



Implementaciones de selección visual en frutas: una revisión sistemática de literatura

Visual selection in fruits: a systematic literature review

Parraga-Badillo, Saúl Ricardo^{1*}

Coral-Ygnacio, Marco Antonio¹

¹Universidad Católica Sedes Sapientiae, Lima, Perú

Recibido: 09 Sep. 2023 | **Aceptado:** 12 Oct. 2023 | **Publicado:** 10 Ene. 2024

Autor de correspondencia*: saulricardo09@gmail.com

Cómo citar este artículo: Parraga-Badillo, S. R. & Coral-Ygnacio, M. A. (2024). Implementaciones de selección visual en frutas: una revisión sistemática de literatura. *Revista Científica de Sistemas e Informática*, 4(1), e591. <https://doi.org/10.51252/rcsi.v4i1.591>

RESUMEN

La visión artificial tiene una participación importante en el sector agrícola debido a las soluciones que proporciona mediante el reconocimiento de imágenes de frutos considerando su color y forma. El problema es la dificultad en la evaluación de la calidad del fruto, siendo realizado por personas que cometen errores al realizar la selección manual, ya que se involucra el aspecto subjetivo y sus capacidades de percepción. Siendo necesario implementar sistemas de este tipo, se desarrolló una revisión sistemática de literatura utilizando la metodología PRISMA, el cual busca identificar los algoritmos, modelos, dispositivos informáticos, librerías o software vigentes que son utilizados en implementaciones de visión artificial para la fruta. Los resultados evidencian 32 algoritmos, 32 equipamientos informáticos, 35 modelos, 8 librerías o software que posibilita la realización de implementaciones para la selección visual. En síntesis, la visión artificial impacta significativamente en la selección y clasificación de frutas al mejorar la eficiente, reducir el trabajo manual y acelerar el tiempo de selección. Este avance no solo contribuye a la agricultura precisa, sino que también promueve la sostenibilidad al optimizar los procesos y mejorar la calidad de productos, obteniendo un importante en la unión de la tecnología con la agricultura.

Palabras clave: agrícola; algoritmos; dispositivos informáticos; frutos; reconocimiento de imágenes; visión artificial

ABSTRACT

Artificial vision has an important participation in the agricultural sector due to the solutions it provides through the recognition of images of fruits considering their color and shape. The problem is the difficulty in evaluating the quality of the fruit, being done by people who make errors when performing manual selection, since the subjective aspect and their perception abilities are involved. Being necessary to implement systems of this type, a systematic literature review was developed using the PRISMA methodology, which seeks to identify the current algorithms, techniques, computing devices, libraries or software that are used in artificial vision implementations for fruit. The results show 32 algorithms, 32 computer equipment, 35 models, 8 libraries or software that make it possible to carry out implementations for visual selection. In summary, artificial vision significantly impacts fruit selection and classification by improving efficiency, reducing manual work and accelerating selection time. This advance not only contributes to precise agriculture, but also promotes sustainability by optimizing processes and improving the quality of products, achieving an important role in the union of technology with agriculture.

Keywords: agriculture; algorithms; computing devices; fruits; image recognition; artificial vision



1. INTRODUCCIÓN

Las implementaciones de visión artificial (VA) sirven para reconocer objetos a partir de técnicas de inteligencia artificial mediante imágenes adquiridas por cámaras de alta resolución y que posteriormente son convertidos en datos para ser analizados como información e identificar objetos. La importancia de estos sistemas radica en la precisión de la identificación.

La aplicación de VA sirve en situaciones reales como el siguiente: el consumidor de productos alimenticios que al observar defectos en la superficie de cualquier fruta asocia a la calidad de producto, por ello, identificar un método de rigor, donde se evalúe la producción es complicado, solo los expertos evalúan visualmente la calidad del fruto (Álvarez-Bermejo et al., 2019); esta evaluación abarca tiempo y costos en producción, además los trabajadores con menor experiencia suelen equivocarse al clasificar los frutos (Mazzia et al., 2020); por ese motivo, se hace necesario realizar una implementación con VA para frutas.

La VA y su aplicación a nivel industrial demuestran eficacia al ser una técnica innovadora puesto que se utilizan técnicas de procesamiento, modelos de clasificación/regresión para la calificación de productos y estimación de distintas características de frutas (Palumbo et al., 2023), debido a que se necesita contar con una mejora en el método de producción de frutas con calidad durante la fabricación y comercialización basado en inspección visual realizada por la computadora (Castro et al., 2019).

En el próximo decenio la producción agrícola crecerá en un 1,4% anual en el ámbito nacional, regional y mundial, impulsando en gran medida los ingresos de las empresas (FAO, 2020), de tal manera que el sector alimentario se beneficia con la evolución tecnológica que permite la automatización de recursos en la categorización de imágenes, que resulta importante para la industria donde se reconoce parámetros básicos como la efectividad y rapidez (Aguilar Alvarado & Campoverde Molina, 2019).

Durante los últimos años comenzaron a aparecer estudios que aplican técnicas asociadas a la VA en el sector agrícola, ya que se busca obtener distintos mecanismos automatizados que proporcionen mejora en la toma de decisiones dentro de la industria (Marco-Detchart et al., 2023); con distintos dispositivos que permiten el funcionamiento correcto de la implementación de VA junto a algoritmos especializados en aprendizaje automático que funcionan en plataformas especiales enfocadas en temas de inteligencia artificial. También, se encontraron trabajos asociados a la mejora de algoritmos que permiten incrementar la precisión en la detección de objetos en tiempo real (Adeniji et al., 2022) y obtener una mayor calidad en la segmentación de imágenes y características, demostrando grandes avances en las aplicaciones de VA.

El objetivo del presente trabajo se enfoca en la identificación de algoritmos y modelos utilizados en las implementaciones de VA para las frutas; además, se identifican las de mejor precisión; asimismo se busca identificar dispositivos informáticos, librerías o software que son utilizados o empleados en el proceso de visión por computadora.

2. MATERIALES Y MÉTODOS

Para el desarrollo de la revisión sistemática de literatura se consideraron las fases propuestas por los autores de la declaración PRISMA (Liberati et al., 2009), enfoque que fue empleado en la investigación científica para dar inicio a la revisión asociada al campo de la VA, lo cual determina el desarrollo de los siguientes pasos: planteamiento del título, elaboración del resumen estructurado, la justificación, los objetivos, el protocolo y registro, los criterios de elegibilidad, las fuentes de información, la búsqueda, la selección de estudios y la recopilación de datos.

2.1. Objetivos

En esta investigación, se buscó lograr determinados objetivos específicos que orienten el estudio hacia el tema tratado donde se realice la identificación de algoritmos y modelos de inteligencia artificial con

óptimos rendimientos, esto abarca el análisis de las mejores prácticas para su implementación dentro de la industria agrícola; asimismo, se buscó reconocer dispositivos informáticos utilizados y librerías o software de VA disponibles hasta este año para la selección de frutas.

Estos objetivos tienen como finalidad responder las siguientes preguntas:

Q1: ¿Qué algoritmos de selección visual han sido utilizados para la selección de frutas?

Q2: ¿Qué equipamiento informático se utiliza en las implementaciones de visión por computadora para la selección de fruta?

Q3: ¿Qué modelos de Inteligencia Artificial se utilizan para la descripción y detección de características de las frutas?

Q4: ¿Qué modelo de Inteligencia Artificial ha tenido el mejor resultado con respecto a la descripción y detección de características de las frutas?

Q5: ¿Qué algoritmos de selección visual tienen una mejor performance en la selección de frutas?

Q6: ¿Qué librerías o software de visión por computadora existen para la selección visual de frutas?

2.2. Fuentes de información

Las bases de datos científicas consultadas fueron Scopus e IEEE Xplore, siendo las más indicadas, ya que proporcionan publicaciones con estudios exhaustivos en diversos idiomas, confiables y de alta calidad que proporciona información relevante y actualizada evaluados y aprobados por expertos en el campo.

2.3. Búsqueda

Esta fase es importante, al permitir que se identifiquen los estudios relevantes para la revisión sistemática. Una adecuada elección de palabras clave nos garantizó la identificación de estudios pertinentes asociados al tema. En la siguiente cadena de búsqueda, se consideraron palabras clave que provienen de los objetivos establecidos anteriormente, adicional a ello, se tiene en cuenta los operadores lógicos OR, que permite la unión de palabras clave por cada objetivo señalado y el conector AND que vincula el grupo de palabras clave que ayuda a limitar la búsqueda para posteriormente utilizar en los buscadores de las bases de datos.

Tabla 1.

Cadena de búsqueda

Acción	Operadores y palabras clave
Cadena de búsqueda utilizada en buscadores de Base de Datos	(("selection" OR "choise" OR "classification") AND ("computer vision" OR "artificial vision" OR "visual identification" OR "image processing") AND ("sowing" OR "plant" OR "field" OR "fruit" OR "avocado") AND ("algorithms") AND ("devices IT" OR "IT equipment" OR "hardware") AND ("implementations" OR "packages" OR "software" OR "libraries") AND ("techniques" OR "methods" OR "models") AND ("artificial intelligence" OR "IA"))

2.4. Selección de Estudio

En este paso se realiza el proceso de identificación y filtrado respectivo de los artículos científicos encontrados y que son relevantes dentro del trabajo de investigación. Este paso permite garantizar la respuesta a las interrogantes y obtener información pertinente para el estudio de implementación de la VA.

En la Figura 1, se observa que dentro de la selección de estudio se realizan varios pasos. En primer lugar, dentro del proceso de identificación, se inició la búsqueda de la literatura en las bases de datos señaladas previamente el día 7 de octubre del 2023, donde se obtuvieron 9 069 registros en total. Esta cantidad de registros son filtrados mediante los criterios de exclusión que indica que no se aceptan artículos en prensa, documentos de conferencia, revisiones, libros, capítulos de libros, encuestas cortas, editoriales, documento

de datos, notas, letras y retraídos; además se excluyeron áreas que no abarquen Ciencias de la Computación, Ingeniería y Agricultura, esto para retirar aquellas investigaciones que no estén relacionados al tema y que tengan palabras clave.

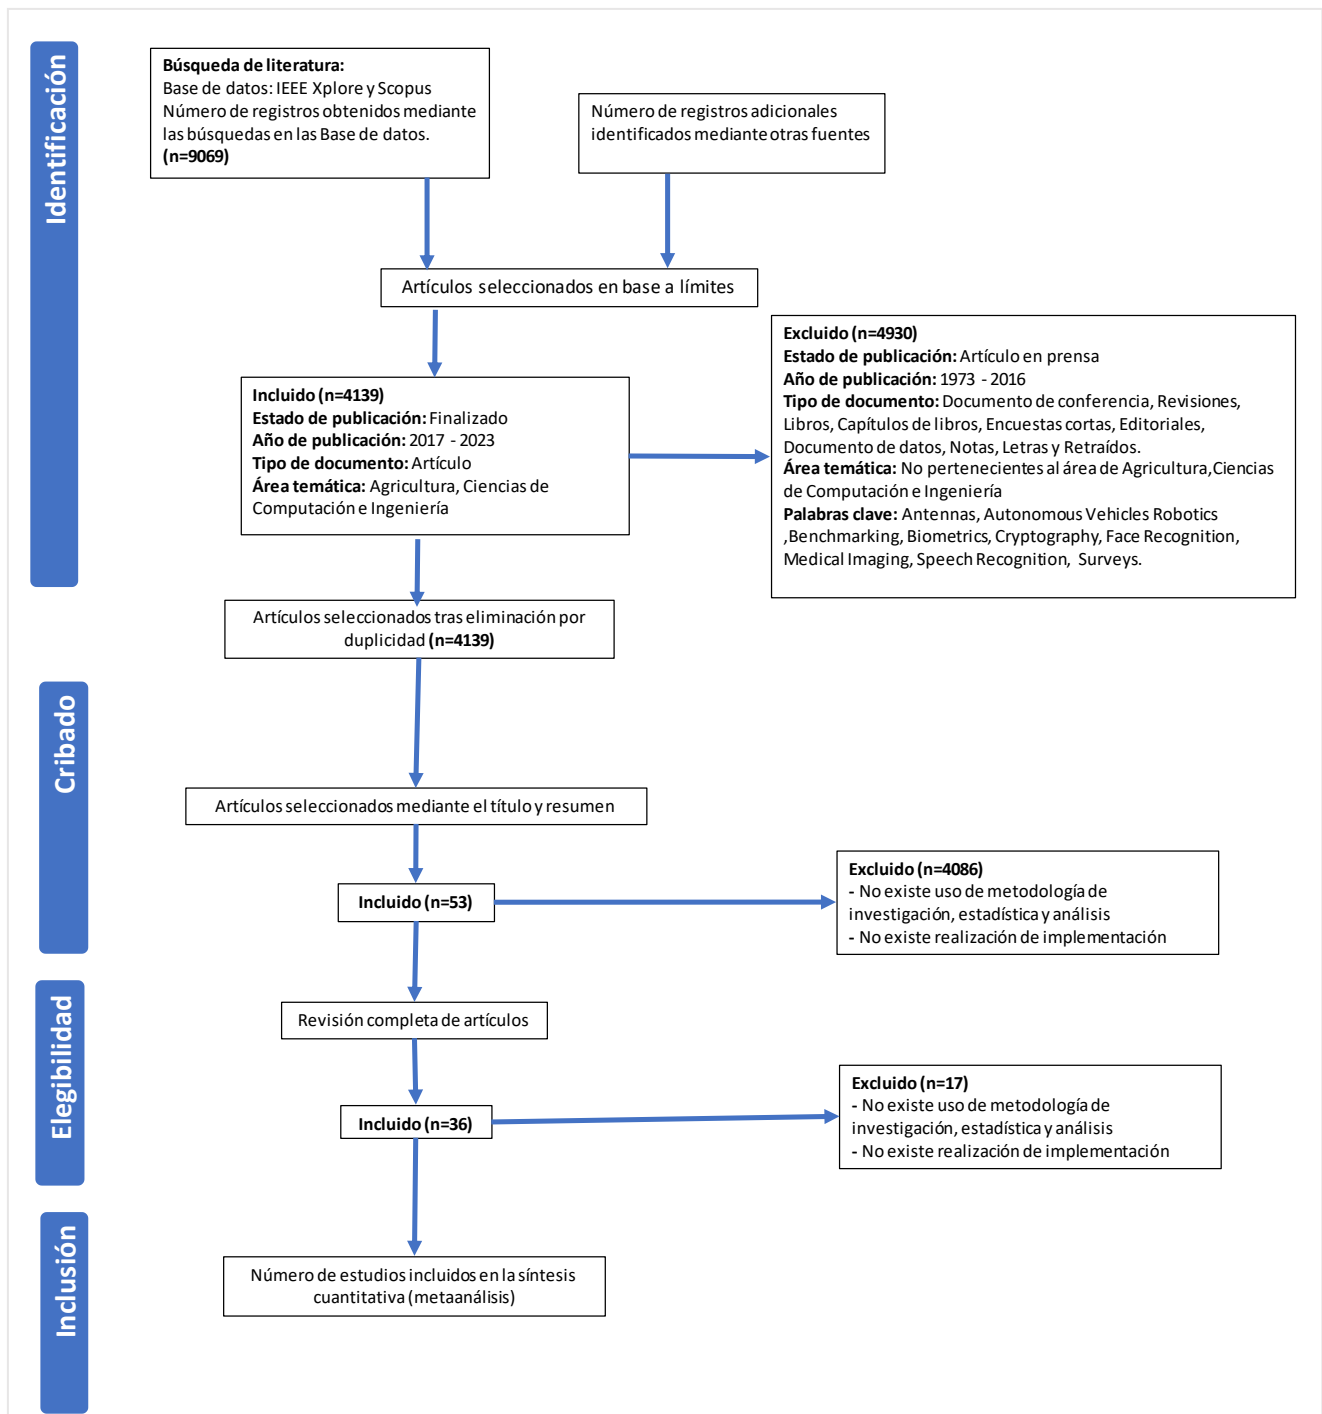


Figura 1. Diagrama de flujo de la revisión sistemática

Estos criterios de exclusión permiten retirar 4 930 registros quedando 4 139 registros con los criterios de inclusión que determinó la inclusión de artículos con estados de publicación finalizados con una unidad de análisis que involucre implementaciones de selección de frutas, donde se logre identificar modelos, algoritmos y dispositivos de tecnologías de la información desde el año 2017 hasta la actualidad. Después de las restricciones aplicadas, no se aplica la eliminación de trabajos de investigación duplicados, porque no aplica su existencia. En segundo lugar, está el proceso de Cribado, que consta la lectura del título y resumen de cada artículo filtrado. En este paso, se detectan solamente 53 artículos que cumplen con lo

indicado; mientras que los otros 4 086 trabajos fueron descartados. En tercer lugar, dentro del proceso de Elegibilidad, se realiza la revisión completa del texto de cada documento, obteniendo un total 36 estudios que cumplen la condición; en contraste 17 escritos fueron anulados debido a la inexistencia de implementaciones o metodologías de investigación, estadísticas o análisis asociados a la temática que se realiza en la revisión sistemática. Por último, en el proceso de inclusión, como su nombre lo indica se incluyen los estudios asociados a reconocimiento de distintos tipos de frutas expuestos en el artículo de revisión.

2.5. Recopilación de datos

Al obtener los artículos filtrados, se comenzó con el análisis cuantitativo en figuras y tablas estadísticas que se organizan de la siguiente manera:

La Tabla 2 muestra las palabras clave más utilizadas que se obtienen al analizar las palabras clave que nos proporciona cada artículo, se realiza el conteo de palabras donde se obtuvieron términos clave que aportan en la investigación. Las palabras clave Deep learning e Image processing son términos muy relevantes en la investigación, esto nos permite señalar que se exploran áreas en la detección y análisis de imágenes con técnicas de aprendizaje profundo. Asimismo, se tiene que Fruit detection, Object detection y YOLO está relacionada con la identificación y seguimiento de frutas con modelos de detección. En contraste, se encuentran los términos con menor frecuencia como 3D imaging, Adaptive hue threshold (AHT), etc. que son temas con enfoque secundario en el artículo. La lista nos presenta una diversidad de términos y áreas de la inteligencia artificial que brinda una visión general del tema, permitiendo inferir que se el trabajo está centrado en aplicación de técnicas de VA y aprendizaje automático que posibilitan la mejora en la precisión y eficiencia en el reconocimiento de imágenes.

Tabla 2.

Palabras clave más usadas

Palabras clave	Frecuencia
Deep learning, image processing	6
Computer vision, fruit detection, Machine learning, object detection, YOLO	3
Apple detection, Apple growth, Artificial intelligence, Convolutional neural network, edge detection, fruit horizontal diameter estimation, fruit maturity, harvesting robots, image classification, K-nearest neighbors, ResNet-50, Support vector machine, remote monitoring	2
3D imaging, Adaptive hue threshold (AHT), and value (HSV) space, Apple bruise grading, apple sorting system, artificial neural networks, avocado, balance between saturation and luminance, Cameras, Cape gooseberry, citrus fruit diseases detection, Citrus leaf diseases, Classification, Climacteric fruit, CNN classifier, cocoa farmers, Color, color detection, Color features, color image segmentation, color spaces, complicated environment, Continuous picking, Co-occurrence matrix, curve fitting, Data augmentation, date fruit, decision trees, deforestation, depth image, digital storage, Direct methods, Disc method, Disorder detection, drought prevision, Edge AI, EfficientNet, faster RCNN, feature selection, Firmness, Food grading, food measurement, food storage, food technology, fresh fruit bunch, fruits, frustum method, graph segmentation, grasping, Hass, Homography, hue, Hyperparameter tuning, hyperspectral imaging, hyperspectral imaging (HSI), image alignment, image process, Image segmentation, Industry 4.0, information fusion, Internet of things (IoT), knowledge distillation, Lasso regressions, lightweight network, load cell, location detection of fruit-bearing branches, low-cost smart agriculture, Machine learning models, machine vision, Machine vision system, Machine vision systems, Machinery, maturity, mechanical harvesting, Model validation, Modern agriculture, modified YOLOv4, morphology, multi-camera, multiclass confusion matrix, multi-class detection, multi-modal visual data, multi-modality faster R-CNN, Nearest neighbor search, non-destructive methods, oil palm, oil palm ripeness, online detection, PCA, Picking robot, post-harvest, Postharvest technology, predicate optimization, Procrustes analysis, Raspberry Pi, real-time counting, real-time detection, real-time embedded systems,	1

reinforcement learning, remote sensors monitoring, RGB-D image, RGB-D sensor, ripening, ripening classification, robotic arm, robots, saturation, Sensors, SITS, size measuring, smart electronics, Smart farming, smartphones, smart-phone cameras, socio-technical transition, sorting, speed and accuracy, starfruit mass, starfruit volume, stereo vision, support vector machines, Support vector regression, Support vector regression(SVR), Target fruit, Textural feature, Tomatoes sorting, transfer learning, U-NET, water resources forecasting, Watermelon internal quality, YOLO-Light, YOLOMuskmelon, YOLOv3, YOLOv4, YOLOv5, YOLOv5s, Zanthoxylum bugeanum fruit detection

De los artículos seleccionados en el estudio, se observa en la Figura 2, la existencia de varias publicaciones que se ubican en el Quartil 1 (Q1) lo cual indica que hay un número significativo de publicaciones de alta calidad y su alto factor de impacto; en contraste se tienen pocas publicaciones en el Quartil 2(Q2), Quartil 3 (Q3), y el Quartil 4 (Q4), donde se refleja un impacto bajo y poca influencia en el tema de investigación. Estos resultados sugieren que existe un enfoque en la calidad de las publicaciones, pero también hay espacio para la difusión de conocimientos en revistas y conferencias de menor reconocimiento.

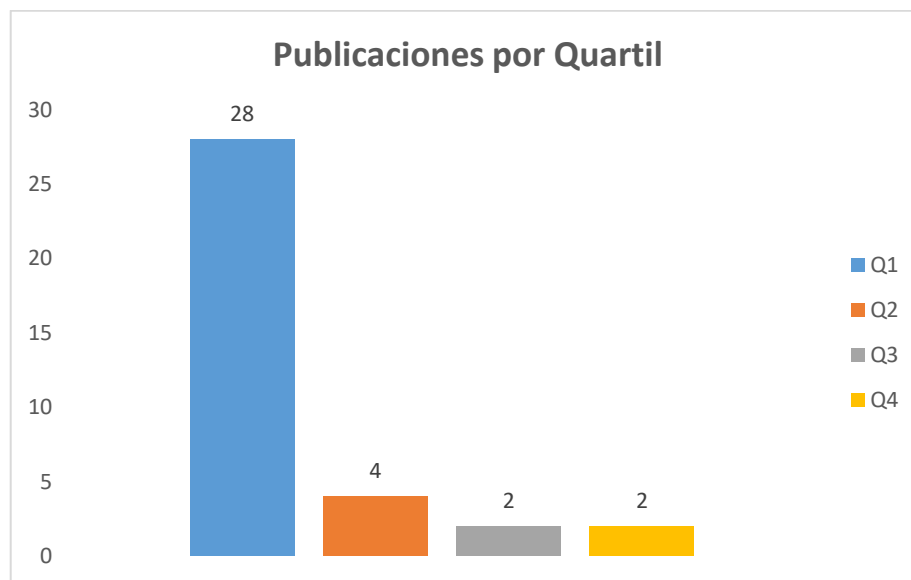


Figura 2. Cantidad de publicaciones por quartil

La Figura 3 se obtuvo a partir de una revisión de la nacionalidad de los autores que tiene cada artículo, esto permite descubrir el interés de investigación que tiene el representante de cada país, donde China tiene la mayor capacidad de participantes, lo que indica un significativo enfoque en la investigación y dedicación; seguido se tiene a Italia ocupando el segundo lugar con 10 autores académicos, que demuestra interés creciente en el tema de investigación; mientras que Bangladesh, Canadá, Emiratos Árabes Unidos, Irán y Rusia tienen poco interés por el tema de investigación. Estos hallazgos resaltan el valor y la cantidad de investigadores en distintas partes del mundo.



Figura 3. Número de investigadores por país

En la Figura 4, la editorial que presentó la mayor cantidad de publicaciones relacionado al tema de investigación fue Institute of Electrical and Electronics Engineers (IEEE), luego se tiene a la editorial Multidisciplinary Digital Publishing (MDPI) como una de las editoriales que se enfocan en el estudio. En tanto que, Springer, De Gruyter Open Ltd. y otras editoriales son aquellas que cuentan con pocas publicaciones con respecto al tema de investigación. Esto nos permite indicar que cada editorial presenta una amplia gama de conocimientos y avances en el campo, lo que demuestra el interés e importancia de la investigación en la comunidad científica y/o académica.

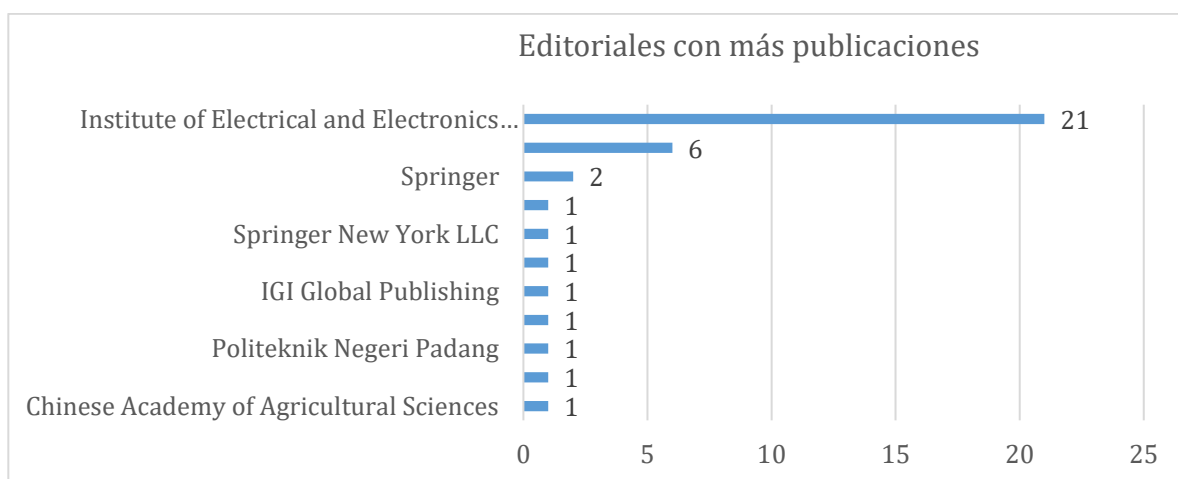


Figura 4. Editoriales con mayor cantidad de publicaciones

En la Figura 5 se observa los diez mayores artículos citados por cada autor, por un lado, los artículos de Khriji et al. (2020), Adhitya et al. (2020), Wu et al. (2021) y D. Chen et al. (2021) son los más citados en el tema de investigación sobre la selección de paltas. Estos artículos tienen un mayor interés; por el contrario, artículos como Cho et al. (2021), Ferraris et al. (2023) y Lee et al. (2023), obtienen poca atención en el contexto del estudio. Estos resultados indican que los autores con mayores citas aportaron con su estudio, siendo los más referenciados por la comunidad científica.




Figura 5. Top 10 cantidad de artículos citados por autor

3. RESULTADOS Y DISCUSIÓN

3.1. Imágenes digitales y su clasificación

Las imágenes digitales están compuestas por píxeles, siendo la unidad mínima de la imagen, esto se debe a que a la imagen está definida como una función en dos dimensiones " $f(x,y)$ " donde " f " representa la intensidad del color gris; mientras que el valor " x " y el valor " y " son las coordenadas del plano (Constante, 2012). Por eso, al pasar la información del objeto del plano tridimensional al bidimensional se convierte en una imagen digital que es capturada por dispositivos que cuenten con un lente especial. Esta imagen digitalizada y cuantificada se presenta mediante una matriz numérica en el cual se ubican los píxeles ubicados en pares ordenados " $f(x,y)$ " donde cada información obtenida de cada píxel de una imagen se le categoriza como se observa en la Tabla 3 (Heras, 2017):

Tabla 3.

Categorías de imagen

Tipo de imagen	Descripción
Imágenes bitonales	Son imágenes estructuradas basadas en dos colores, negro con un valor de 0 y el blanco con un valor de 255.
Imágenes en escala de grises	Son imágenes estructuradas en base a una diversidad de 256 niveles de grises.
Imágenes a color	Son imágenes estructuradas en base en tres distintas matrices del tipo monocromático con 256 niveles representativos de los colores primarios: rojo, verde y azul.

3.2. La visión artificial

La visión artificial es una ciencia que permite programar a la computadora de tal modo que realice el procesamiento y comprensión de las imágenes digitales. Esta tecnología posibilita lograr satisfacer las expectativas del consumidor de manera rigurosa y veloz (Valdivia Arias, 2016), su utilidad se basa en procesar las imágenes y analizarlas teniendo en cuenta su color y figura del objeto (Amaya-Zapata et al., 2016). Esta ciencia, presenta, por un lado, tres beneficios como la rapidez, exactitud y repetitividad al procesar imágenes con determinadas estructuras; esto dependerá mucho del funcionamiento de la cámara con resolución adecuada, (Augusto, 2020) dado que al capturar escenas se requiere obtener una mayor visibilidad de la imagen para su posterior análisis. Por otro lado, la rama de la Inteligencia Artificial también

posee tres desventajas, una de ellas es la dificultad de su aplicación asociado a la poca iluminación, luego está el registro de velocidad al interpretar los datos y el mantenimiento de equipos que son implementados en la VA (Quinde et al., 2021).

3.3. Fases del proceso de funcionamiento de la visión artificial

En la Figura 6, la visión artificial, posee un proceso de funcionamiento que consta de una serie de fases que inicia desde la adquisición de imagen hasta la interpretación de los datos obtenidos.

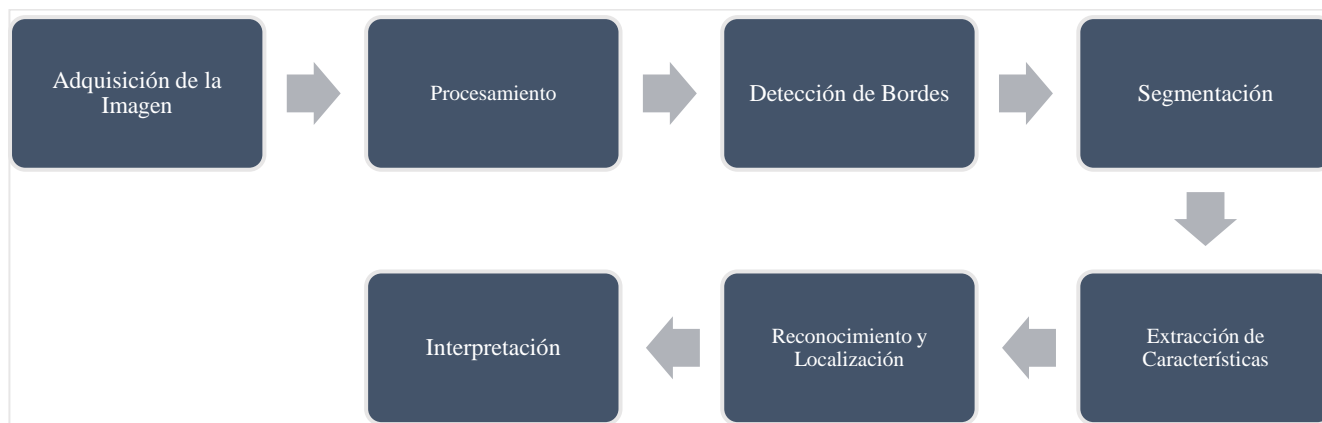


Figura 6. Fases del proceso de funcionamiento de la VA. Tomado de (Alvear-Puertas et al., 2017)

Las fases del proceso son independientes y opcionales (Álvarez Durán, 2014). Desde la fase inicial, conocida como adquisición de imagen, se digitaliza la imagen. Después se realiza al pre procesamiento, que facilita la eliminación de partes de imágenes que serán innecesarias para el análisis (Véles et al., 2003) La fase de detección de bordes, separa los datos significativos del fondo, reduciendo los datos (Shah, 1997). En la fase de segmentación de imagen se seleccionan los píxeles en base al RGB (sigla que se conoce por Red, Green y Blue y que es un modelo de color que representa los colores utilizando los colores primarios de la luz) y HSV (sigla en inglés conocida como Hue, Saturation, Value y que es el modelo color que utiliza los componentes de matiz, saturación y valor para la mezcla de colores) que permiten destacar un objeto de color (Juan et al., 2015). La fase del reconocimiento y localización, realizan la clasificación de objetos en base a sus características y restringen el espacio tridimensional, a través de una técnica de triangulación que se seleccione una imagen para ser interpretada (Álvarez Durán, 2014). La última fase de la interpretación aporta significado a los objetos identificados (Vicuña & Anelle, 2021), de tal manera que se permita entender el contenido de la imagen o video.

3.4. Impacto en la agricultura

La VA dentro de la agricultura tuvo un incremento significativo, porque permite disminuir los costes de producción, lo que genera que exista una reducción en los precios de equipos tecnológicos. Esta tecnología brinda información del objeto y, sobre todo, permite el análisis de estos objetos en regiones del espectro electromagnético, que incluye una serie de elementos imperceptibles al ojo humano y que aportan un tipo de información a la imagen para ser utilizada en su campo de aplicación (Blasco et al., 2010; Santillán et al., 2015).

3.5. Análisis de las preguntas de investigación

En las próximas líneas, se presentan los resultados obtenidos por un análisis cuantitativo y cualitativo de cada pregunta señalada anteriormente. En el análisis cuantitativo se tiene en cuenta a la pregunta 1, 2, 3 y 6, puesto que se requiere listar los algoritmos, dispositivos, técnicas, librería y software utilizados en la VA y que estén relacionados al tema de investigación; mientras que en la pregunta 4 y 5 se realiza un análisis cualitativo, debido a que se busca descubrir la mejor técnica y algoritmo respectivamente.

Q1: ¿Qué algoritmos de selección visual han sido utilizados para la selección de frutas?

Se tiene en cuenta, que el algoritmo es considerado una secuencia de pasos lógicos ejecutados que permiten lograr la interpretación visual computarizada, por ese motivo, se busca identificar los algoritmos existentes para la selección de imágenes, de tal modo que en la Tabla 4 nos da una visibilidad a la respuesta de la interrogante.

Tabla 4.

Algoritmos de selección visual utilizados para la selección de frutas

Referencia	Algoritmo	Observación
Lee et al. (2023)	Algoritmo de segmentación	El algoritmo de segmentación o entrena el modelo centrándose en las regiones de la fruta, garantizando una mejor detección, por ello divide la imagen que tienen atributos comunes para realizar el análisis y comprensión de la imagen.
Andriyanov (2023); Ferraris et al. (2023); S. Chen et al. (2023)	Algoritmo YOLOv5	YOLOv5 es un algoritmo de detección de objetos que analiza la imagen una sola vez. Su funcionamiento se basa en el uso de redes neuronales y estructura de celdas que abordan mejor los objetos de distintos tamaños en la imagen.
Luo et al. (2022)	Algoritmo YOLOv5s	YOLOv5s es una variante del algoritmo YOLOv5 enfocada a una detección veloz con un menor uso de recursos. Su funcionamiento inicia con la extracción de características de la imagen, generación refinada de predicciones con su respectiva etiqueta de clase y que muestra el resultado de la imagen en tiempo real.
Adeniji et al. (2022)	YOLOv4-tiny	YOLOv4-tiny es una variante del algoritmo YOLO que se caracteriza por ser rápida en la detección de objetos en tiempo real. Su funcionamiento se basa en el uso de la red neuronal convolucional que procesa y extrae características relevantes de la imagen para luego obtener las detecciones más adecuadas y mostrando las imágenes de salida con las etiquetas de clase.
D. Chen et al. (2021)	Algoritmo de Fusión de Imágenes	Fusión de Imágenes es un algoritmo que mejora la información visual y extrae los conocimientos de fuentes de datos visuales múltiples y variados para convertirla en una imagen compuesta donde se resalta las características relevantes del objeto.
Mazzia et al. (2020)	Algoritmo YOLOv3-tiny	YOLOv3-tiny es un algoritmo que detecta imágenes en tiempo real. Su funcionamiento, inicia con la extracción de características y el procesamiento de la imagen con una precisión inferior a la versión de YOLO.
Álvarez-Bermejo et al. (2019)	Algoritmo Kanny	Kanny es un algoritmo usado en visión por computadora porque detecta los bordes en las imágenes y resalta las transiciones en la intensidad de píxeles en la imagen. Su funcionamiento inicia con la reducción de distorsión en la imagen para finalizar con la aplicación de umbrales y obtener contornos significativos.
Tian et al. (2019)	Algoritmo de segmentación	La segmentación es un algoritmo que permite la división de la imagen en regiones o segmentos significativos basados en características que tiene la imagen para eliminar áreas no deseadas y conseguir identificar los objetos de interés.
An et al. (2022)	Algoritmo SDNet	SDNet es un algoritmo de visión por computadora que detecta objetos en imágenes o videos. Su funcionamiento se basa en dividir la imagen en varios píxeles y el algoritmo aprende del modelo matemático asociando las propiedades de la imagen con las clases de objetos.
Lawal (2021)	Algoritmo de Supresión No Máxima (NMS)	Supresión No Máxima es un algoritmo que elimina las detecciones repetidas o superpuestas y sólo retiene las detecciones confiables. Su funcionamiento, se basa en detectar las características en la imagen, calcula los puntajes de confianza que indica que la detección es correcta y suprime las detecciones innecesarias para conseguir un resultado adecuado.
Tran et al. (2023)	Algoritmo de detección de bordes y búsqueda de	Detección de bordes y búsqueda de contornos de Canny es un algoritmo utilizado en la visión por computadora. Su funcionamiento se basa en reducir las distorsiones y disminuir las variaciones en los píxeles de la imagen para generar resultados de calidad.

	contornos de Canny	
Lai et al. (2022); Tran et al. (2023)	Algoritmo YOLOv4	YOLOv4 es un algoritmo que detecta varios objetos por una sola vez en la imagen haciéndolo rápido en la detección. Su funcionamiento se basa en dividir la imagen en cuadrículas de celdas que se encargan de predecir la presencia del objeto, luego extrae las características de la imagen y finalmente elimina detecciones innecesarias para obtener un resultado adecuado.
He et al. (2023)	Algoritmo de segmentación de umbral de Otsu	La segmentación de umbral de Otsu es un algoritmo que realiza la segmentación automática de imágenes en varias regiones. Su funcionamiento, inicia con la construcción del histograma de intensidad, después calcula las varianzas para obtener el objeto y fondo que permita conseguir el mejor umbral y tener la imagen binaria segmentada donde se resalte el objeto de interés.
Xuan et al. (2020)	Algoritmo YOLOv3 mejorado	YOLOv3 mejorado es la versión del algoritmo YOLOv3 que detecta los objetos con un modelo de aprendizaje profundo aprendiendo características complejas y detectando objetos más pequeños con mayor velocidad, precisión y menor cantidad de recursos.
Jaramillo-Acevedo et al. (2020)	Algoritmo de umbral binario invertido	Umbral Binario Invertido es un algoritmo que convierte la imagen en grises en una imagen binaria. Su funcionamiento inicia con el cálculo del umbral, que divide los píxeles de la imagen en dos grupos con píxeles claros y oscuros.

Q2: ¿Qué equipamiento informático se utiliza en las implementaciones de visión por computadora para la selección de fruta?

En la Tabla 5, cuando nos referimos a equipamiento informático, se incluye a todos aquellos equipos tecnológicos que permiten la realización de procesamiento de imágenes como cámaras, procesadores, controladores, entre otros dispositivos electrónicos que son capaces de lograr el proceso de implementación de la VA.

Tabla 5.

Equipamiento informático utilizado en implementaciones de visión por computadora para la selección de frutas

Referencia	Equipamiento informático	Observación
Lee et al. (2023)	Cámara industrial Sensor de luz Nvidia Jetson Nano	La cámara industrial es un dispositivo que posee una resolución de 5MP con una velocidad de 35 fotogramas y que permite capturar las imágenes de frutas. El sensor de luz es el componente que realiza la medición de la intensidad de luz y corrige las variaciones de iluminación en la escena. El Nvidia Jetson Nano es una computadora utilizada en VA que ejecuta, entrena, infiere y despliega modelos de aprendizaje automático.
Andriyanov (2023)	Raspberry Pi 4 Cámara estéreo ZED 2 computadora ASUS FX 504 Tarjeta Nvidia GeForce 1060	Raspberry Pi 4 es un ordenador de placa única que proporciona una solución compacta en tareas de procesamiento de imágenes en tiempo real, la detección de objetos y el control de dispositivos que capturan las imágenes. Cámara estéreo ZED 2 es un cámara 3d que tienen dos lentes separados que capturan las imágenes desde distintos ángulos, lo que permite medir la profundidad y distancia a los objetos en escena. Computadora ASUS FX 504 es una computadora portátil que es utilizada en la tarea de desarrollo, entrenamiento del modelo de aprendizaje profundo y ejecuciones de aplicaciones de VA. Tarjeta Nvidia GeForce 1060 es una unidad de procesamiento gráfico que permite acelerar el entrenamiento y la inferencia de modelos de aprendizaje profundo.
Luo et al. (2022)	Cámara Microsoft Azure Kinect RGB-D	La cámara Microsoft Azure Kinect RGB-D es un dispositivo que es utilizado en implementaciones de visión por computadora para

		capturar la información del color y la profundidad obteniendo una mejor comprensión de la escena.
Adeniji et al. (2022)	<p>Arduino ATmega328P Cámara IP Sensor de temperatura/humedad (DHT11) Sensor de gas (MQ-3) Módulo WiFi (ESP8622)</p>	<p>Arduino ATmega328P es un microcontrolador utilizado en la placa Arduino Uno que interactúa con la visión por computadora. Cámara IP es una cámara de video que se conecta a una red IP (Protocolo de Internet) y que transmite video y datos mediante la red. Su uso se basa en capturar las imágenes que serán procesadas con el algoritmo de visión por computadora. Sensor de temperatura/humedad (DHT11) es utilizado para medir la temperatura y humedad en el entorno y capturar los datos que es utilizado en la aplicación. Sensor de gas (MQ-3) se utiliza para detectar concentraciones de gases en el aire. Módulo Wifi (ESP32) son dispositivos que permiten la conectividad inalámbrica a redes WiFi y que son el medio para el envío de datos.</p>
Sari et al. (2022)	<p>Motor tipo MG955 y MG90S Celda de carga conectada al modelo HX711 Arduino Uno Cámara web 720p</p>	<p>Los motores MG955 y MG90S son servomotores que se utilizan en la aplicación de automatización para controlar la posición del objeto. La celda de carga conectada al módulo HX711 es un sensor que mide las fuerzas o pesos y es utilizado para amplificar la señal de la celda de carga y convertirla en valores digitales. El Arduino Uno es el microcontrolador que permite la programación y el control de dispositivos electrónicos. Este dispositivo es utilizado como interfaz entre el sistema y el dispositivo físico. La cámara web de 720p es un dispositivo que captura las imágenes para su procesamiento por el algoritmo de visión.</p>
Wu et al. (2021)	<p>UPC: Intel Xeon GPU: Tesla K80</p>	<p>La UPC (Intel Xeon) es el dispositivo principal de la computadora que realiza operaciones de procesamiento de imágenes. La GPU Tesla K80 es una unidad de procesamiento utilizada en la aceleración de tareas de procesamiento de imágenes.</p>
Adhitya et al. (2020)	<p>Computadora portátil Intel Core i5 de doble núcleo a 2,7 GHz con 8 GB de RAM DDR3 a 1867 MHz.</p>	<p>El procesador Intel Core i5 es una unidad de procesamiento central que se utiliza en la ejecución del algoritmo de visión y procesamiento de imágenes.</p>
Khriji et al. (2020)	<p>Dispositivo FPGA SoC Zynq 7020</p>	<p>El dispositivo FPGA es un tipo de dispositivo lógico que acelera la extracción de características de imágenes y procesa grandes cantidades de datos de imágenes en tiempo real. El SoC - Zynq 7020 es un dispositivo que combina componentes de hardware y software para realizar tareas de procesamiento de imágenes y visión.</p>
Wang et al. (2020)	<p>Cámara de video esférica inteligente CMOS</p>	<p>La cámara de video esférica CMOS es el dispositivo que captura imágenes y videos en todas las direcciones. Su funcionamiento, se producen con los lentes que tienen para que fusionen la imágenes y se pueda presentar el contenido en una vista panorámica completa.</p>
Mazzia et al. (2020)	<p>Raspberry Pi 3 B+ con Intel NCS2 y Movidius NCS NVIDIA Jetson AGX Xavier</p>	<p>El Raspberry Pi 3B+ es una serie de placas de computadora que funciona procesando modelos de aprendizaje profundo y acelerando la inferencia de red neuronal con el Intel NCS2 y Movidius NCS. El NVIDIA Jetson AGX Xavier es una computadora de alto rendimiento que ejecuta algoritmos de aprendizaje profundo.</p>
Álvarez-Bermejo et al. (2019)	<p>Teléfono inteligente Cámara CCD</p>	<p>El teléfono inteligente es un dispositivo que captura las imágenes mediante su cámara y son visualizadas desde su pantalla. La cámara CCD es un tipo de sensor de imagen utilizado en la captura de imágenes digitales que son procesados en la tarea de análisis de reconocimiento y toma de decisiones.</p>
Li et al. (2020)	<p>Kinect V2 Cámara RGB-D Cámara infrarroja</p>	<p>Kinect V2 es un dispositivo que combina una cámara RGB con una cámara de profundidad que permite la captura de información visual de una escena. La cámara RGB-D es un tipo de cámara que captura las imágenes en color como información de profundidad permitiendo una detección de objetos.</p>

		La cámara infrarroja es el dispositivo que captura las imágenes para detectar la temperatura de objetos con radiación térmica.
Tian et al. (2019)	Kinect V2	Kinect V2 es un dispositivo que combina una cámara RGB con una cámara de profundidad que permite la captura de información visual de una escena.
Miraei Ashtiani et al. (2021)	cámara digital (Nikon D3200 24.2MP CMOS) lámpara fluorescente circular	La cámara digital Nikon D3200 es un dispositivo que es utilizado para la adquisición de imágenes de objetos que son procesados mediante el algoritmo de visión por computadora. La lámpara fluorescente circular es una fuente de iluminación que proporciona luz continua y uniforme en la escena para garantizar que el objeto sea visible en la imagen.
Tang et al. (2020)	Cámara de imágenes hiperespectrales (GaiaSky-Mini) lámparas halógenas ELC de 50 W Ordenador personal	La cámara de imágenes hiperespectrales (GaiaSky-Mini) captura imágenes en escena para recuperar datos utilizando algoritmos de visión por computadora. Las lámparas halógenas ELC de 50w proporcionan iluminación brillante y continua para garantizar que el objeto sea visible. El ordenador personal es un dispositivo utilizado en el procesamiento de datos y ejecución de algoritmos de visión por computadora.
S. Chen et al. (2023)	Dispositivo móvil GPU NVIDIA RTX 2060 Super 8G CPU Intel i5-12400F a 2,5 GHz	El dispositivo móvil es un aparato que permite capturar imágenes digitales en color y en una determinada resolución de píxeles. Su funcionamiento es básicamente utilizar el aplicativo propio del dispositivo para capturar imágenes y almacenarlas en la memoria. La GPU NVIDIA RTX 2060 Super 8G es una unidad de hardware de procesamiento paralelo diseñado para realizar operaciones como el entrenamiento del modelo de aprendizaje automático. El CPU Intel i5-12400F 2.5 GHz es el procesador de la computadora que realiza la tarea de procesamiento de imágenes.
Castro et al. (2019)	Cámara web VGA Tubos fluorescentes (Philips TL-D Super y Philips GX23 PH-T9) Computadora personal (Intel Pentium CPU de doble núcleo T4200 a 2,00 GHz y 3,0 GB de RAM)	La cámara web VGA es un dispositivo que captura imágenes con una resolución de 640 x 480 píxeles y que captura los datos visuales de la escena. Los tubos fluorescentes (Philips TL-D Super y Philips GX23 PH-T9) proporcionan iluminación en entornos controlados con el objetivo de garantizar que las imágenes sean claras y nítidas. La computadora personal (Intel Pentium CPU de doble núcleo T4200 a 2,00 GHz y 3,0 GB de RAM) es un dispositivo que permite el procesamiento de datos y análisis de imágenes.
Zhang & Gao (2019)	cámara con semiconductor complementario de óxido metálico (CMOS) 1/2 5"	La cámara CMOS de 1/2 5" es un tipo de sensor de imagen que tiene la cámara digital y permite la captura de imágenes en la escena de interés.
Aiadi et al. (2022)	Cámara web	La cámara web es un dispositivo de captura de imágenes y videos que se conecta a la computadora para captura imágenes de la escena para su posterior procesamiento.
An et al. (2022)	Teléfono inteligente (Iphone11)	El teléfono inteligente (iPhone 11) es un dispositivo equipado con una cámara capaz de capturar imágenes en alta calidad que son procesadas en la aplicación para reconocer objetos.
Lawal (2021)	CPU Intel-Core i7-8700 @ 64-bit 3.20 GHz: 16 GB de RAM GPU NVIDIA GeForce GTX 1080Ti	La CPU Intel Core i7-8700 es un procesador que se encargan de ejecutar tareas específicas en la aplicación de visión por computadora. La GPU NVIDIA GeForce GTX 1080 Ti es una tarjeta gráfica que ayuda en el procesamiento de imágenes.
Khattak et al. (2021)	Dispositivo móvil	El dispositivo móvil es un aparato que permite capturar imágenes digitales en color y en una determinada resolución de píxeles. Su funcionamiento es básicamente utilizar el aplicativo propio del dispositivo para capturar imágenes y almacenarlas en la memoria interna del aparato.
Tran et al. (2023)	Cámara digital (CANON EOS 60D)	La cámara digital CANON EOS 60D con lente Tamron 17-50 es el dispositivo que captura imágenes en una escena.

	con lente Tamron 17-50) Dos tubos de luz LED envolventes CPU INTEL CORE I7 (décima generación) y 16 GB de RAM	Los tubos de luz LED son dispositivos que permiten la mejora de la calidad de imágenes y mejorar el procesamiento de imágenes. El CPU Intel Core i7 de décima generación y 16 GB de RAM es la unidad de procesamiento de alto rendimiento que se utiliza para ejecutar algoritmos de procesamiento de imágenes.
Liu et al. (2020)	Cámara RGB-D CPU Intel Core i7-8750H (4,1 GHz) de seis núcleos, una GPU NVIDIA GTX 1060 de 6 GB y 8 GB de memoria Kinect V2	La cámara RGB-D es un dispositivo que captura la información de color como datos de profundidad de los objetos en la escena. El CPU Intel Core i7-8750H es el procesador que se encarga de ejecutar los algoritmos de procesamiento de imágenes. El Kinect V2 es un dispositivo que proporciona los datos tridimensionales y en color del objeto.
Suharjito et al. (2023)	Teléfono inteligente	El teléfono inteligente es un dispositivo que captura las imágenes mediante su cámara y son visualizadas desde su pantalla.
Lai et al. (2022)	Cámara Intel Realsense D435 Procesador Core i7-8750H Tarjeta gráfica GeForce GTX 1070	La cámara Intel RealSense D435 es una cámara de profundidad que captura imágenes en color y datos de profundidad consiguiendo un mapa tridimensional de la escena. El procesador Core i7-8750H es un procesador que permite realizar y gestionar acciones en el procesamiento de imágenes. La tarjeta gráfica GeForce GTX1070 es un dispositivo que apoya en el procesamiento y análisis de grandes volúmenes de datos visuales.
Wang et al. (2020)	Cámara de vídeo esférica inteligente CMOS (DS-2DC4220IW-D) Router Computadora de escritorio con Windows 7	La cámara de vídeo esférica CMOS es el dispositivo que captura imágenes y videos en todas las direcciones. Su funcionamiento se producen con los lentes que tienen para que fusionen las imágenes y se pueda presentar el contenido en una vista panorámica. El router es un dispositivo de red que posibilita la conexión de varios dispositivos en la red y proporciona el acceso a redes para realizar la transferencia de datos. La computadora de escritorio con Windows 7 es una computadora personal que se utiliza para ejecutar software de visión por computadora que realiza tareas de procesamiento de imágenes.
Xuan et al. (2020)	Cámara Iphone 7 plus	La cámara del Iphone 7 plus permite la captura de imágenes en alta resolución y permite recopilar los datos visuales para su posterior procesamiento de datos en la visión por computadora.
Jaramillo-Acevedo et al. (2020)	Teléfono Android	El teléfono Android es un dispositivo móvil que está equipado con una cámara que es utilizado en la captura de imágenes para realizar tareas de reconocimiento de objetos.
Davur et al. (2023)	Cámara de escáner de línea de 12 bits luces halógenas	La cámara de escáner de línea de 12 bits es un dispositivo de captura de imágenes utilizado en la obtención de imágenes de alta calidad por su gama de niveles de intensidad de luz. Las luces halógenas son fuentes de iluminación que emiten luz brillante y uniforme en la escena donde se captura las imágenes.
Cho et al. (2021)	Cámara de Iphone 5s	La cámara del Iphones 5s es el dispositivo que captura imágenes de alta calidad y que es utilizado para su procesamiento con el uso del algoritmo de visión por computadora.
Cho et al. (2020)	Cámara de Iphone 5s	La cámara del Iphones 5s es el dispositivo que captura imágenes de alta calidad y que es utilizado para su procesamiento con el uso del algoritmo de visión por computadora.

Q3: ¿Qué modelos de Inteligencia Artificial se utilizan para la descripción y detección de características de las frutas?

En la Tabla 6, se muestra que la VA comprende modelos modernos que permiten el análisis e interpretación de imágenes y entrenamiento de la data obtenida, por este motivo, se busca obtener todos los enfoques asociados a esta ciencia que participen directa o indirectamente en su aplicación.

Tabla 6.*Modelos de Inteligencia Artificial utilizados en la descripción y detección de características de frutas*

Referencia	Modelo	Observación
(Ferraris et al., 2023)	Modelo YOLOv5m	El modelo YOLOv5m es una versión de YOLOv5 que utiliza una red neuronal convolucional en la detección de objetos en imágenes de manera eficiente y precisa.
Lee et al. (2023)	RegNetY-8.0GF (R8) RegNetY-32GF (R32) EfficientNet-B4 (EB4) EfficientNet-B6 (EB6) ResNet18	RegNetY-8.0GF (R8) y RegNetY-32GF (R32) son distintas variantes del RegNet que son eficientes en las redes neuronales. EfficientNet-B4 (EB4) y EfficientNet-B6 (EB6) son modelos caracterizados por el rendimiento en las tareas que realizan en visión por computadora. ResNet18 es un modelo que tiene 18 capas y permiten el entrenamiento de redes profundas con eficiencia.
Andriyanov (2023)	Modelo Yolov5	El modelo de YOLOv5 es utilizado en la detección de objetos en tiempo real de manera rápida y precisa.
Luo et al. (2022)	YOLOX-Nano PP-YOLO-Tiny EfficientDet-D0 Yolov5 mejorado	YOLOX-Nano es una evolución de YOLO que se encarga de mejorar la velocidad y la eficiencia manteniendo un elevado rendimiento en la detección de objetos. PP-YOLO-Tiny es la versión ligera y rápida de YOLO enfocado en mejorar la precisión de la detección de objetos en tiempo real. EfficientDet-D0 es una variante ligera de la arquitectura EfficientDet-do que logra el equilibrio entre la eficiencia y rendimiento. YOLOv5 mejorado es un modelo que incorpora técnicas de entrenamiento para la mejora en la precisión y rendimiento en tareas de detección de objetos.
Adeniji et al. (2022)	Modelo YOLOv4-tiny	YOLOv4-tiny es el modelo compacta de YOLOv4 que se utiliza en la detección de objetos en tiempo real con menor cantidad de parámetros entrenables, haciéndolo más rápido con escasos recursos a nivel de hardware.
D. Chen et al. (2021)	Modelo SSD mejorado Modelo R-CNN (Red neuronal convolucional)	El SSD es un modelo de detección de varios objetos en tiempo real que divide la imagen en cuadrículas de celdas y realiza la clasificación y regresión en distintos tamaños y formas para obtener detecciones adecuadas. El R-CNN es un modelo que divide el proceso de detección en dos partes: generación de regiones de la imagen que contiene objetos y clasifica el objeto presente en la región, de tal manera que genere una mayor precisión en la detección de objetos.
Wu et al. (2021)	Modelo YOLOv4	El modelo YOLOv4 es utilizado para la detección de objetos en tiempo real que divide la imagen en cuadrícula de celdas obteniendo una mejor velocidad y precisión.
Wang et al. (2020)	ResNet-50	El modelo ResNet-50 es una variante del ResNet que extrae características de imágenes y resuelve el problema del desvanecimiento de gradientes en redes neuronales profundas.
Mazzia et al. (2020)	Modelo YOLOv3-tiny	El modelo YOLOv3-tiny es una versión reducida del YOLOv3 que detecta los objetos en tiempo real y con mayor velocidad, por eso divide la imagen en cuadrículas para mejorar la precisión y evitar duplicaciones en las detecciones.
Li et al. (2020)	Deeplabv3	El modelo Deeplabv3 se basa en redes neuronales convolucionales profundas para obtener características de la imagen con mejor precisión en la segmentación y etiquetas a cada píxel de una imagen indicando la categoría a la que pertenece.
Miraei Ashtiani et al. (2021)	ResNet-18	El modelo ResNet-18 es una variante específica de ResNet que clasifica y entrena redes neuronales profundas. Este modelo resuelve el problema de gradientes que extraen características en distintos niveles de abstracción mediante un proceso de reducción del peso de la conexión de red para minimizar el error.
Tang et al. (2020)	Modelo ECOC-SVM	El modelo ECOC-SVM son clasificadores binarios que resuelven problemas de clasificación asignando una etiqueta a cada clase dividiendo el problema en partes pequeñas y fáciles de resolver.

S. Chen et al. (2023)	YOLOv5 mejorado	El modelo YOLOv5 mejorado es una mejora del modelo YOLOv5 que tiene un rendimiento y alta precisión en la detección de objetos.
Castro et al. (2019)	Combinación del modelo Espacio de color con modelo SVM	El conjunto de técnicas que se aplican a los datos o señales antes de su análisis sirven para mejorar la calidad, eliminar ruido y artefactos, y prepararlos adecuadamente para obtener resultados más precisos y confiables en estudios y aplicaciones científicas y tecnológicas.
Aiadi et al. (2022)	K-vecino más cercano (KNN) Máquina de vectores de soporte (SVM) Árboles de decisión (DT)	El modelo KNN es utilizado en la clasificación de imágenes que busca los K puntos de datos más cercanos en el entrenamiento y toma una decisión basada en las clases de clasificación y regresión. El modelo SVM es un algoritmo de clasificación que encuentra la separación entre dos clases en un espacio multidimensional. El modelo maximiza el margen entre clases para transformar los datos en un espacio de características no lineales. El modelo DT se utiliza en la clasificación de imágenes que construyen y dividen el conjunto de datos en base a las características particulares y criterios que maximizan la clase generando predicciones dividiendo el espacio de características en regiones.
An et al. (2022)	SDNet	El modelo SDNet es un modelo de reconocimiento de imágenes que reduce el número de parámetros del modelo siendo eficiente en recursos y rápido en el entrenamiento.
Lawal (2021)	YOLOMuskmelon	YOLOMuskmelon es el modelo enfocado en la detección de melones que ha sido enfocado en la mejora del rendimiento en la detección del fruto con diversos tamaños y formas y con una alta precisión.
Khattak et al. (2021)	CNN	CNN o el modelo de red neuronal convolucional es un tipo de red utilizada en tareas de reconocimiento de patrones como la clasificación de imágenes que permite detectar las características complejas del objeto y realizar reconocimiento con precisión.
Suharjito et al. (2023)	YOLOv4 mejorado	YOLOv4 mejorado es una variante de la versión del modelo YOLOv4 que se utiliza en la detección de objetos con un alto adaptamiento a condiciones de iluminación, precisión y velocidad.
Lai et al. (2022)	YOLOv4	El modelo YOLOv4 es utilizado para la detección de objetos en tiempo real que divide la imagen en cuadrícula de celdas obteniendo una mejor velocidad y precisión.
Wang et al. (2020)	ResNet-50	El modelo ResNet-50 es una variante del ResNet que extrae características de imágenes y resuelve el problema del desvanecimiento de gradientes en redes neuronales profundas.
Xuan et al. (2020)	YOLOv3 mejorado	YOLOv3 mejorado es el modelo enfocado en la detección de objetos que tiene una alta precisión, velocidad y adaptable a distintas condiciones ambientales por la arquitectura de red neuronal que emplea.
Jaramillo-Acevedo et al. (2020)	Modelo de perceptrón multicapa (MLP)	El LP es un modelo que tiene múltiples capas de neuronas y posee una matriz de datos que le permite realizar una predicción del modelo mediante las capas que generan un proceso iterativo con precisión.
Cho et al. (2021)	Modelo ANN	La ANN (Red Neuronal Artificial) es un modelo que tiene una red de unidades de procesamiento que se organizan en tres capas para realizar la propagación de los datos hasta lograr la precisión en las predicciones.
Cho et al. (2020)	Modelo SVR	El modelo SVR (Support Vector Regression) es el modelo que encuentra la mejor función que se ajuste a un conjunto de datos, minimizando el error de la predicción. Su funcionamiento se inicia con la selección de características relevantes, el mapeo de los datos en una dimensión para entrenar el modelo y encontrar una función cercana a los datos y con menor error para utilizar en predicción de futuros datos.

Q4: ¿Qué modelo de Inteligencia Artificial ha tenido el mejor resultado con respecto a la descripción y detección de características de las frutas?

De todos los modelos visualizados previamente, se identifican en la Tabla 7, los mejores enfoques de VA que proporcionan una precisión en la detección superior al 90%. Estas técnicas, fueron identificadas en cada estudio, donde se demostró en sus conclusiones generalmente, la óptima respuesta que tuvo en comparación con otras técnicas utilizadas en el campo de estudio.

Tabla 7.

Modelos de Inteligencia Artificial con mejor resultado

Referencia	Modelo	Observación
Ferraris et al. (2023)	Modelo YOLOv5m	El modelo detecta las frutas sanas en tiempo real con un 98%, sin embargo, presenta dificultades para diferenciar enfermedades del fruto.
Lee et al. (2023)	RegNetY-8.0GF (R8) RegNetY-32GF (R32) EfficientNet-B4 (EB4) EfficientNet-B6 (EB6) ResNet18	El modelo ResNet18 tiene la mejor precisión con un valor equivalente al 94,48% a diferencia de los otros modelos utilizados.
Andriyanov (2023)	Modelo Yolov5	Se observa que el modelo con su variación Yolov5x6+ (1280px) logra un mayor porcentaje en detección de las manzanas rojas con un 97,96% y con las manzanas verdes logra una detección del 95,38%
Luo et al. (2022)	YOLOX-Nano PP-YOLO-Tiny EfficientDet-D0 Yolov5 mejorado	De todos los modelos utilizados, se indica que el Yolov5 mejorado tiene un mejor resultado al proporcionar una precisión del 95,32% de los melocotones.
D. Chen et al. (2021)	Modelo SSD mejorado Modelo R-CNN (Red neuronal convolucional)	El modelo SSD mejorado destaca por obtener una precisión del 93,74% en el reconocimiento de madurez de la fruta.
(Wu et al., 2021)	Modelo YOLOv4	El modelo durante las pruebas obtiene una precisión del 98,22% en la detección de manzanas.
Miraei Ashtiani et al. (2021)	ResNet-18	El modelo logra una precisión equivalente al 98,65% en la clasificación con 60 épocas mayor que los otros modelos comparados.
S. Chen et al. (2023)	YOLOv5 mejorado	El modelo propuesto logra una precisión del 93,3% con respecto a la fresa.
An et al. (2022)	SDNet	El modelo de detección logra el monitoreo de los frutos con una precisión del 94,26%.
Khattak et al. (2021)	CNN	El modelo CNN alcanza el mejor nivel de precisión con un 94,55% que otros modelos estudiados.
Suharjito et al. (2023)	YOLOv4 mejorado	El modelo demuestra que funciona mejor que otros modelos en comparación con una precisión del 97%.
Xuan et al. (2020)	YOLOv3 mejorado	El modelo tuvo un mejor de efecto de precisión del 97,9% en el reconocimiento de manzanas rojas y un 97,6% en el reconocimiento de manzanas verdes.

Q5: ¿Qué algoritmos de selección visual tienen una mejor performance en la selección de frutas?

La VA al comprender algoritmos que consigan un funcionamiento adecuado se hace necesario identificarlos, ver la Tabla 8, en los estudios analizados cuales tienen un mejor rendimiento en el procesamiento, extracción y análisis de información para que la máquina pueda comprender el entorno

visual sin problemas. Por ello, se consideran aquellos algoritmos que tengan un porcentaje en la precisión en el reconocimiento superior al 85% que demuestre superioridad frente a otros algoritmos.

Tabla 8.

Algoritmos de selección visual que tienen mejor performance en la selección de frutas

Referencia	Algoritmo	Observación
Lee et al. (2023)	Algoritmo de segmentación	El algoritmo garantiza un proceso de detección de defectos con una alta precisión, logrando que el sistema obtenga una velocidad de procesamiento en 2.84 segundos y una precisión del 93,83%.
Luo et al. (2022)	Algoritmo Yolov5s	El algoritmo Yolov5s ofrece una precisión del 95,32% en la detección de los frutos con distintas mediciones.
Adeniji et al. (2022)	YOLOv4-tiny	El algoritmo YOLOv4-tiny logra detectar una precisión aproximada del 88,10% y una pérdida del 0.3 en las sandías.
Tian et al. (2019)	Algoritmo de segmentación	El algoritmo de segmentación propuesto obtiene una precisión del 96,61% en el reconocimiento del fruto.
S. Chen et al. (2023)	Algoritmo YOLOv5	El algoritmo YOLOv5 propuesto muestra una mayor precisión con un 93,3% y menor FLOP.
An et al. (2022)	Algoritmo SDNet	El algoritmo alcanza una precisión de detección promedio equivalente al 93,15% superando a otros algoritmos como el YOLOv4, YOLOv5 y STR (Swin Transformer).
He et al. (2023)	Algoritmo de segmentación de umbral de Otsu	El algoritmo indica una precisión superior 90,95% al realizar varias pruebas con un error de coordinación del 8%.
Lai et al. (2022)	Algoritmo YOLOv4	El algoritmo obtiene una precisión del 95% y una recuperación del 82% en la detección en tiempo real de racimos de frutas.
Xuan et al. (2020)	Algoritmo YOLOv3 mejorado	El algoritmo posee un mejor rendimiento en la superposición, una tasa de recuperación de reconocimiento superior al 88,5% y una precisión superior al 97,5%.
Jaramillo-Acevedo et al. (2020)	Algoritmo de umbral binario invertido	El algoritmo proporciona una precisión del 88% siendo conveniente para la detección visual del estado de madurez del fruto.

Q6: ¿Qué librerías o software de visión por computadora existen para la selección visual de frutas?

Cuando se menciona en la pregunta, se toma en cuenta que el término librería o software abordan las mismas necesidades específicas del estudio de investigación, de esta manera, se hace necesario encontrar todas aquellas herramientas predefinidas, ver la Tabla 9, que proporcionen diversas funciones que realicen tareas en la implementación de la VA, sin esto no se podría mejorar el tiempo y esfuerzo, siendo una base para el desarrollo de la tecnología.

Tabla 9.

Librerías de visión por computadora existentes en la selección visual de paltas

Referencia	Librería o Software	Observación
Ferraris et al. (2023); Khattak et al. (2021)	Keras Tensorflow	Keras es una interfaz que funciona en el desarrollo de redes neuronales, de tal manera que permite definir, compilar, entrenar y evaluar modelos de redes neuronales. TensorFlow es una librería de código abierto que sirve para construir y entrenar modelos de aprendizaje automático. Esta librería funciona definiendo, compilando, entrenando, evaluando el modelo para la predicción y despliegue.
An et al. (2022); S. Chen et al. (2023); Lee et al. (2023); Luo et al. (2022); Wu et al. (2021)	TensorRT Pytorch	TensorRT es una biblioteca de inferencia de aprendizaje profundo que utiliza NVIDIA. Su funcionamiento consiste en optimizar y acelerar la inferencia de los modelos haciéndolo más eficiente. Pytorch es una biblioteca de aprendizaje profundo que funciona brindando herramientas e infraestructura al desarrollador de tal

		modo que construya, entrene y despliegue modelos de aprendizaje profundo.
Adeniji et al. (2022); He et al. (2023); Jaramillo-Acevedo et al. (2020); Li et al. (2020); Sari et al. (2022); Tran et al. (2023)	Open CV	OpenCV es una biblioteca de código abierto diseñada para el procesamiento de imágenes y visión por computadora. Proporciona una diversidad de funciones y algoritmos para manipular y analizar imágenes y videos.
Álvarez-Bermejo et al. (2019)	OpenCV BoofCV	OpenCV es una librería de código abierto que brinda una variedad de funciones y algoritmos para el procesamiento de imágenes. Su funcionamiento se basa en ofrecer un conjunto de funciones y algoritmos predefinidos que permiten ejecutar tareas relacionadas a la visión por computadora. BoofCV es una librería de código abierto enfocada en algoritmos de alto rendimiento que permiten la detección y seguimiento de objetos. Esta librería utiliza algoritmos que pueden ser personalizados y ser extendidos en temas de funcionalidad.
Lawal (2021)	cuDNN 7.6.5 openCV 4.2.0	cuDDN es una biblioteca de software que optimiza y acelera las operaciones en redes neuronales, logrando un entrenamiento eficiente. OpenCV es una biblioteca de código abierto diseñada para el procesamiento de imágenes y visión por computadora. Proporciona una diversidad de funciones y algoritmos para manipular y analizar imágenes y videos.
Xuan et al. (2020)	CUDNN	cuDDN es una biblioteca de software que optimiza y acelera las operaciones en redes neuronales, logrando un entrenamiento eficiente.
Cho et al. (2020, 2021)	Scikit-image OpenCV	Scikit-image es una biblioteca utilizada en visión por computadora que permite realizar el preprocesamiento de datos de las imágenes digitales. Su funcionamiento se basa en brindar una serie de herramientas y funciones para realizar operaciones de procesamiento y análisis de imágenes en el lenguaje de programación Python. OpenCV es una biblioteca de código abierto diseñada para el procesamiento de imágenes y visión por computadora. Proporciona una diversidad de funciones y algoritmos para manipular y analizar imágenes y videos.

Los resultados de la presente revisión sistemática revelan un panorama variado en el uso de algoritmos de VA aplicados en la identificación de frutos en el sector agrícola. Si bien la identificación de diversos algoritmos, modelos y equipos informáticos señalan logros significativos que dirigen hacia la necesidad de abordar la dependencia de factores específicos y mejorar la adaptabilidad a distintas condiciones. Propuestas constructivas incluyen el desarrollo de mecanismos de aprendizaje continuo, integración de tecnologías e implementación de iniciativas que fomenten la aceptación y comprensión de la VA en la selección de frutas con distintos escenarios cambiantes, que apuntan a una evaluación positiva en la aplicación en la agricultura, destacando la importancia de la adaptación e innovación continua.

CONCLUSIONES

Los resultados de la revisión revelan 32 algoritmos, esto evidencia su uso en aplicaciones de la VA en el sector agrícola, en la identificación de frutos. Entre los más eficientes se tiene al algoritmo YOLOv3 mejorado, capaz de reconocer frutos en fondos de imágenes complejos, por ello, su reconocimiento es dependiente de los factores de precisión y características que tiene el fruto a analizar. Además, se identifican 32 equipamientos informáticos utilizados en dichas implementaciones, adaptados a requisitos y objetivos específicos según el ambiente donde se utilicen, por lo que resulta necesario conocerlos para posibles trabajos en detección y análisis de imágenes digitales.

Entre los algoritmos expuestos anteriormente se encuentran algunos ideales en la identificación y selección de frutos por su calidad de precisión. El algoritmo de segmentación propuesto se distingue con una

precisión del 96,61%, al igual que el algoritmo YOLOv5s logra una precisión del 95,32% donde se destaca en la identificación de frutos con distintas dimensiones. Asimismo, el YOLOv3 mejorado presenta un rendimiento superior con una tasa de recuperación del 88,5% y una precisión superior al 97,5%. Estos algoritmos, junto con el YOLOv4 logran detectar las frutas en tiempo real, siendo opciones prometedoras de alta calidad en aplicaciones de VA. El artículo evidencia los elementos clave en las implementaciones del tema respectivo, además de la apertura de áreas para próximas investigaciones como la exploración de optimización de algoritmos en la identificación de frutas específicas, considerando sus características únicas. Inclusive, se sugiere la investigación de la aplicación en tiempo real y en entornos agrícolas, la detección de defectos en frutas, generalización a nuevas variedades y la incorporación de novedosas tecnologías.

FINANCIAMIENTO

El autor no recibió patrocinio para llevar a cabo este estudio-artículo.

CONFLICTO DE INTERESES

No existe ningún tipo de conflicto de interés relacionado con la materia del trabajo.

CONTRIBUCIÓN DE LOS AUTORES

Conceptualización: Parraga-Badillo, S. R. y Coral-Ygnacio, M. A.

Curación de datos: Parraga-Badillo, S. R. y Coral-Ygnacio, M. A.

Análisis formal: Parraga-Badillo, S. R. y Coral-Ygnacio, M. A.

Investigación: Parraga-Badillo, S. R.

Administración del proyecto: Parraga-Badillo, S. R.

Software: Parraga-Badillo, S. R.

Supervisión: Parraga-Badillo, S. R. y Coral-Ygnacio, M. A.

Validación: Parraga-Badillo, S. R.

Visualización: Parraga-Badillo, S. R.

Redacción-borrador original: Parraga-Badillo, S. R.

Redacción - revisión y edición: Parraga-Badillo, S. R.

REFERENCIAS BIBLIOGRÁFICAS

Adeniji, K. A., Onibonoje, M. O., Minevesho, A., Ejidokun, T., & Omitola, O. O. (2022). A robust 4.0 dual-classifier for determining the internal condition of watermelons using YOLOv4-tiny and sensory. *Indonesian Journal of Electrical Engineering and Computer Science*, 28(3), 1834–1844. <https://doi.org/10.11591/ijeecs.v28.i3.pp1834-1844>

Adhitya, Y., Prakosa, S. W., Köppen, M., & Leu, J. S. (2020). Feature extraction for cocoa bean digital image classification prediction for smart farming application. *Agronomy*, 10(11). <https://doi.org/10.3390/agronomy10111642>

Aguilar Alvarado, V., & Campoverde Molina, M. A. (2019). Classification of fruits based on convolutional neural networks Classificação de frutos com base em redes neurais convolucionais Ciencias de la ingeniería Artículo de investigación. *Polo Del Conocimiento: Revista Científico - Profesional*, ISSN-e 2550-682X, Vol. 5, No. 1, 2020, Págs. 3-22, 5(01), 3–22. <https://doi.org/10.23857/pc.v5i01.1210>

AIADI, O., KHALDI, B., KHERFI, M. L., MEKHALFI, M. L., & ALHARBI, A. (2022). Date Fruit Sorting Based on Deep Learning and Discriminant Correlation Analysis. *IEEE Access*, 10(August), 79655–79668.

<https://doi.org/10.1109/ACCESS.2022.3194550>

- Álvarez-Bermejo, J. A., Morales-Santos, D. P., Castillo-Morales, E., Parrilla, L., & López-Ramos, J. A. (2019). Efficient image-based analysis of fruit surfaces using CCD cameras and smartphones. *Journal of Supercomputing*, 75(3), 1026–1037. <https://doi.org/10.1007/s11227-018-2284-y>
- Álvarez Durán, M. A. (2014). *Análisis, diseño e implementación de un sistema de control de ingreso de vehículos basado en visión artificial y reconocimiento de placas en el parqueadero de la Universidad Politécnica Salesiana - Sede Cuenca*. Universidad Politécnica Salesiana. <http://dspace.ups.edu.ec/handle/123456789/7060>
- Alvear-Puertas, V., Rosero-Montalvo, P., Peluffo-Ordóñez, D., & Pijal-Rojas, J. (2017). Internet de las Cosas y Visión Artificial, Funcionamiento y Aplicaciones: Revisión de Literatura. *Enfoque UTE*, 8(1), 244–256. <https://doi.org/10.29019/enfoqueute.v8n1.121>
- Amaya-Zapata, S., Pulgarín-Velásquez, D., & Torres-Pardo, Í. D. (2016). Desarrollo e Implementación de un Sistema de Visión Artificial Basado en Lenguajes de Uso Libre para un Sistema Seleccionador de Productos de un Centro Integrado de Manufactura (CIM). *Lámpsakos*, 15, 43. <https://doi.org/10.21501/21454086.1702>
- An, Q., Wang, K., Li, Z., Song, C., Tang, X., & Song, J. (2022). Real-Time Monitoring Method of Strawberry Fruit Growth State Based on YOLO Improved Model. *IEEE Access*, 10(December), 124363–124372. <https://doi.org/10.1109/ACCESS.2022.3220234>
- Andriyanov, N. (2023). Development of Apple Detection System and Reinforcement Learning for Apple Manipulator. *Electronics (Switzerland)*, 12(3). <https://doi.org/10.3390/electronics12030727>
- Augusto, J. S. F. (2020). Introducción a la visión artificial. *British Journal of Cancer*.
- Blasco, J., Cubero, S., Gómez-Sanchís, J., & Moltó, E. (2010). Avances en visión artificial automática de productos hortofrutícolas. *Horticultura Global*, 288, 48–50. https://www.horticom.com/revistasonline/horticultura/rhg288/48_51.pdf
- Castro, W., Oblitas, J., De-La-Torre, M., Cotrina, C., Bazan, K., & Avila-George, H. (2019). Classification of Cape Gooseberry Fruit According to its Level of Ripeness Using Machine Learning Techniques and Different Color Spaces. *IEEE Access*, 7, 27389–27400. <https://doi.org/10.1109/ACCESS.2019.2898223>
- Chen, D., Tang, J., Xi, H., & Zhao, X. (2021). Image recognition of modern agricultural fruit maturity based on internet of things. *Traitement Du Signal*, 38(4), 1237–1244. <https://doi.org/10.18280/ts.380435>
- Chen, S., Liao, Y., Lin, F., & Huang, B. (2023). An Improved Lightweight YOLOv5 Algorithm for Detecting Strawberry Diseases. *IEEE Access*, 11, 54080–54092. <https://doi.org/10.1109/ACCESS.2023.3282309>
- Cho, B. H., Koyama, K., & Koseki, S. (2021). Determination of ‘Hass’ avocado ripeness during storage by a smartphone camera using artificial neural network and support vector regression. *Journal of Food Measurement and Characterization*, 15(2), 2021–2030. <https://doi.org/10.1007/s11694-020-00793-7>
- Cho, B. H., Koyama, K., Olivares Díaz, E., & Koseki, S. (2020). Determination of “Hass” Avocado Ripeness During Storage Based on Smartphone Image and Machine Learning Model. *Food and Bioprocess Technology*, 13(9), 1579–1587. <https://doi.org/10.1007/s11947-020-02494-x>
- Constante, P. N. (2012). *Diseño E Implementación De Un Prototipo De Brazo Robótico Para Aplicaciones De Clasificación Y Reconocimiento De Formas En El Proceso De Paletizado Empleando Procesamiento Digital De Imágens*. Escuela Politécnica del Ejército Extensión Latacunga.

- Davur, Y. J., Kämper, W., Khoshelham, K., Trueman, S. J., & Bai, S. H. (2023). Estimating the Ripeness of Hass Avocado Fruit Using Deep Learning with Hyperspectral Imaging. *Horticulturae*, 9(5), 1–16. <https://doi.org/10.3390/horticulturae9050599>
- FAO. (2020). OCDE-FAO Perspectivas Agrícolas 2020-2029. In *OECD Publishing*.
- Ferraris, S., Meo, R., Pinardi, S., Salis, M., & Sartor, G. (2023). Machine Learning as a Strategic Tool for Helping Cocoa Farmers in Côte D'Ivoire. *Sensors*, 23(17), 1–25. <https://doi.org/10.3390/s23177632>
- He, L., Cheng, X., Jiwa, A., Li, D., Fang, J., & Du, Z. (2023). Zanthoxylum bungeanum Fruit Detection by Adaptive Thresholds in HSV Space for an Automatic Picking System. *IEEE Sensors Journal*, 23(13), 14471–14486. <https://doi.org/10.1109/JSEN.2023.3277042>
- Heras, D. (2017). Fruit image classifier based on artificial intelligence. *Revista Killkana Técnica*, 1(2), 21–30. <https://doi.org/10.26871/killkana>
- Jaramillo-Acevedo, C. A., Choque-Valderrama, W. E., Guerrero-Álvarez, G. E., & Meneses-Escobar, C. A. (2020). Hass avocado ripeness classification by mobile devices using digital image processing and ANN methods. *International Journal of Food Engineering*, 16(12). <https://doi.org/10.1515/ijfe-2019-0161>
- Juan, T., González, D., Manuel, Y. J., & Velasco, S. (2015). *Diseño de Prototipo de Recogida Automatizada de bolos mediante brazo robótico y visión artificial*.
- Khattak, A., Asghar, M. U., Batool, U., Asghar, M. Z., Ullah, H., Al-Rakhami, M., & Gumaei, A. (2021). Automatic Detection of Citrus Fruit and Leaves Diseases Using Deep Neural Network Model. *IEEE Access*, 9, 112942–112954. <https://doi.org/10.1109/ACCESS.2021.3096895>
- Khriji, L., Ammari, A. C., & Awadalla, M. (2020). Hardware/software co-design of a vision system for automatic classification of date fruits. *International Journal of Embedded and Real-Time Communication Systems*, 11(4), 21–40. <https://doi.org/10.4018/IJERTCS.2020100102>
- Lai, J. W., Ramli, H. R., Ismail, L. I., & Hasan, W. Z. W. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4. *IEEE Access*, 10(August), 95763–95770. <https://doi.org/10.1109/ACCESS.2022.3204762>
- Lawal, O. M. (2021). YOLOMuskmelon: Quest for fruit detection speed and accuracy using deep learning. *IEEE Access*, 9, 15221–15227. <https://doi.org/10.1109/ACCESS.2021.3053167>
- Lee, J. H., Vo, H. T., Kwon, G. J., Kim, H. G., & Kim, J. Y. (2023). Multi-Camera-Based Sorting System for Surface Defects of Apples. *Sensors*, 23(8). <https://doi.org/10.3390/s23083968>
- Li, J., Tang, Y., Zou, X., Lin, G., & Wang, H. (2020). Detection of Fruit-Bearing Branches and Localization of Litchi Clusters for Vision-Based Harvesting Robots. *IEEE Access*, 8, 117746–117758. <https://doi.org/10.1109/ACCESS.2020.3005386>
- Liberati, A., Altman, D. G., Tetzlaff, J., Mulrow, C., Gøtzsche, P. C., Ioannidis, J. P. A., Clarke, M., Devereaux, P. J., Kleijnen, J., & Moher, D. (2009). The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. In *Journal of clinical epidemiology* (Vol. 62, Issue 10). <https://doi.org/10.1016/j.jclinepi.2009.06.006>
- Liu, Z., Wu, J., Fu, L., Majeed, Y., Feng, Y., Li, R., & Cui, Y. (2020). Improved Kiwifruit Detection Using Pre-Trained VGG16 with RGB and NIR Information Fusion. *IEEE Access*, 8, 2327–2336. <https://doi.org/10.1109/ACCESS.2019.2962513>
- Luo, Q., Rao, Y., Jin, X., Jiang, Z., Wang, T., Wang, F., & Zhang, W. (2022). Multi-Class on-Tree Peach Detection Using Improved YOLOv5s and Multi-Modal Images. *Smart Agriculture*, 4(4), 84–104. <https://doi.org/10.12133/j.smartag.SA202210004>

- Marco-Detchart, C., Carrascosa, C., Julian, V., & Rincon, J. (2023). Robust Multi-Sensor Consensus Plant Disease Detection Using the Choquet Integral. *Sensors*, 23(5). <https://doi.org/10.3390/s23052382>
- Mazzia, V., Khaliq, A., Salvetti, F., & Chiaberge, M. (2020). Real-time apple detection system using embedded systems with hardware accelerators: An edge AI application. *IEEE Access*, 8, 9102–9114. <https://doi.org/10.1109/ACCESS.2020.2964608>
- Miraei Ashtiani, S. H., Javanmardi, S., Jahanbanifard, M., Martynenko, A., & Verbeek, F. J. (2021). Detection of mulberry ripeness stages using deep learning models. *IEEE Access*, 9, 100380–100394. <https://doi.org/10.1109/ACCESS.2021.3096550>
- Palumbo, M., Cefola, M., Pace, B., Attolico, G., & Colelli, G. (2023). Computer vision system based on conventional imaging for non-destructively evaluating quality attributes in fresh and packaged fruit and vegetables. *Postharvest Biology and Technology*, 200(March), 112332. <https://doi.org/10.1016/j.postharvbio.2023.112332>
- Quinde, D. F., Cisneros Prieto, E. A., & Soto Galarza, I. A. (2021). Aplicación de Visión Artificial en Sistemas de Video Vigilancia con Reconocimiento Facial para el Control de Acceso. *Revista Científica Carácter*, 9(1), 16.
- Santillán, G., Danilo, I., Sánchez, C., & Manuel, V. (2015). *La visión artificial y los campos de aplicación*. April. <https://doi.org/10.32645/26028131.76>
- Sari, M. I., Fajar, R., Gunawan, T., & Handayani, R. (2022). The Use of Image Processing and Sensor in Tomato Sorting Machine by Color, Size, and Weight. *International Journal on Informatics Visualization*, 6(1–2), 244–249. <https://doi.org/10.30630/joiv.6.1-2.944>
- Shah, M. (1997). *Fundamentals of Computer Vision*. Orlando: University of Central Florida.
- Suharjito, Asrol, M., Utama, D. N., Junior, F. A., & Marimin. (2023). Real-Time Oil Palm Fruit Grading System Using Smartphone and Modified YOLOv4. *IEEE Access*, 11(June), 59758–59773. <https://doi.org/10.1109/ACCESS.2023.3285537>
- Tang, Y., Gao, S., Zhuang, J., Hou, C., He, Y., Chu, X., Miao, A., & Luo, S. (2020). Apple Bruise Grading Using Piecewise Nonlinear Curve Fitting for Hyperspectral Imaging Data. *IEEE Access*, 8, 147494–147506. <https://doi.org/10.1109/ACCESS.2020.3015808>
- Tian, Y., Duan, H., Luo, R., Zhang, Y., Jia, W., Lian, J., Zheng, Y., Ruan, C., & Li, C. (2019). Fast Recognition and Location of Target Fruit Based on Depth Information. *IEEE Access*, 7, 170553–170563. <https://doi.org/10.1109/ACCESS.2019.2955566>
- Tran, H. M., Pham, K. T., Vo, T. M., Le, T. H., Huynh, T. T. M., & Dao, S. V. T. (2023). A New Approach for Estimation of Physical Properties of Irregular Shape Fruit. *IEEE Access*, 11(May), 46550–46560. <https://doi.org/10.1109/ACCESS.2023.3273777>
- Valdivia Arias, C. J. (2016). *Diseño de un Sistema de Visión Artificial para la clasificación de chirimoyas basado en medidas*. Pontificia Universidad Católica del Perú. <http://hdl.handle.net/20.500.12404/7849>
- Véles, A. M., Sánchez, A., & Sánchez, J. (2003). Visión por Computador. In Dykinson (Ed.), *Universidad Rey Juan Carlos*.
- Vicuña, J., & Anelle, M. (2021). Lectura de Medidores Eléctricos Analógicos mediante Visión Artificial. *Universidad Católica de Cuenca*, 1–71.
- Wang, D., Li, C., Song, H., Xiong, H., Liu, C., & He, D. (2020). Deep Learning Approach for Apple Edge Detection to Remotely Monitor Apple Growth in Orchards. *IEEE Access*, 8, 26911–26925. <https://doi.org/10.1109/ACCESS.2020.2971524>

- Wu, L., Ma, J., Zhao, Y., & Liu, H. (2021). Apple detection in complex scene using the improved yolov4 model. *Agronomy*, *11*(3). <https://doi.org/10.3390/agronomy11030476>
- Xuan, G., Gao, C., Shao, Y., Zhang, M., Wang, Y., Zhong, J., Li, Q., & Peng, H. (2020). Apple Detection in Natural Environment Using Deep Learning Algorithms. *IEEE Access*, *8*, 216772–216780. <https://doi.org/10.1109/ACCESS.2020.3040423>
- Zhang, Q., & Gao, G. (2019). Grasping Point Detection of Randomly Placed Fruit Cluster Using Adaptive Morphology Segmentation and Principal Component Classification of Multiple Features. *IEEE Access*, *7*, 158035–158050. <https://doi.org/10.1109/ACCESS.2019.2946267>