultados	Precisión, exactitud, exactitud de la cosecha, precisión de la cosecha de cultivos, tolerancia de precisión del cultivo	Precision, accuracy, harvest accuracy, crop harvesting accuracy, crop precision tolerance	"precision" OR "accuracy" OR "Harvest accuracy" OR "Crop harvesting Accuracy" OR "crop precision tolerance"
Ecuación General de Búsqueda				
(TITLE-ABS-KEY ("Tall Stem Fruit" OR "tall fruit" OR "Garden Crops" OR "Fruit" OR "Fruit trees") AND TITLE-ABS-KEY ("Computer Vision" OR "Machine learning" OR "Image analysis" OR "Automatic learning") AND TITLE-ABS-KEY ("Prediction" OR "Crop estimation" OR "harvest forecast" OR "Prediction methods" OR "estimation") AND TITLE-ABS-KEY ("precision" OR "accuracy" OR "Harvest accuracy" OR "Crop harvesting Accuracy" OR "crop precision tolerance"))				

**Criterios (Inclusión y Exclusión):**

Se establecieron varios criterios para asegurar la selección apropiada de la literatura para la investigación, con el objetivo de identificar estudios que puedan abordar las preguntas de investigación, descartando aquellas que no cumplan con los requisitos mínimos que indiquen los criterios. Su aplicación adecuada garantiza la fiabilidad e integridad de la investigación, lo que a su vez conduce a brindar contenido más sólido y confiable. Se especifica a continuación los criterios de inclusión (CI) y exclusión (CE):

TABLA III. CRITERIOS (INCLUSIÓN Y EXCLUSIÓN)

CI	CE
CI1: Investigaciones publicadas en los periodos 2020-2024	CE1: Excluir aquellas investigaciones que no comprendan la visión artificial en la agricultura.
CI2: Investigaciones disponibles en los idiomas español e inglés	CE2: Excluir artículos que estén enfocados en la aplicación de métodos tradicionales para la predicción de la cosecha de frutos, como el muestreo manual o la estimación visual.
CI3: Artículos que sean de acceso abierto.	CE3: Excluir estudios enfocados en la predicción de cosecha aplicando otros tipos de inteligencia artificial tales como
CI4: Incluir solo artículos originales y artículos de revisión	
CI5: Incluir artículos que hayan estudiado frutos de tallo alto.	
CI6: Se pueden incluir investigaciones enfocadas en el análisis de la calidad del fruto a través de la captura y procesamiento de imágenes inteligentes (para evaluar sus propiedades	

físicoquímicas y estimar el rendimiento de la cosecha)	gemelos digitales, IOT, el big data, robótica, entre otros.
--	---

**Proceso de Selección de estudios**

En esta etapa de selección de estudios de investigación, se aplicó el planteamiento del método PRISMA por sus siglas: Preferred Reporting Items for Systematic Reviews and Meta-Analyses. Esta estrategia está diseñada para ayudar a los autores a documentar de manera transparente y detallada las razones por las cuales se ejecutó la investigación, lo que se ha realizado y los resultados encontrados en dicho estudio.

Para garantizar que las publicaciones de las revisiones sistemáticas sean transparentes, completas y precisas, se ha desarrollado desde hace mucho tiempo una guía de PRISMA. La última actualización guía PRISMA 2020, proporciona orientación adicional, clara y precisa para la publicación de cada apartado de la investigación, así como recomendaciones y ejemplos modelos de publicaciones para que los autores puedan orientarse y mejorar sus revisiones sistemáticas de forma sencilla y eficaz.

Así pues, promover el uso de la guía PRISMA 2020 proporciona información sólida para tomar decisiones acertadas, así como beneficia a los autores, editores y a los diferentes usuarios de revisiones sistemáticas de cualquier grupo de interés [11]. Para recopilar información enfocada uso de la visión artificial para la predicción de la cosecha de frutos de tallo alto, la metodología de revisión sistemática, así como el método PRISMA constituyen elementos indispensables para planificar y realizar revisiones.

Para empezar el proceso de revisión, se han considerado varios elementos del método PRISMA, se inició por la elaboración del plan de búsqueda, por criterios (inclusión y exclusión), las fuentes de información, y finalmente el proceso de selección de investigaciones.

Se consultaron bases de datos como Scopus, Scielo y Redalyc. Se empleó la ecuación de búsqueda conformada por los términos "Tall Stem Fruit", "tall fruit", "Garden Crops", "Fruit", "Fruit trees" "Computer Vision", "Machine learning", "Image analysis", "Automatic learning" "Prediction", "Crop estimation", "harvest forecast", "Prediction methods", "estimation" "precision", "accuracy", "Harvest accuracy", "Crop harvesting Accuracy", "crop precision tolerance.

Los términos se limitan al período comprendido entre 2020 y 2024. Inicialmente se aplicó la ecuación de búsqueda obteniendo en total 838 artículos de investigación: Scopus 782, Scielo 2 y Redalyc 54. De este total, se eliminó 1 artículo duplicado. Después aplicar los criterios de inclusión (CI) y exclusión (CE) se retiraron 660 artículos. Finalmente, después de una revisión de títulos y resúmenes, se procedieron a retirar 151 artículos debido que no se encontraba disponible la información, no había acceso completo o no cumplía con el objetivo de investigación. Quedando un total de 26 artículos disponibles para revisión.

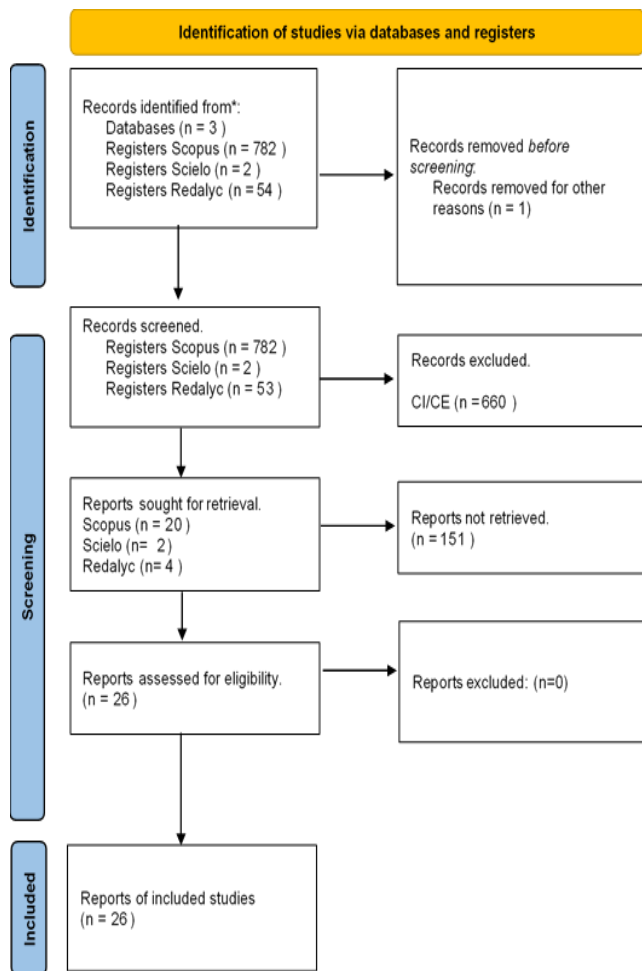


Fig. 1 Diagrama Prisma

### III. RESULTADOS

La información se examinó desde dos perspectivas: bibliométrica y de contenido. La primera ofreció un análisis general de las investigaciones mientras que la segunda profundizó en detalles específicos del tema de investigación.

#### Resultados Bibliométricos

Al iniciar el estudio, se realizó un análisis bibliométrico de cada investigación incluida en la revisión sistemática. La Tabla IV resume la información recopilada: nombres de los autores, títulos de los artículos y el año de publicación.

TABLA IV.  
ARTÍCULOS INCORPORADOS EN LA REVISIÓN SISTEMÁTICA SOBRE LA INFLUENCIA DE LA VISIÓN ARTIFICIAL PARA PREDECIR LA COSECHA DE FRUTOS DE TALLO ALTO EN EL PERÍODO 2020-2024.

Autor (s)	Título del artículo	Año
Ahmed et al. [12]	"Few_shot_learning_for_avocado_maturity_determination_from_microwave_images"	2024

Sandra et al. [13]	"Developing a prediction method for physicochemical characteristics of Pontianak Siam orange (Citrus suhuiensis cv. Pontianak) based on combined reflectance-Fluorescence spectroscopy and artificial neural network"	2024
Dutta et al. [3]	"Zero-shot transfer learned generic AI models for prediction of optimally ripe climacteric fruits"	2023
Torgbor et al. [1]	"Integrating Remote Sensing and Weather Variables for Mango Yield Prediction Using a Machine Learning Approach"	2023
Kang et al. [14]	"Visual perception and modeling for autonomous apple harvesting"	2020
Vijayakumar et al. [15]	"Tree-level citrus yield prediction utilizing ground and aerial machine vision and machine learning"	2023
Arianti et al. [16]	"Classification of Harvesting Age of Mango Based on NIR Spectra Using Machine Learning Algorithms"	2023
Moussaid et al. [17]	"Machine Learning Applied to Tree Crop Yield Prediction Using Field Data and Satellite Imagery: A Case Study in a Citrus Orchard"	2022
Mimma et al. [18]	"Fruits Classification and Detection Application Using Deep Learning"	2022
Boechel et al. [19]	"Prediction of Harvest Time of Apple Trees: An RNN-Based Approach"	2022
Hasanzadeh et al. [20]	"Non-Destructive Detection of Fruit Quality Parameters Using Hyperspectral Imaging, Multiple Regression Analysis and Artificial Intelligence"	2022
Liu et al. [21]	"A Crop Harvest Time Prediction Model for Better Sustainability, Integrating Feature Selection and Artificial Intelligence Methods"	2022
Janowski et al. [22]	"Detecting apples in the wild: Potential for harvest quantity estimation"	2021
Bai et al. [23]	"Comparison of machine-learning and casa models for predicting apple fruit yields from time-series planet imageries"	2021
Scalisi et al. [24]	"Maturity prediction in yellow peach (Prunus persical) cultivars using a fluorescence spectrometer"	2020
Biffi et al. [25]	"Evaluating the performance of a semi-automatic apple fruit detection in a high-density orchard system using low-cost digital RGB imaging sensor"	2021



La base de datos más empleada para la búsqueda de los artículos incluidos fue Scopus, con un total de 20 estudios, mientras que la menos utilizada fue Scielo, con un total de 2, como se evidencia a continuación.




Figura 5. Bases de datos utilizadas en la recopilación de los artículos en la revisión sistemática.

De acuerdo al tipo de estudio de los artículos de investigación, podemos observar que el 65% de las publicaciones contenidas en la RSL fueron estudios de tipo Experimental, mientras que el 35% corresponden a la categoría de estudio de casos en artículos de revisión de tipo descriptiva, tal como se puede visualizar a continuación.

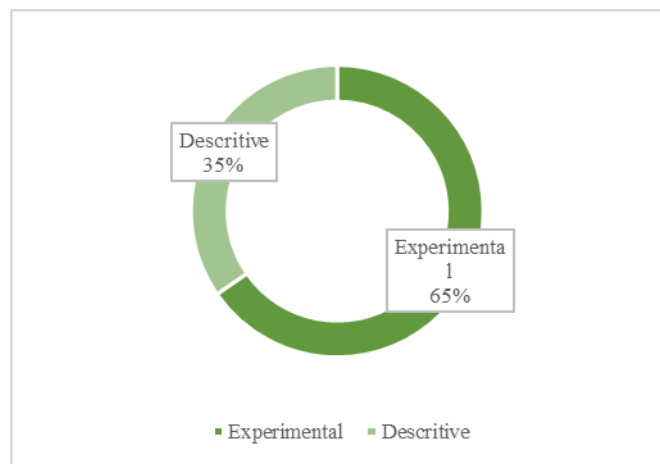


Figura 6. Distribución porcentual de artículos seleccionados según el tipo de estudio.

La mayoría de las publicaciones fueron obtenidas de estudios realizados en Brasil, con un total de 5 estudios, seguido por Australia con 3 estudios. Además, se observa que Cuba, China, Indonesia y Estados Unidos tienen 2 publicaciones cada uno, como se muestra a continuación.



Figura 7. Artículos incluidos en la revisión sistemática según países.

### Resultados por contenido

En esta sección se detallan los resultados del análisis y lectura crítica de los artículos disponibles sobre el uso de los métodos de visión artificial para la predicción de la cosecha de frutos de tallo alto. Se optimiza la información a través de los hallazgos más relevantes, utilizando formularios de extracción que permiten responder las preguntas de investigación planteadas para esta RSL.

### ¿Qué frutos de tallo alto se producen en la agricultura?

Los frutos climatéricos de tallo alto con los que se realizaron los diferentes estudios son: aguacate, naranja Pontianak Siam, plátano, mango, manzana, melocotón entre otros. En este contexto, según el análisis de estudios de los tipos de frutos de tallo alto se confirma el dominio del aguacate como materia prima más utilizada, estos son conocidos por ser botánicamente una baya grande y ovalada, con una textura cremosa y un alto contenido de grasas saludables.

Durante el proceso de cultivo, uno de los mayores desafíos es determinar el momento óptimo para la cosecha, ya que los aguacates maduran después de ser recolectados [12]. Con respecto a las naranjas Pontianak Siam, se destaca por su color y sabor distintivos, tiene un aspecto exterior vibrante y un sabor que equilibra perfectamente el dulzor y la acidez y su proceso de maduración es crítico para garantizar que las naranjas alcancen su calidad óptima antes de ser comercializadas [13]. Por otro lado, los plátanos son frutos climatéricos, lo que significa que continúan madurando después de la cosecha. Durante este proceso, experimentan un

aumento en la respiración y la producción de etileno, lo cual influye en su textura y sabor [31][34].

Otro fruto característico en un estudio es el mango, apreciados por su sabor dulce y jugoso, también son climáticos y requieren condiciones específicas de cultivo y cosecha para maximizar su calidad [16]. Finalmente, las manzanas, que son uno de los frutos más adquiridos a nivel global, presentan una gran diversidad de variedades como (Red Delicious, Golden Delicious y Malus domestica Borkh) estas son conocidas por su textura crujiente y sabor refrescante, el proceso de cultivo y almacenamiento es crucial para mantener su frescura y prolongar su vida útil [20] [23] [25].

En la tabla V, se resumen los frutos de tallo producidos en la agricultura y utilizadas en los artículos seleccionados.

TABLA V.  
FRUTOS DE TALLO ALTO QUE SE PRODUCEN EN LA AGRICULTURA INCLUIDAS EN LA REVISIÓN SISTEMÁTICA.

Frutos de Tallo Alto	Cantidad de estudios
Aguacates [12]	1
Naranjas [13] [15] [17]	3
Plátano [31] [34]	2
Manzana [14] [19] [20] [22] [23] [25] [27] [33]	8
Mango [1] [3] [16]	3
Melocotón [3] [24]	2

*¿De qué manera se utiliza la visión artificial en la agricultura?*

La visión artificial se utiliza en la agricultura involucrando vehículos aéreos no tripulados (UAV), en su mayoría, estos equipos poseen cámaras y sensores instalados que utilizan técnicas de teledetección para supervisar el crecimiento de los cultivos y monitorizar automáticamente las siembras discriminando cultivos y malezas en tiempo real [32].

La espectroscopía es otro método de visión artificial que estudia cómo la radiación electromagnética interactúa con la fruta, dando como resultado la absorción o emisión de energía radiante. Se utiliza principalmente para determinar componentes como azúcares y ácidos del fruto, y para identificar defectos o enfermedades, empleando radiaciones en el rango visible (VIS) entre 400 y 700 nm, y en el infrarrojo cercano (NIR) entre 780 y 2500 nm [30].

Otros estudios aplicaron el sistema de imágenes de microondas (MI) que utiliza 10 antenas Coplanar Vivaldi dispuestas en una configuración circular, con una separación de 36° entre cada antena, lo que permite un campo de visión de 360°, la distancia entre las antenas opuestas se establece en 18 cm para obtener imágenes del fruto de alta calidad y la potencia de transmisión se ajusta a -17 dBm de modo que, envía y recibe señales electromagnéticas. Una vez adquirida la señal de radar, se emplea la Caja de herramientas de imágenes para procesar los datos de escaneo y generar imágenes que son analizadas por un modelo de aprendizaje automático (FSL),

proporcionando información valiosa sobre su estado de maduración [12].

Así también, la detección de objetos en Yolo 1 que se basa en imágenes de drones, seguida de Yolo 2 fusiona estas imágenes con la detección de frutos desde tierra, enfocándose en un lado del árbol y Yolo 3 que mejora esto al detectar frutos desde ambos lados del árbol, utilizando también imágenes de drones. Su aplicación permite identificar defectos en la piel de los cítricos, como manchas o cicatrices, descartando frutos que no cumplen con los estándares de calidad [15]. Es por ello, mediante los diferentes algoritmos se diseña un modelo de reconocimiento de objetivos que va a permitir una mejor detección, además de una identificación y conteo de frutos en

*¿Qué métodos de visión artificial se utilizan actualmente para predecir la cosecha de frutos?*

Existen varios métodos de visión artificial utilizados específicamente para predecir con anticipación la madurez de los frutos. De los artículos científicos incluidos, la mayoría de investigaciones utilizaron sensores de imágenes RGB y el procesamiento de imágenes con espectros NIR. El primer método, utilizó una cámara RGB con 3 canales de color (Red-Green-Blue) para monitorizar y detectar características de color (textura y forma) y descriptores geométricos que permitieron identificar el rendimiento de las frutas en las imágenes capturadas [14][25][28].

Así también, 4 investigaciones utilizaron la espectroscopía del infrarrojo cercano NIR para analizar las características externas e internas del fruto mediante un sistema no destructivo que captura los reflejos de luz infrarrojos para medir la cantidad de longitud de onda reflejada de cada fruto [13][16][17]. Cabe resaltar, que de acuerdo a [24], utilizar espectros NIR en empresas de gran escala, resulta más accesible a diferencia de otros métodos o tecnologías que siguen siendo demasiado costosos.

Otros estudios utilizaron procesamiento de imágenes UAV (vehículo aéreo no tripulado) debido a su capacidad para recopilar datos de alta calidad a nivel de campo en tiempo real [32]. Otros métodos como el uso cámaras hiperespectrales y YOLOv3, son herramientas que han utilizado adicionalmente el aprendizaje automático para mejorar la precisión de sus cálculos, de la misma forma que el modelo prototípico FSL, junto con la clasificación de imágenes por microondas de frutos para evaluar su madurez [12]. Pocas investigaciones aplicaron sensores de imágenes térmicas y detector de cajas múltiples de disparo único.

En la tabla VI, se presenta un resumen de los métodos de visión artificial aplicadas en la predicción de la cosecha utilizadas en los artículos seleccionados.

TABLA VI.  
PRINCIPALES MÉTODOS DE VISIÓN ARTIFICIAL UTILIZADAS EN LA PREDICCIÓN DE COSECHA INCLUIDAS EN LA REVISIÓN SISTEMÁTICA



Métodos de V.A.	Cantidad de estudios
Procesamiento de imágenes con espectros NIR [13] [16] [17] [24]	4
Sensores de imágenes RGB [14] [25] [28] [32]	4
Imágenes de vehículos aéreos no tripulados (UAV) [32] [35]	2
Cámaras hiperspectrales [20] [30]	2
You Only Look Once (YOLOv3) [18] [22]	2
SSD (Detector de cajas múltiples de disparo único) [27]	1
Modelo FSL prototípico[12]	1

En la aplicación de la visión artificial, es importante conocer que todos los métodos mencionados no siempre son aplicables para analizar la madurez de todos los frutos de tallo alto. Según [14] considera que el sensor de imágenes RGB y térmicas son sistemas enfocados en el reconocimiento y codificación de la apariencia física de las frutas. Es decir, su aplicación va orientada a aquellos frutos que tienen en su cáscara coloraciones variadas en todas sus etapas de crecimiento, lo que facilita el análisis de la forma, color y textura del fruto [33]. Se puede incluir frutos tales como el banano, papaya, mango, uva, manzana, entre otras.

Por otra parte, para frutos de tallo alto como la palta, cítricos, y melocotón, que poseen una corteza gruesa, dura y/o de coloración uniforme en todo su crecimiento resulta viable aplicar un modelo FSL prototípico no invasivo que permite obtener ondas electromagnéticas emitidas que se reflejan o pasan a través de la fruta generando imágenes que presentan las propiedades dieléctricas internas de la fruta determinando con eficacia la madurez y calidad interna del alimento [12].

De la misma forma, se utiliza espectrómetros de infrarrojo cercano (NIR), cámaras espectrales que poseen la misma funcionalidad. Para [24], el procesamiento de imágenes con espectros NIR se han adoptado de manera confiable para la estimación de la concentración sólidos solubles de una fruta ya que las longitudes de onda en la región NIR están bien correlacionadas con la absorbancia y reflectancia del agua y los azúcares solubles de los frutos

*¿Qué tan eficiente es la visión artificial para predecir la cosecha de frutos de tallo alto?*

Según el análisis de los estudios científicos incluidos, se evidencia que la aplicación de procesamiento de imágenes con espectro NIR alcanzó una precisión promedio de 93% en la mayoría de investigaciones consultadas. Para [13] la espectrometría NIR utilizó la combinación de espectros de fluorescencia y reflectancia para predecir el grado de madurez y las características fisicoquímicas de las naranjas Pontianak Siam logrando una precisión de entrenamiento de 0,99. y prueba de precisión de 1. Asimismo, se alcanzó una precisión promedio del 92.4% aplicando una propuesta de modelo mejorado de detección de frutas de cajas múltiples de disparo

único SSD en frutas como la manzana, el caqui, la nectarina y la pera [27].

Con respecto al procesamiento de imágenes UAV (vehículos no tripulados) y YOLOv3, obtuvieron una precisión promedio de 90% y 91% respectivamente. [15] mencionó que aplicar UAV y YOLOv3 a un área experimental de aproximadamente 48 árboles cítricos, permitió realizar predicciones entre 4 y 6 meses antes de la cosecha. La precisión promedio más baja en los artículos consultados fue en la aplicación de sensores de imágenes RGB. Este método fue empleado en la predicción de manzanas, donde los resultados muestran que algunas bandas y combinaciones de colores, textura y firmeza permitieron aciertos superiores al 75% [14][25].

Anteriormente, el uso de métodos tradicionales basados solamente en la información histórica de las parcelas y el monitoreo climático, no consiguió exitosos resultados en la estimación del rendimiento de frutos por parcela, obteniendo un error porcentual promedio de 0.4392. Inclusive, se destaca que hay algunas parcelas que obtuvieron calificaciones de hasta el 100% de error. Con la aplicación de métodos de espectrometría, se obtuvieron errores porcentuales promedio que no exceden 0.1629, resultados que brindan datos más precisos y confiables [17].

En el gráfico 9, se presenta un resumen de las precisiones promedios obtenidas en la aplicación de los métodos de V.A. en la predicción de la cosecha.

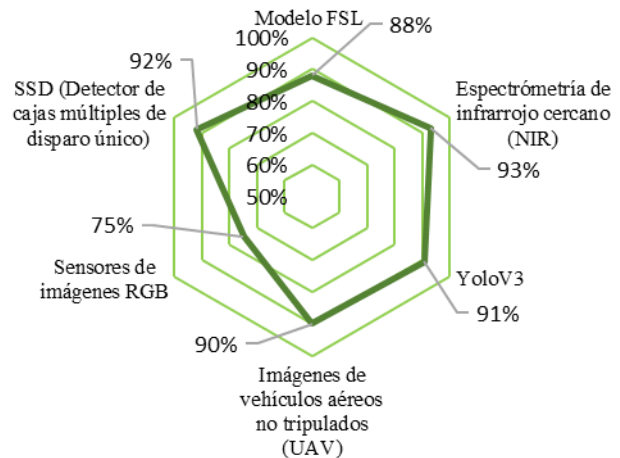


Figura 8. Porcentaje de precisión promedio de acuerdo al método de Visión Artificial aplicada.

Se han evidenciado limitaciones en los procedimientos de estimación de la cosecha. El modelo de detección de frutas YOLOv3 ha demostrado una gran capacidad para identificar cítricos, sin embargo, su eficacia se ve afectada por factores como la oclusión por hojas, las especificaciones de la cámara y las condiciones de iluminación [18]. De acuerdo a [14] los sensores de imágenes RGB no obtuvieron una precisión

mayor, debido que, este sistema solo está enfocado en el análisis externo del fruto, el cual requería obligatoriamente de una iluminación correcta del fruto para identificar las características físicas como variaciones de color y textura.

En adición, las cámaras RGB sólo poseen tres bandas visibles disponibles, lo que da como resultado una capacidad de identificación finita de las condiciones del fruto [28]. Otro factor limitante en las investigaciones fue la ausencia de cámaras de media o alta definición para las demandas específicas en la agricultura, específicamente en la captura de imágenes más detalladas y de alta resolución [32]. Está limitante afectó en gran medida las precisiones identificadas en algunas investigaciones.

#### IV. DISCUSIÓN

La aplicación de sensores de imágenes RGB utilizando reconocimiento de bandas (Red-Green-Blue) para analizar la madurez de las manzanas obtuvo aciertos aproximados al 75% en precisión [25], en comparación con el método de espectroscopia del infrarrojo cercano (NIR), el cual, ha logrado precisiones superiores al 95% en la mayoría de frutos cítricos [13]. En esta diferencia, se puede inferir, que depende en gran medida del tipo de fruto climatérico que se esté analizando, es decir, específicamente a la variación en la pigmentación de la corteza o cascarón en sus etapas de floración hasta la maduración.

En relación a lo anteriormente mencionado, el procesamiento de imágenes RGB solo analiza la madurez basándose en aspectos físicos del fruto, como variaciones de color, tamaños, forma y textura [14]. Por ello, resulta ser más efectivo aplicar este método en aquellos frutos que poseen una corteza con pigmentación variada en su crecimiento tales como el banano, manzana, mango, peras. No obstante, el método (NIR), analizó mediante fluorescencia y/o reflectancia la parte interna y externa del fruto para predecir su calidad identificando variables como la concentración de sólidos solubles (SSC), atributos del color de la piel y firmeza de la pulpa (FF) del fruto [24]. En este contexto, para clasificar perfectamente la edad de cosecha de los mangos en función de las propiedades ópticas del NIR con longitudes de onda de 1000-2500 nm, se obtuvieron precisiones mayores al 95% [16]. Mientras que, para [24] la emisión de fluorescencia para estimar FF y SSC en melocotones amarillos han generado precisiones  $\geq 85\%$ .

Esto quiere decir que, el procesamiento de espectrometría NIR en ambas frutas (mango y melocotón) independientemente de la variación de la pigmentación de la corteza, genera precisiones mayores comparados con el procesamiento de imágenes RGB. Sin embargo, es más viable aplicar este método (NIR) en frutos cuya pigmentación de la corteza sea uniforme en su crecimiento, de lo contrario, continúa siendo efectivo, pero su procedimiento es más complejo comparado con la facilidad de aplicación del procesamiento de imágenes RGB. También se encontró que, al

aplicar drones u otro dispositivo aéreo no tripulado (UAV) junto con sensores de imágenes RGB y/o YOLOv3 han permitido recopilar datos de alta resolución a nivel de campo a tiempo real resultando precisiones superiores al 90% permitiendo realizar predicciones entre 4 y 6 meses antes de la cosecha [15]. Esto sugiere que, al combinar varios métodos de visión artificial es probable que pueda proporcionar datos más detallados y precisos con varios meses de antelación de la cosecha.

#### V. CONCLUSIÓN

El estudio analizó los métodos de visión artificial en la predicción de la cosecha de frutos de tallo alto. Se determinó que, los sensores de imágenes RGB, espectrometría del infrarrojo (NIR), vehículos aéreos no tripulados (UAV) y YOLOv3, demostraron eficiencias superiores al 75% en la predicción de la madurez y calidad de los frutos. De todos ellos, se destaca la aplicación de espectroscopia del infrarrojo cercano (NIR) que alcanza precisiones superiores al 95% en frutos de tallo alto, mientras que el uso de sensores de imágenes RGB solo han obteniendo precisiones aproximadas al 75%.

El método NIR ofrece mayores precisiones independientemente de la pigmentación de la corteza del fruto, pero su aplicación es más compleja. Por otro lado, el método RGB, aunque menos preciso, es más sencillo y viable para ciertos tipos de frutos con pigmentación variada. Los métodos de visión artificial, a través del análisis y procesamiento de imágenes digitales y espectroscopia en tiempo real, han demostrado ser eficaces para capturar propiedades internas y externas de los alimentos en maduración y realizar un seguimiento continuo de su proceso de maduración. Por lo tanto, se debe tener en cuenta, que la aplicación de estos métodos está limitada principalmente por las diversas variedades que existen de un fruto climatérico en específico.

Para futuras investigaciones, se sugiere profundizar en métodos de visión artificial que utilicen adicionalmente tecnologías basadas en otros tipos de inteligencia artificial que evalúen la predicción de cosecha considerando diferentes condiciones climáticas y el grado de maduración del fruto. Asimismo, se sugiere investigar la viabilidad del proceso de visión artificial para usarse en pequeñas comunidades de agricultores. Para que, con su implementación, proporcione a los agricultores herramientas precisas y económicas para estimar la producción de sus cultivos, optimizar la planificación agrícola y maximizar los beneficios económicos.

#### REFERENCIAS

- [1] B. A. Torgbor, M. M. Rahman, J. Brinkhoff, P. Sinha, and A. Robson, "Integrating Remote Sensing and Weather Variables for Mango Yield Prediction Using a Machine Learning Approach," *Remote Sens (Basel)*, vol. 15, no. 12, 2023, doi: 10.3390/rs15123075.

- [2] E. Elbasi *et al.*, “Artificial Intelligence Technology in the Agricultural Sector: A Systematic Literature Review,” *IEEE Access*, vol. 11, 2023, doi: 10.1109/ACCESS.2022.3232485.
- [3] J. Dutta, M. Patwardhan, P. Deshpande, S. Karande, and B. Rai, “Zero-shot transfer learned generic AI models for prediction of optimally ripe climacteric fruits,” *Sci Rep*, vol. 13, no. 1, 2023, doi: 10.1038/s41598-023-34527-8.
- [4] M. E. Suárez, “Wichi plant morphology: an ethnobiological study,” *Revista del Museo de Antropología*, vol. 13, no. 3, pp. 443–458, 2020, doi: 10.31048/1852.4826.V13.N3.27844.
- [5] F. J. Bucio, C. Isaza, E. Gonzalez, J. P. Z. De Paz, J. A. R. Sierra, and E. K. A. Rivera, “Non-Destructive Post-Harvest Tomato Mass Estimation Model Based on Its Area via Computer Vision and Error Minimization Approaches,” *IEEE Access*, vol. 10, 2022, doi: 10.1109/ACCESS.2022.3203348.
- [6] V. G. Dhanya *et al.*, “Deep learning based computer vision approaches for smart agricultural applications,” *Artificial Intelligence in Agriculture*, vol. 6, 2022, doi: 10.1016/j.aiia.2022.09.007.
- [7] O. E. Apolo-Apolo, J. Martínez-Guanter, G. Egea, P. Raja, and M. Pérez-Ruiz, “Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV,” *European Journal of Agronomy*, vol. 115, Apr. 2020, doi: 10.1016/j.eja.2020.126030.
- [8] R. L. Alarcón, “Diseño de sistema automático de clasificación de paltas por visión artificial,” Oct. 2021.
- [9] C. I. Belupú Amaya, “Propuesta de una plataforma de agricultura inteligente basada en IoT para el monitoreo de las condiciones climáticas del cultivo de banano,” *Universidad de Piura*, 2022.
- [10] MIDAGRI, “Perú pierde el 35% de su producción de frutas y hortalizas para el mercado interno por fallas en la cadena de producción,” *Agencia Agraria de Noticias*, Perú, Sep. 19, 2022.
- [11] M. J. Page *et al.*, “The PRISMA 2020 statement: An updated guideline for reporting systematic reviews,” *The BMJ*, vol. 372, BMJ Publishing Group, Mar. 29, 2021, doi: 10.1136/bmj.n71.
- [12] M. Ahmed *et al.*, “Few shot learning for avocado maturity determination from microwave images,” *J Agric Food Res*, vol. 15, 2024, doi: 10.1016/j.jafr.2024.100977.
- [13] Sandra *et al.*, “Developing a prediction method for physicochemical characteristics of Pontianak Siam orange (*Citrus suhuiensis* cv. Pontianak) based on combined reflectance-Fluorescence spectroscopy and artificial neural network,” *Talanta Open*, vol. 9, 2024, doi: 10.1016/j.talo.2024.100303.
- [14] H. Kang, H. Zhou, and C. Chen, “Visual perception and modeling for autonomous apple harvesting,” *IEEE Access*, vol. 8, 2020, doi: 10.1109/ACCESS.2020.2984556.
- [15] V. Vijayakumar, Y. Ampatzidis, and L. Costa, “Tree-level citrus yield prediction utilizing ground and aerial machine vision and machine learning,” *Smart Agricultural Technology*, vol. 3, 2023, doi: 10.1016/j.atech.2022.100077.
- [16] N. D. Arianti, M. Muslih, C. Irawan, E. Saputra, Sariyusda, and R. Bulan, “Classification of Harvesting Age of Mango Based on NIR Spectra Using Machine Learning Algorithms,” *Mathematical Modelling of Engineering Problems*, vol. 10, no. 1, 2023, doi: 10.18280/MMEP.100123.
- [17] A. Moussaid *et al.*, “Machine Learning Applied to Tree Crop Yield Prediction Using Field Data and Satellite Imagery: A Case Study in a Citrus Orchard,” *Informatics*, vol. 9, no. 4, 2022, doi: 10.3390/informatics9040080.
- [18] N. E. A. Mimma, S. Ahmed, T. Rahman, and R. Khan, “Fruits Classification and Detection Application Using Deep Learning,” *Sci Program*, vol. 2022, 2022, doi: 10.1155/2022/4194874.
- [19] T. Boechel, L. M. Policarpo, G. de O. Ramos, R. da Rosa Righi, and D. Singh, “Prediction of Harvest Time of Apple Trees: An RNN-Based Approach,” *Algorithms*, vol. 15, no. 3, 2022, doi: 10.3390/a15030095.
- [20] B. Hasanzadeh, Y. Abbaspour-Gilandeh, A. Soltani-Nazarloo, M. Hernández-Hernández, I. Gallardo-Bernal, and J. L. Hernández-Hernández, “Non-Destructive Detection of Fruit Quality Parameters Using Hyperspectral Imaging, Multiple Regression Analysis and Artificial Intelligence,” *Horticulturae*, vol. 8, no. 7, 2022, doi: 10.3390/horticulturae8070598.
- [21] S. C. Liu, Q. Y. Jian, H. Y. Wen, and C. H. Chung, “A Crop Harvest Time Prediction Model for Better Sustainability, Integrating Feature Selection and Artificial Intelligence Methods,” *Sustainability (Switzerland)*, vol. 14, no. 21, 2022, doi: 10.3390/su142114101.
- [22] A. Janowski, R. Kaźmierczak, C. Kowalczyk, and J. Szulwic, “Detecting apples in the wild: Potential for harvest quantity estimation,” *Sustainability (Switzerland)*, vol. 13, no. 14, 2021, doi: 10.3390/su13148054.
- [23] X. Bai *et al.*, “Comparison of machine-learning and casa models for predicting apple fruit yields from time-series planet imageries,” *Remote Sens (Basel)*, vol. 13, no. 16, 2021, doi: 10.3390/rs13163073.
- [24] A. Scalisi, D. Pelliccia, and M. G. O’connell, “Maturity prediction in yellow peach (*Prunus persica* l.) cultivars using a fluorescence spectrometer,” *Sensors (Switzerland)*, vol. 20, no. 22, 2020, doi: 10.3390/s20226555.
- [25] L. J. Biffi, E. A. Mitishita, V. Liesenberg, J. A. S. Centeno, M. B. Schimalski, and L. Rufato, “Evaluating the performance of a semi-automatic apple fruit detection in a high-density orchard system using low-cost digital rgb imaging sensor,” *Boletim de Ciências Geodésicas*, vol. 27, no. 2, 2021, doi: 10.1590/s1982-21702021000200014.
- [26] M. A. Lee, A. Monteiro, A. Barclay, J. Marcar, M. Miteva-Neagu, and J. Parker, “A framework for predicting soft-fruit yields and phenology using embedded, networked microsensors, coupled weather models and machine-learning techniques,” *Comput Electron Agric*, vol. 168, 2020, doi: 10.1016/j.compag.2019.105103.
- [27] J. Cai, J. Tao, Y. Ma, X. Fan, and L. Cheng, “Fruit image recognition and classification method based on improved single shot multi-box detector,” in *Journal of Physics: Conference Series*, 2020, doi: 10.1088/1742-6596/1629/1/012010.
- [28] E. Vrochidou, C. Bazinas, M. Manios, G. A. Papakostas, T. P. Pachidis, and V. G. Kaburlasos, “Machine vision for ripeness estimation in viticulture automation,” *Horticulturae*, vol. 7, no. 9, 2021, doi: 10.3390/horticulturae7090282.
- [29] B. V. C. Guimarães *et al.*, “Digital platform for experimental and technical support to the cultivation of cactus pear,” *Acta Sci Agron*, vol. 45, 2023, doi: 10.4025/actasciagron.v45i1.57407.
- [30] A. C. Silveira, S. Rodríguez, R. Kluge, L. F. Palaretti, C. Inestroza, and V. H. Escalona, “Non-destructive techniques for mitigating losses of fruits and vegetables,” *Agrociencia Uruguay*, vol. 25, no. E2, 2021, doi: 10.31285/AGRO.25.850.
- [31] H. V. Cevallos, H. C. Romero, S. B. Unda, V. Cevallos, C. Romero, and & Barrezueta, “APPLICATION OF AUTOMATIC LEARNING ALGORITHMS TO CLASSIFY THE FERTILITY OF A BANANA SOIL.”
- [32] J. P. Molin, H. C. Bazame, L. Maldaner, L. de P. Corredo, M. Martello, and T. F. Canata, “Precision agriculture and the digital contributions for site-specific management of the fields,” *REVISTA CIÊNCIA AGRONÔMICA*, vol. 51, no. 5, 2020, doi: 10.5935/1806-6690.20200088.
- [33] G. A. S. Megeto, A. G. da Silva, R. F. Bulgarelli, C. F. Bublitz, A. C. Valente, and D. A. G. da Costa, “Artificial intelligence applications in the agriculture 4.0,” *REVISTA CIÊNCIA AGRONÔMICA*, vol. 51, no. 5, 2020, doi: 10.5935/1806-6690.20200084.
- [34] J. A. Guzman-Alvarez, M. González-Zuñiga, J. A. S. Fernandez, and J. C. Calvo-Alvarado, “Use of remote sensing in agriculture: Applications in banana crop,” *Agronomía Mesoamericana*, 2022.
- [35] R. Pérez *et al.*, “Universidad Agraria de La Habana Application of drones in international and Cuban agriculture. A review Revista Ciencias Application of drones in international and Cuban agriculture. A review Aplicación de drones en la agricultura internacional y cubana. Revisión,” *Técnicas Agropecuarias*, vol. 33, no. 1, p. 7, 2024.