



Universidad
Señor de Sipán

**FACULTAD DE INGENIERÍA, ARQUITECTURA
Y URBANISMO
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**

TRABAJO DE INVESTIGACIÓN

**Uso de Machine Learning para estimar la
producción de cultivos frutales: análisis de
tendencias y agenda de investigación**

**PARA OPTAR EL GRADO ACADÉMICO DE BACHILLER
EN INGENIERÍA DE SISTEMAS**

Autor(es)

Arcila Diaz Liliana Nataly

<https://orcid.org/0000-0003-1117-9571>

Asesor

Mg. Mejia Cabrera Heber Ivan

<https://orcid.org/0000-0002-0007-0928>

Línea de Investigación

**Ciencias de la información como herramientas
multidisciplinares y estratégicas en el contexto industrial
y de organizaciones**

Sublínea de Investigación

**Informática y transformación digital en el contexto industrial
y organizacional**

Pimentel – Perú

2024



Universidad
Señor de Sipán

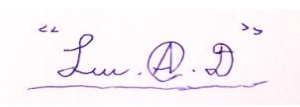
DECLARACIÓN JURADA DE ORIGINALIDAD

Quien suscribe la **DECLARACIÓN JURADA**, soy **Arcila Diaz Liliana Nataly**, del Programa de Estudios de **Ingeniería de Sistemas** de la Universidad Señor de Sipán S.A.C, declaro bajo juramento que soy autor el trabajo titulado:

Uso de Machine Learning para estimar la producción de cultivos frutales: análisis de tendencias y agenda de investigación

El texto de mi trabajo de investigación responde y respeta lo indicado en el Código de Ética de la Universidad Señor de Sipán (CIEI USS), conforme a los principios y lineamientos detallados en dicho documento, en relación a las citas y referencias bibliográficas, respetando el derecho de propiedad intelectual, por lo cual informo que la investigación cumple con ser inédito, original y autentico.

En virtud de lo antes mencionado, firman:

Arcila Diaz Liliana Nataly	DNI: 48085003	
----------------------------	------------------	---

Pimentel, 09 de setiembre de 2024.

Agradecimientos

Con el amor más sincero a Dios, nuestro Padre Celestial, por concederme la salud y la fortaleza necesarias para alcanzar este objetivo tan significativo en mi vida.

A mis padres Juan y Ana por apoyarme en todo momento. Todos mis logros son suyos.

A mi asesor Mg. Heber Ivan Mejia Cabrera por su orientación en el desarrollo de esta investigación.

Dedicatoria

A mis hermanos, Juan Carlos, Luis y Cesy, por su cariño, su apoyo incondicional y por ser una fuente constante de motivación en cada etapa de mi vida.

A mis docentes, por las valiosas enseñanzas que me han brindado a lo largo de mi carrera universitaria. Su compromiso con mi formación académica y personal ha sido fundamental para alcanzar este logro.

Índice general

Agradecimientos.....	iii
Dedicatoria	iv
Índice general.....	v
Índice de Figuras.....	vi
Índice de Tablas.....	vii
Resumen.....	viii
Abstract.....	ix
I. INTRODUCCIÓN	10
1.1. Realidad Problemática	10
1.2. Formulación del Problema	12
1.3. Hipótesis	12
1.4. Objetivos	12
1.4.1. Objetivo General	12
1.4.2. Objetivos Específicos.....	13
1.5. Teorías relacionadas al tema.....	13
II. MÉTODO DE INVESTIGACIÓN	25
2.1. Método de Investigación	25
2.2. Plan de investigación	26
2.3. Procedimiento de la Investigación.....	27
III. RESULTADOS	33
IV. DISCUSIÓN Y CONCLUSIONES.....	46
V. REFERENCIAS.....	50

Índice de Figuras

Figura 1. Aplicaciones de la IA en la agricultura.....	15
Figura 2. Filtrado bilateral con OpenCV.	16
Figura 3. Data augmentacion: (a) imagen original, (b) imagen con rotación.	17
Figura 4. Proceso de trabajo con Machine Learning.	19
Figura 5. Arquitectura del algoritmo Faster R-CNN.....	22
Figura 6. Arquitectura del algoritmo Faster R-CNN.....	23
Figura 7. Arquitectura del algoritmo Yolo V8.	24
Figura 8. Combinación de registros en RStudio	29
Figura 9. Diagrama de flujo PRISMA. Elaboración propia a partir de Scopus y WOS.	32
Figura 10. Cultivos con investigaciones para estimar su producción.	36
Figura 11. Investigaciones por año.....	38
Figura 12. Datos analizados para estimar la producción de los cultivos frutales..	38
Figura 13. Métodos de inteligencia artificial más utilizados para la estimación de la producción de cultivos frutales.	42

Índice de Tablas

Tabla 1. Expresiones de búsquedas usadas en las bases de datos consultadas.	28
Tabla 2. Criterios de inclusión y exclusión de la revisión.	30
Tabla 3. Artículos de investigación incluidos en el presente estudio.	33

Resumen

La estimación precisa de la producción de cultivos frutales es crucial para mejorar la planificación agrícola, optimizando la cosecha, el almacenamiento y la distribución, y, en última instancia, gestionando de manera más eficiente la cadena de suministro agrícola. Este estudio presenta una revisión sistemática sobre el uso de métodos de inteligencia artificial (IA) y machine learning (ML) en la estimación de la producción de cultivos frutales. Aplicando la metodología PRISMA, se identificaron 266 documentos en las bases de datos Scopus y Web of Science, de los cuales se analizaron 21 tras aplicar criterios de inclusión y exclusión. La investigación examina qué cultivos frutales utilizan técnicas de machine learning para la estimación de producción y qué técnicas muestran el mejor desempeño en la estimación o conteo de cultivos. Se identificaron tendencias emergentes, como la integración de variables climáticas, el uso de imágenes multiespectrales y la implementación de sistemas en tiempo real. Se propone una agenda de investigación para abordar las lagunas existentes, enfocándose en el desarrollo de soluciones ligeras y escalables para su implementación práctica en la agricultura.

Palabras claves: Fruit production, Production estimation, Machine learning, PRISMA Statement, Precision agriculture.

Abstract

Accurate estimation of fruit crop production is crucial for enhancing agricultural planning, optimizing harvest, storage, and distribution processes, and ultimately managing the agricultural supply chain more efficiently. This study presents a systematic review of the use of artificial intelligence (AI) and machine learning (ML) methods for estimating fruit crop production. Using the PRISMA methodology, 266 documents were identified from the Scopus and Web of Science databases, of which 21 were analyzed after applying inclusion and exclusion criteria. The research examines which fruit crops apply machine learning techniques for production estimation and which techniques perform best in estimating or counting fruit crops. Emerging trends were identified, such as the integration of climatic variables, the use of multispectral images, and the implementation of real-time systems. An agenda for future research is proposed to address existing gaps, focusing on the development of lightweight and scalable solutions for practical implementation in agriculture.

Keywords: Fruit production, Production estimation, Machine learning, PRISMA Statement, Precision agriculture.

I. INTRODUCCIÓN

1.1. Realidad Problemática

La estimación precisa de la producción de cultivos frutales es fundamental para la industria agrícola, ya que permite a los agricultores planificar de manera eficiente la cosecha, distribución y comercialización de los productos, de esta estimación dependen la organización y la logística necesarias para la recolección, la planificación del almacenamiento, el control del inventario y el abastecimiento de mercados. Tradicionalmente, esta tarea se ha llevado a cabo mediante métodos manuales, que son laboriosos, costosos y frecuentemente imprecisos debido a la variabilidad natural en el crecimiento y la producción de los cultivos [1] [2].

En los últimos años, el avance de las tecnologías de la información y la disponibilidad de grandes volúmenes de datos han fomentado la adopción de técnicas de aprendizaje automático (Machine Learning, ML) en diversos ámbitos, incluida la agricultura. El aprendizaje automático ofrece una alternativa prometedora para la estimación de la producción de cultivos frutales, al poder manejar grandes conjuntos de datos, identificar patrones complejos y mejorar la precisión de las predicciones [2].

Las investigaciones científicas en este ámbito han analizado diversas metodologías y algoritmos de aprendizaje automático con el propósito de abordar el desafío de la estimación de la producción de cultivos frutales [3]. Dentro de estos enfoques se destacan modelos de regresión, árboles de decisión, redes neuronales artificiales [4] [5], así como técnicas de aprendizaje profundo [6], cada uno presentando ventajas y limitaciones específicas. Los estudios indican que estos métodos son capaces de integrar múltiples fuentes de datos, tales como imágenes satelitales, imágenes multiespectrales [7], datos climáticos, características del suelo y variables fisiológicas de los cultivos, permitiendo la generación de estimaciones más precisas y confiables.

La integración del aprendizaje automático en la agricultura de precisión no solo optimiza la estimación de la producción, sino que también permite una gestión más sostenible y eficiente de los recursos agrícolas, contribuyendo a la seguridad alimentaria y a la reducción del desperdicio de alimentos. A medida que la tecnología continúa evolucionando, es probable que las técnicas de aprendizaje automático se vuelvan aún más sofisticadas y accesibles, potenciando su impacto en la estimación de la producción de cultivos frutales y en la agricultura en general.

La investigación sobre la aplicación de la inteligencia artificial, en particular el aprendizaje automático, para la estimación de la producción frutal en cultivos mediante imágenes de los cultivos, presenta ciertas lagunas que justifican el uso de la bibliometría para evaluar y analizar el estado actual de la literatura científica en este campo. Una de las principales deficiencias es la necesidad de examinar los algoritmos y enfoques de inteligencia artificial empleados en la estimación de la producción frutal, lo cual podría influir en la precisión y eficacia de los métodos. Aunque existen estudios previos sobre la estimación de la producción de frutos mediante inteligencia artificial [2], esta revisión ofrecerá un análisis detallado de los métodos de aprendizaje automático.

El desarrollo de un estudio de revisión, basado en la literatura científica, permitirá recopilar, analizar y sintetizar información de diversas fuentes académicas, proporcionando así una visión integral del estado actual de la investigación sobre el uso del aprendizaje automático en la estimación de la producción de cultivos frutales. En este contexto, el objetivo de esta investigación es examinar las tendencias en el uso del aprendizaje automático para la estimación de la producción frutal, con el propósito de ofrecer una agenda para futuras investigaciones.

1.2. Formulación del Problema

La estimación precisa de la producción de cultivos frutales es un desafío en la agricultura, con implicaciones significativas para la planificación de la producción, la gestión de recursos y la optimización de la cadena de suministro. En los últimos años, el aprendizaje automático ha emergido como una herramienta prometedora para mejorar estas predicciones, pero existen diversidad de enfoques; esto plantea la necesidad de un análisis exhaustivo de las metodologías actuales y una identificación de las áreas emergentes y las brechas en la investigación sobre el uso de machine learning para la estimación de la producción frutal.

La presente investigación se plantea la siguiente formulación:

¿Qué métodos de inteligencia artificial, incluyendo machine learning y otras técnicas de visión por computador, se posicionan como prioritarios en comparación con enfoques tradicionales para la estimación de la producción de cultivos frutales, con el fin de diseñar una agenda de investigación?

1.3. Hipótesis

Los métodos de inteligencia artificial, particularmente aquellos basados en machine learning, se posicionan como los más eficaces y prometedores en comparación con los enfoques tradicionales para la estimación de la producción de cultivos frutales y, por lo tanto, deben ser priorizados en la agenda de investigación.

1.4. Objetivos

1.4.1. Objetivo General

Identificar y analizar los temas clave en la investigación sobre el uso de machine learning para la estimación de la producción de cultivos frutales, con el fin de proponer una agenda de investigación para trabajos futuros.

1.4.2. Objetivos Específicos

- a) Seleccionar y analizar documentos de investigación relevantes sobre métodos de inteligencia artificial y machine learning para la estimación de la producción de cultivos frutales
- b) Analizar los métodos de inteligencia artificial y machine learning utilizados para la estimación de la producción de cultivos frutales.
- c) Comparar el desempeño de los métodos de inteligencia artificial y machine learning utilizados en la estimación de la producción de cultivos frutales.
- d) Proponer una agenda de investigación que priorice los temas emergentes y tendencias en la investigación sobre el uso de machine learning para la estimación de la producción en cultivos frutales.

1.5. Teorías relacionadas al tema

En este apartado se incluyen los fundamentos que soportan la parte teórica de las técnicas de inteligencia artificial, machine learning y visión por computador utilizados para la estimación de producción de cultivos frutales.

1.5.1. Inteligencia artificial

El concepto de "Inteligencia Artificial" fue introducido en 1956 por John McCarthy en una conferencia en Dartmouth College. Desde ese momento, la comunidad científica comenzó a explorar la posibilidad de desarrollar máquinas capaces de replicar la inteligencia humana, sin embargo, las limitaciones tecnológicas de la época restringieron considerablemente el progreso en este campo. En las décadas de 1970 y 1980, surgieron los sistemas expertos, estos representaron uno de los primeros intentos por formalizar el conocimiento humano y aplicarlo

en sistemas computacionales. En la década de 1990, el enfoque comenzó a desplazarse hacia el aprendizaje automático, con la introducción de algoritmos como las máquinas de soporte vectorial (SVM) y los árboles de decisión, facilitando la identificación de patrones en grandes conjuntos de datos. Los avances en el procesamiento del lenguaje natural también permitieron el surgimiento de asistentes virtuales y sistemas de traducción automática. En 2006, Geoffrey Hinton y colaboradores introdujeron el aprendizaje profundo (Deep Learning, DL), una subdisciplina basada en redes neuronales profundas que ha transformado significativamente la inteligencia artificial, especialmente en campos como la visión por computadora, el reconocimiento del habla y el procesamiento del lenguaje natural [8].

En el siglo XXI, el aprendizaje profundo y las redes neuronales han revolucionado la inteligencia artificial, impulsando su aplicación en áreas como la robótica, los vehículos autónomos, la atención médica y los sistemas de recomendación. Este avance ha sido posible gracias al aumento de la capacidad computacional, la disponibilidad de grandes volúmenes de datos y el desarrollo de algoritmos innovadores [9].

Inteligencia artificial en la agricultura

La incorporación de la IA en el ámbito agrícola está reconfigurando significativamente el sector al proporcionar soluciones avanzadas que optimizan la producción y la gestión de cultivos. A través de la aplicación de algoritmos de aprendizaje automático y técnicas de análisis de datos, la IA permite prever el rendimiento de los cultivos, perfeccionar los procesos de fertilización, riego y cosecha, así como gestionar riesgos, mejorar la calidad de las semillas, monitorizar la salud de las plantas y optimizar tanto el procesamiento como el almacenamiento de alimentos. Estas innovaciones no solo incrementan la

productividad y reducen los costos operativos, sino que también promueven prácticas agrícolas más sostenibles, consolidando la IA como una herramienta esencial para el desarrollo futuro de la agricultura.



Figura 1. Aplicaciones de la IA en la agricultura.

Fuente: [10].

1.5.2. Procesamiento de imágenes

Filtros

En el procesamiento de imágenes, los filtros son técnicas diseñadas para modificar o mejorar ciertas características de una imagen, como la reducción de ruido, el realce de bordes o el suavizado [11]. Estas técnicas emplean operaciones matemáticas que se aplican a los píxeles de la imagen para lograr los efectos deseados. Los filtros se dividen en dos categorías principales: filtros lineales y filtros no lineales. Los filtros lineales utilizan operaciones matemáticas que se basan en combinaciones lineales de los píxeles vecinos, mientras que los filtros no lineales aplican transformaciones que no siguen una relación lineal entre los píxeles.

Filtros lineales

Los filtros lineales en procesamiento de imágenes son técnicas que aplican operaciones matemáticas basadas en combinaciones lineales de los valores de los píxeles vecinos. En esencia, un filtro lineal calcula el valor de cada píxel en la imagen de salida como una suma ponderada de los valores de los píxeles en la vecindad del píxel correspondiente en la imagen de entrada. Esto se realiza mediante el uso de un núcleo (o kernel) que se desliza sobre la imagen para aplicar la operación deseada. Ejemplos comunes de filtros lineales incluyen el filtro de suavizado (blurring) y el filtro de detección de bordes, como el filtro de Sobel.

Filtros no lineales

Los filtros no lineales, por otro lado, utilizan operaciones matemáticas que no se basan en combinaciones lineales de los valores de los píxeles vecinos. Estos filtros aplican transformaciones que pueden ser más complejas y adaptativas, lo que permite abordar tareas como la eliminación de ruido impulsivo, el realce de características específicas o la preservación de bordes. Un ejemplo típico de un filtro no lineal es el filtro de mediana, que reemplaza el valor de un píxel con la mediana de los valores de los píxeles en su vecindad, ayudando a eliminar el ruido sin afectar significativamente los bordes.




Figura 2. Filtrado bilateral con OpenCV.

Fuente: [11]

Aumento de datos

El aumento de datos (data augmentation) es una técnica utilizada en el aprendizaje automático y el procesamiento de imágenes para incrementar la cantidad y diversidad de datos disponibles para el entrenamiento de modelos. Esto se logra mediante la creación de nuevas muestras de datos a partir de las existentes, aplicando transformaciones y variaciones a los datos originales [12]. Las técnicas comunes de aumento de datos incluyen la rotación, el escalado, la traslación, el recorte, la inversión y la modificación del brillo y contraste en imágenes.




Figura 3. Data augmentation: (a) imagen original, (b) imagen con rotación.

Los tipos principales incluyen:

Transformaciones Geométricas: Rotación, escalado, traslación, recorte y reflexión para cambiar la perspectiva de la imagen.

Modificaciones de Color: Ajustes en brillo, contraste y saturación para simular diferentes condiciones de iluminación.

Ruido y Perturbaciones: Introducción de ruido o distorsiones para emular condiciones imperfectas.

Transformaciones de Espacio: Aplicación de transformaciones lineales o mapeo a otras perspectivas.

Modificación de Datos en el Dominio de la Imagen: Corte aleatorio y mezcla de imágenes para variar los datos.

Aumento Basado en el Contexto: Creación de datos sintéticos y cambio de fondo para diversificar el entorno.

Etiquetado de datos

El etiquetado de datos es el proceso de asignar información específica a los datos brutos para que puedan ser utilizados en modelos de aprendizaje automático. Este proceso implica la identificación y anotación de características o categorías relevantes en los datos para entrenar y evaluar algoritmos. La calidad y precisión del etiquetado son cruciales para el rendimiento y la exactitud de los modelos entrenados [13].

Tipos de Etiquetado de Datos:

Etiquetado Clasificadorio

Asignación de una etiqueta a cada muestra para clasificarla en una categoría.

Etiquetado de Objetos

Identificación y anotación de objetos dentro de imágenes mediante cuadros delimitadores, máscaras o puntos clave.

Etiquetado de Segmentación

Anotación precisa de áreas específicas en imágenes para identificar regiones de interés.

Etiquetado de Texto

Anotación de texto con categorías o entidades específicas, como partes del discurso, entidades nombradas o sentimientos.

1.5.3. Machine Learning

El Aprendizaje Automático, un subcampo de la Inteligencia Artificial, otorga a los sistemas computacionales la capacidad de adquirir conocimientos y realizar tareas sin necesidad de ser programados explícitamente. En lugar de establecer directrices precisas para la ejecución de una tarea, los sistemas de Aprendizaje Automático son capaces de aprender y mejorar su desempeño de manera autónoma mediante el análisis de datos, ajustándose y optimizándose conforme reciben información adicional (ver Figura 4).

El proceso de aprendizaje se puede categorizar en tres tipos principales: aprendizaje supervisado (SL), aprendizaje no supervisado (UL), aprendizaje semi-supervisado (SSL) y Reinforcement Learning (RL) [14] [15].

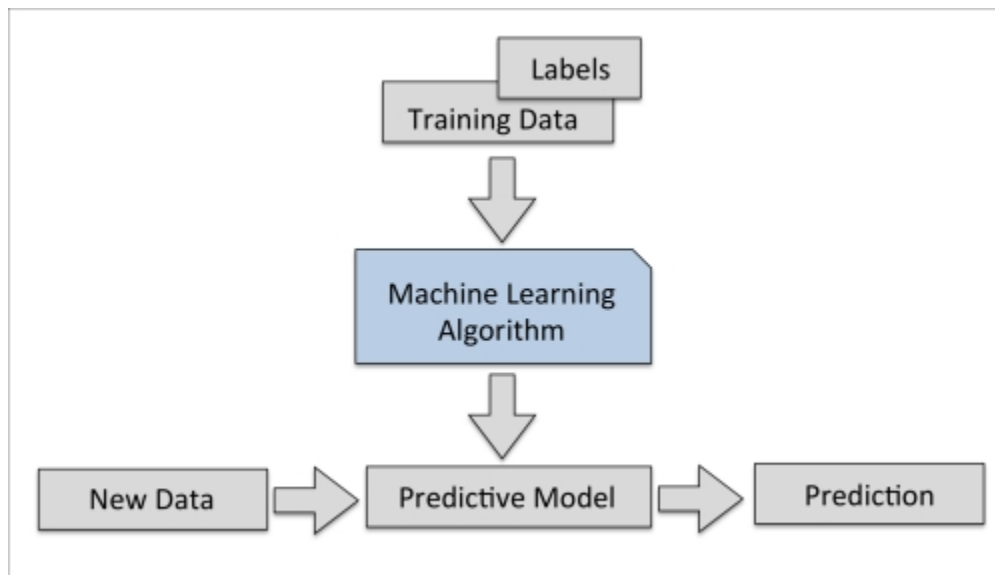


Figura 4. Proceso de trabajo con Machine Learning.

Fuente: [16]

Aprendizaje Supervisado

Es un enfoque de machine learning en el que un modelo se entrena utilizando un conjunto de datos etiquetado. En este proceso, el modelo recibe ejemplos de entrada junto con las correspondientes etiquetas o respuestas correctas. El objetivo es que el modelo aprenda una función que mapea las entradas a las etiquetas, de manera que pueda predecir correctamente las etiquetas para nuevos datos no vistos. Los algoritmos de aprendizaje supervisado incluyen regresión lineal, SVM y redes neuronales [15].

Aprendizaje No Supervisado

Es un método en el que el modelo se entrena con datos que no están etiquetados, es decir, sin respuestas predeterminadas. En lugar de aprender a predecir una etiqueta, el objetivo es descubrir patrones, estructuras o agrupamientos subyacentes en los datos. Los algoritmos de aprendizaje no supervisado incluyen el análisis de clústeres (como K-means) y el análisis de componentes principales (PCA).

Aprendizaje por Refuerzo

Es un paradigma de machine learning en el que un agente aprende a tomar decisiones mediante la interacción con un entorno. El agente realiza acciones y recibe recompensas o penalizaciones en función de los resultados de esas acciones. El objetivo es maximizar la recompensa acumulada a lo largo del tiempo mediante la mejora continua de la política de decisiones. Los algoritmos de aprendizaje por refuerzo incluyen el Q-learning y las redes neuronales profundas aplicadas al refuerzo, como las redes neuronales profundas con Q-learning (DQN).

1.5.4. Técnicas de detección de objetos

La percepción visual en los seres humanos es esencial para la adquisición de información sobre el entorno. Las imágenes y los vídeos representan las principales fuentes de datos visuales y han sido ampliamente utilizadas en diferentes aplicaciones de visión por computadora. En este ámbito, la detección de objetos emerge como una de las áreas más cruciales, con el propósito de identificar y localizar objetos específicos en imágenes o secuencias de vídeo [17].

Arquitecturas de redes neuronales convolucionales (CNN)

La detección de objetos mediante CNN se clasifica en dos enfoques predominantes: detección en dos etapas y detección en una etapa. Los modelos de detección en dos etapas se basan en la generación de regiones de interés (RoI) para producir candidatos a cuadros delimitadores, de los cuales se extraen características para la identificación de los objetos. En contraste, los métodos de detección en una etapa integran ambos procesos —la localización y la clasificación— en un único paso, omitiendo el uso del mecanismo RoI [17].

Detección de dos etapas

Regions with Convolutional Neural Networks (R-CNN)

R-CNN es un algoritmo de detección de objetos que combina redes CNN con un enfoque de propuesta de regiones. En este método, primero se generan un conjunto de propuestas de ROI mediante un algoritmo de selección de regiones, como Selective Search. Cada una de estas regiones se procesa a través de una CNN para extraer características, las cuales luego se utilizan para clasificar los objetos y refinar las cajas delimitadoras. R-CNN marcó un avance significativo

al aplicar CNN para la extracción de características de las regiones propuestas [18].

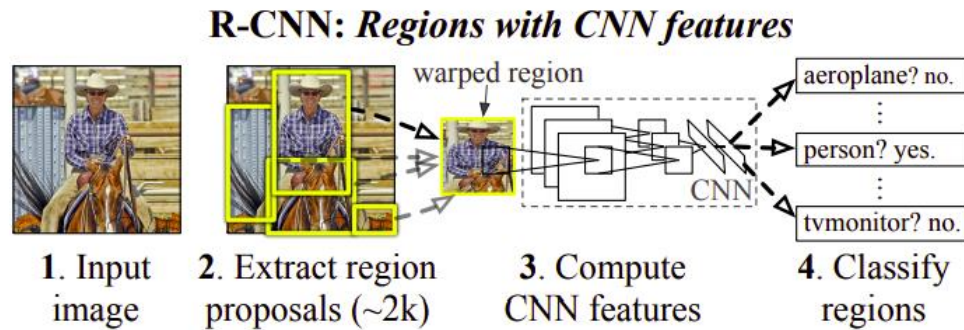


Figura 5. Arquitectura del algoritmo Faster R-CNN

Fuente [18].

Fast R-CNN

Fast R-CNN es una mejora de R-CNN que busca abordar sus limitaciones en términos de velocidad y eficiencia. En lugar de procesar cada región propuesta de forma independiente, Fast R-CNN utiliza una sola red CNN para procesar toda la imagen de entrada y luego extrae las características para cada ROI mediante un mecanismo de pooling ROI. Esto permite una clasificación y una localización más rápida y precisa de los objetos, ya que la red realiza el procesamiento de la imagen una sola vez y luego aplica una capa de red neuronal completamente conectada para cada ROI [19].

Faster R-CNN

Faster R-CNN lleva la eficiencia un paso más allá al introducir un módulo de propuesta de regiones conocido como Region Proposal Network (RPN), que se integra directamente con la red CNN. En este enfoque, la RPN genera propuestas de ROI en paralelo con la extracción de características de la imagen, eliminando la necesidad de métodos externos de generación de regiones como

Selective Search. Esto permite a Faster R-CNN realizar la detección de objetos en tiempo real con alta precisión [20].

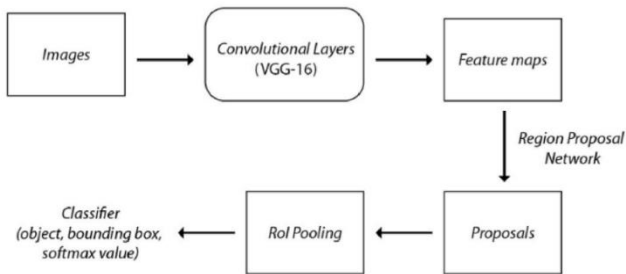


Figura 6. Arquitectura del algoritmo Faster R-CNN.

Fuente: [21].

Detección de una etapa

You Only Look Once (YOLO)

YOLO es un algoritmo de detección de objetos que adopta un enfoque de una sola etapa para identificar y localizar objetos en una imagen. En lugar de dividir el proceso en varias etapas, YOLO trata la detección como un problema de regresión directa, prediciendo simultáneamente las ubicaciones de los cuadros delimitadores y las clases de los objetos en una única pasada de la red. Este enfoque permite una detección extremadamente rápida y es especialmente eficaz para aplicaciones en tiempo real [22].

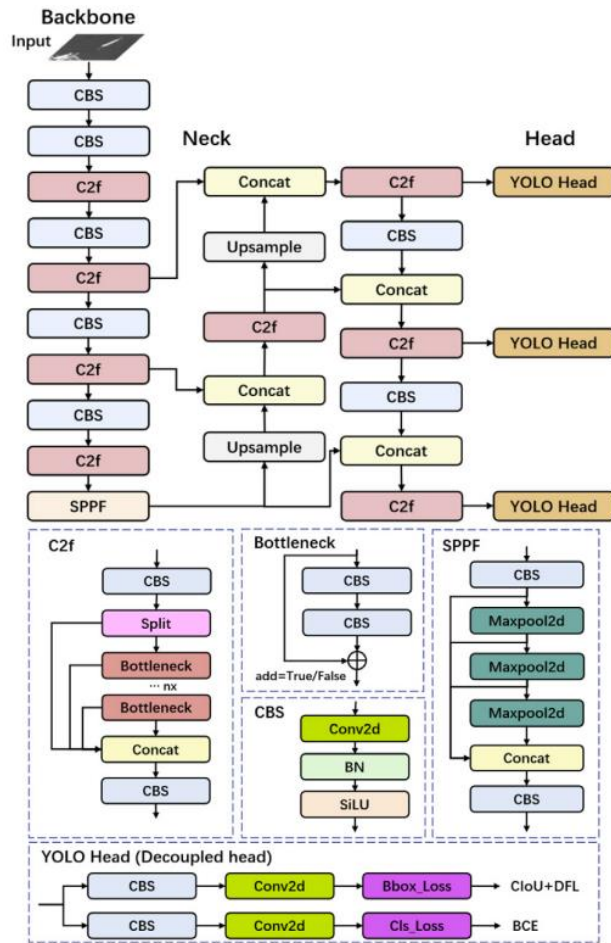


Figura 7. Arquitectura del algoritmo Yolo V8.

Fuente: [23]

RetinaNet

RetinaNet es un algoritmo de detección de objetos que introduce el concepto de "Focal Loss" para abordar el problema del desequilibrio de clases en la detección de objetos. Mientras que los métodos tradicionales pueden verse abrumados por el gran número de negativos (fondo) en comparación con los positivos (objetos), RetinaNet utiliza la Focal Loss para reducir el peso de los ejemplos negativos y enfocarse más en los ejemplos positivos difíciles de clasificar [24].

II. MÉTODO DE INVESTIGACIÓN

2.1. Método de Investigación

El objetivo que se plantea en este trabajo de investigación es Identificar y analizar los temas clave en la investigación sobre el uso de machine learning para la estimación de la producción de cultivos frutales, con el fin de proponer una agenda de investigación para trabajos futuros. Para alcanzar dicho objetivo este trabajo se plantea tres preguntas de investigación:

PI1. ¿Cuáles son los cultivos frutales en las que más se aplican técnicas de machine learning para la estimación de la producción?

PI2. ¿Cuáles son los métodos de inteligencia artificial, machine learning, y visión por computador utilizados actualmente para la estimación de la producción de cultivos frutales?

PI3. ¿Cuáles son los métodos de inteligencia artificial, machine learning, y visión por computador más efectivos para la estimación de la producción en cultivos frutales?

Con el propósito de alcanzar el objetivo de la investigación, se ha llevado a cabo un análisis bibliométrico siguiendo la metodología establecida por la declaración PRISMA 2020 [25] para revisiones de literatura. Esta metodología se centra en el análisis de metadatos, ofreciendo una visión global y exhaustiva del estado actual de la investigación sobre la aplicación de modelos de machine learning en la estimación de la producción de cultivos frutales. El método PRISMA, ampliamente reconocido y recientemente implementado, permite una mayor rigurosidad en la definición de criterios de inclusión y exclusión de estudios, lo que contribuye a reducir los sesgos en la selección y revisión de la literatura científica.

Fuentes de información

Las bases de datos Scopus y Web of Science (WOS) han sido seleccionadas para la búsqueda de publicaciones académicas en esta investigación, dado su creciente uso entre investigadores a nivel mundial para acceder a información científica de relevancia [26].

2.2. Plan de investigación

En el presente trabajo se ha utilizado el diseño metodológico PRISMA recomendado por Urrútia y Bonfill (2010) [27]. Esta metodología rigurosa garantiza la confiabilidad y validez de los resultados obtenidos en el análisis bibliométrico y contribuye a la objetividad de la investigación.

La metodología PRISMA consta de 3 etapas principales:

Identificación

En la etapa de Identificación, se lleva a cabo la búsqueda exhaustiva de estudios relevantes para la revisión sistemática. El objetivo es localizar todos los estudios que podrían ser pertinentes según los criterios establecidos.

Desarrollo de estrategia de búsqueda: Se diseñan estrategias detalladas de búsqueda utilizando términos específicos y combinaciones de palabras clave en bases de datos académicas y otras fuentes relevantes.

Ejecución de la búsqueda: Se realiza la búsqueda en múltiples bases de datos y registros (por ejemplo, PubMed, Scopus, WOS) para reunir una amplia gama de estudios.

Registro de resultados: Se recopilan y registran los resultados de la búsqueda, incluidos los títulos y resúmenes de los estudios encontrados.

Screening (Filtrado)

La etapa de Screening implica el proceso de filtrado para seleccionar estudios relevantes a partir de la lista de estudios identificados. En esta etapa, se revisan los títulos y resúmenes para determinar cuáles cumplen con los criterios de inclusión.

Revisión de títulos y resúmenes: Se examinan los títulos y resúmenes de los estudios identificados para eliminar aquellos que claramente no cumplen con los criterios de inclusión.

Evaluación de textos completos: Los estudios que pasan el primer filtro se revisan en su totalidad para evaluar si cumplen con los criterios específicos de inclusión y exclusión definidos en el protocolo de revisión.

Decisión de inclusión o exclusión: Basado en la revisión de textos completos, se decide si un estudio debe ser incluido en la revisión sistemática o excluido.

Inclusión

En la etapa de Inclusión, se identifican y seleccionan los estudios finales que serán analizados en la revisión sistemática. Esta etapa asegura que solo los estudios que cumplen con todos los criterios de calidad y relevancia se incluyan en la síntesis.

Extracción de datos: Se extraen datos clave de los estudios incluidos, como características del estudio, intervenciones, resultados y calidad.

Evaluación de calidad: Se evalúa la calidad metodológica de los estudios incluidos utilizando herramientas de evaluación de calidad.

Síntesis de resultados: Se combinan y analizan los resultados de los estudios para proporcionar una visión completa y clara de la evidencia disponible.

Estas etapas aseguran que el proceso de revisión sistemática sea exhaustivo, riguroso y transparente, lo que mejora la validez y la utilidad de las conclusiones de la revisión.

2.3. Procedimiento de la Investigación

Identificación de artículos científicos

El proceso de búsqueda bibliométrica en las dos bases de datos seleccionadas se realizó el 20 de agosto de 2024, las búsquedas bibliográficas posteriores a esta fecha pueden arrojar un mayor volumen de información, lo que refleja el panorama cambiante de la

investigación en el campo. Las ecuaciones de búsqueda que se muestran en la tabla 1 fueron diseñadas con un enfoque científico en tercera persona para asegurar la identificación precisa de estudios relevantes sobre estimación de la producción de cultivos frutales. Inicialmente se quería considerar el término “fruit” pero utilizando el operador “OR” se ha combinado con la mayor variedad de cultivos frutales. Para relacionarlo con la producción, se cruzó con los términos "production" o "estimation". Se ha completo la búsqueda incluyendo términos de “machine learning”, “inteligencia artificial” y otras técnicas específicas de inteligencia artificial.

Tabla 1. Expresiones de búsquedas usadas en las bases de datos consultadas.

Base de datos	Ecuación de búsqueda
SCOPUS	(TITLE-ABS-KEY(("fruit" or "mango" OR "banana" OR "apple" OR "orange" OR "pear" OR "grape" OR "peach" OR "plum" OR "cherry" OR "strawberry" OR "raspberry" OR "blueberry" OR "apricot" OR "kiwi" OR "pomegranate" OR "fig" OR "lime" OR "lemon" OR "grapefruit" OR "papaya" OR "melon") and "production" and "estimation") AND TITLE-ABS-KEY("machine learning" OR "artificial intelligence" OR "deep learning" OR "neural networks" OR "CNN" OR "support vector machines" OR "decision trees" OR "random forests" OR "genetic algorithms" OR "fuzzy logic" OR "ensemble methods" OR "reinforcement learning"))
WOS	(TS=("fruit" OR "mango" OR "banana" OR "apple" OR "orange" OR "pear" OR "grape" OR "peach" OR "plum" OR "cherry" OR "strawberry" OR "raspberry" OR "blueberry" OR "apricot" OR "kiwi" OR "pomegranate" OR "fig" OR "lime" OR "lemon" OR "grapefruit" OR "papaya" OR "melon") AND TS=("production" AND "estimation") AND TS=("machine learning" OR "artificial intelligence" OR "deep learning" OR "neural networks" OR "CNN" OR "support vector machines" OR "decision trees" OR "random forests" OR "genetic algorithms" OR "fuzzy logic" OR "ensemble methods" OR "reinforcement learning"))

La búsqueda inicial arrojó 238 y 28 artículos, respectivamente, de Scopus y WOS publicados desde el año 2000 hasta el presente. Utilizando RStudio se han combinado los registros eliminando los duplicados, se ha utilizado el siguiente script en RStudio.

```

installed.packages("bibliometrix")
library(bibliometrix)
install.packages("openxlsx")
library(openxlsx)

setwd("D:/bib")

web_data<-convert2df("wos.txt")

scopus_data<-convert2df("scopus.bib",dbsource = "scopus", format
= "bibtex")

combined<-mergeDbSources(web_data, scopus_data, remove.duplicated
= TRUE)

write.xlsx(combined, file = "databasead.xlsx")

```

Estos registros se almacenaron en una hoja de cálculo de Excel®. Del total de 266 artículos se han removido 25 duplicados, quedando solamente 241 documentos.

Data	
▶ combined	241 obs. of 27 variables
▶ scopus_data	238 obs. of 33 variables
▶ web_data	28 obs. of 67 variables

Figura 8. Combinación de registros en RStudio

Screening - Criterios de elegibilidad

La selección ha incluido artículos científicos publicados en revistas y actas de congresos indexados en las bases de datos correspondientes. Se consideran artículos en todos los idiomas, siempre que los metadatos estén uniformemente traducidos al inglés en las bases de datos. Además, se realiza un análisis cronológico exhaustivo, incorporando artículos de

todos los años disponibles que cumplan con los criterios establecidos, asegurando así una cobertura integral de la literatura relevante.

Además, se han establecidos tres fases de exclusión que se muestran en la tabla 2; en la primera fase se descartan todos los registros con indización incorrecta; en la segunda fase se excluyen las revisiones sistemáticas; finalmente en la tercera fase de exclusión se eliminan aquellos registros que no están centrados en la estimación de producción de cultivos frutales, clasificación de frutos en entornos supervisados, aplican técnicas de machine learning y datos históricos de producción. Con estos criterios se garantiza la integridad y confiabilidad de los datos utilizados en el análisis bibliométrico.

Tabla 2. Criterios de inclusión y exclusión de la revisión.

Fases	Criterios de inclusión	Criterios de exclusión
Fase 1	Indización incorrecta	
Fase 2	Artículos originales	Artículos de revisión
Fase 3	Centrado en la estimación de producción de cultivos frutales	No centrado en la estimación de producción de cultivos frutales
	Detección y conteo de frutos en cultivos frutales	Clasificación de frutos en entornos supervisados
	Aplican técnicas de visión por computador y de datos históricos	Base de datos para estimación

Durante la fase de cribado, el investigador principal y el asesor examinaron 241 títulos y resúmenes, aplicando los criterios de inclusión y exclusión previamente definidos y especificados en la Tabla 1, así como el criterio de accesibilidad al documento. Los registros que suscitaron incertidumbres respecto a su inclusión o exclusión fueron marcados como "Tal vez" y sometidos a discusión con el otro investigador.

De los 228 artículos iniciales identificados, se incluyeron un total de 21 en este trabajo. La reducción en la cantidad se debió a la exclusión de 13 artículos con indexación incompleta y 181 artículos que resultaron no ser relevantes para el estudio. Además, se excluyeron 20 artículos de tipo review, 3 data papers, 1 libro, 1 carta y 1 editorial. Como resultado de esta revisión, se excluyeron 200 registros, quedando 21 artículos para proceder con la revisión exhaustiva del texto completo.

Elementos de los datos

La Figura 9 sintetiza el diseño metodológico recomendado en [27] empleado en esta investigación, proporcionando un diagrama de flujo que ilustra de manera clara el proceso seguido. Esta metodología rigurosa garantiza la confiabilidad y validez de los resultados obtenidos en el análisis bibliométrico y contribuye a la objetividad de la investigación.

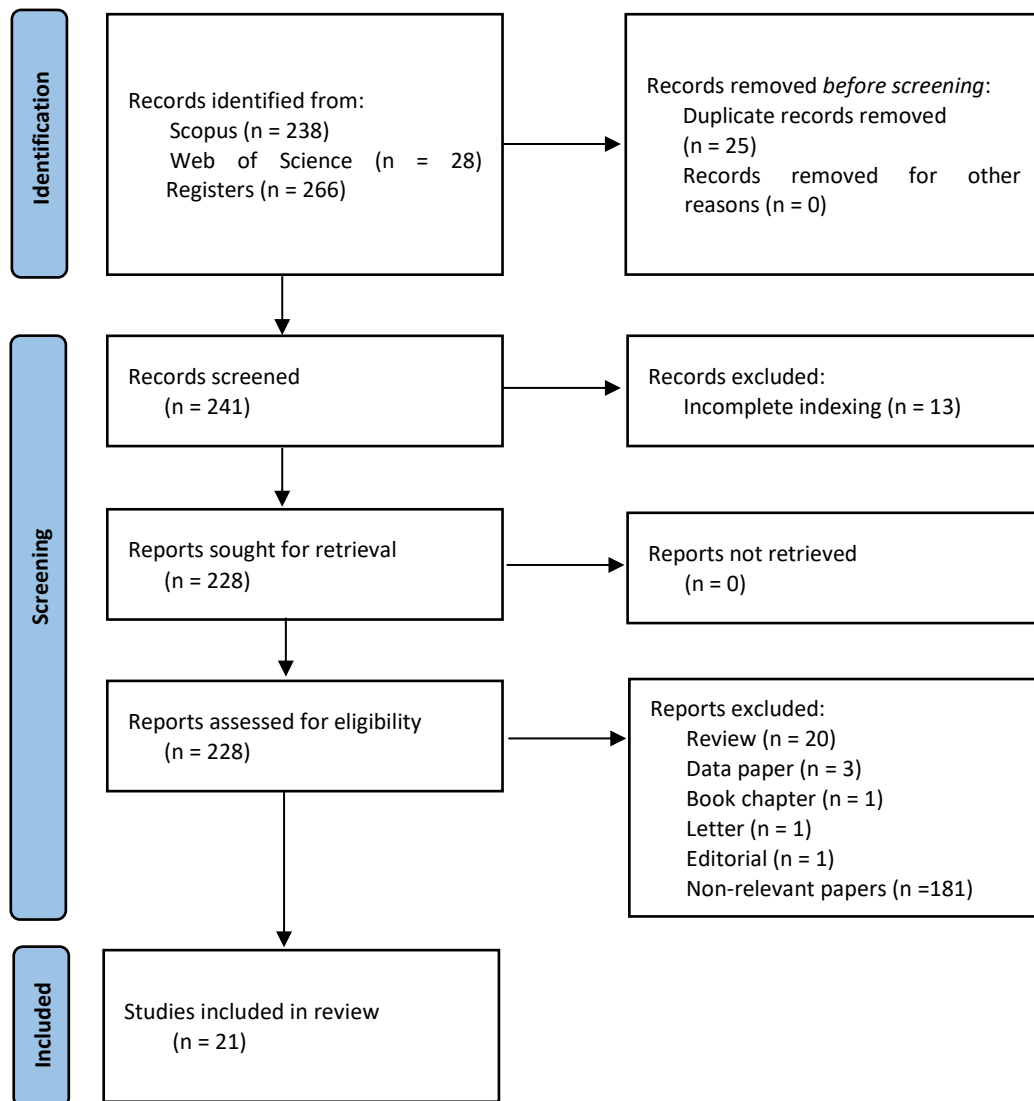


Figura 9. Diagrama de flujo PRISMA. Elaboración propia a partir de Scopus y WOS.

III. RESULTADOS

Los resultados obtenidos en la presente investigación se presentan considerando los objetivos específicos.

a. Documentos de investigación relevantes sobre estimación de producción de cultivos frutales

Después de realizar el análisis de los documentos se han identificado 21 investigaciones, cuyos datos principales se detallan en la Tabla 3. Estas investigaciones se han organizado en función del número total de citas recibidas.

Tabla 3. Artículos de investigación incluidos en el presente estudio.

#	Fruto	Técnica	Resultado	Datos	Título	Año	Revista	# Citas
1	Apple	YOLO v4-tiny	91.49 % accuracy	Imágenes RGB	A NOVEL APPLE FRUIT DETECTION AND COUNTING METHODOLOGY BASED ON DEEP LEARNING AND TRUNK TRACKING IN MODERN ORCHARD [28]	2022	Computers and Electronics in Agriculture	70
2	Citrus	YOLO v5	97.66% recall	Imágenes RGB	GREEN CITRUS DETECTION AND COUNTING IN ORCHARDS BASED ON YOLOV5CS AND AI EDGE SYSTEM [29]	2022	Sensors	47
3	Grape	Artificial neural network (ANN)	R = 0.95	Imágenes satelitales	PREDICTION OF GRAPE YIELDS FROM TIME-SERIES VEGETATION INDICES USING SATELLITE REMOTE SENSING AND A MACHINE-LEARNING APPROACH [30]	2021	Remote Sensing Applications Society and Environment	50
4	Banana	ANN	R ² =91%	Datos vegetativos	UTILIZATION OF ARTIFICIAL NEURAL NETWORKS IN THE PREDICTION OF THE BUNCHES WEIGHT IN BANANA PLANTS [31]	2013	Scientia Horticulturae	38
5	Grape	Desarrollo propio	92% accuracy	Imágenes RGB	A VISION-BASED ROBUST GRAPE BERRY COUNTING ALGORITHM FOR FAST CALIBRATION-FREE BUNCH WEIGHT ESTIMATION IN THE FIELD [32]	2020	Computers and Electronics in Agriculture	36
6	Kiwi	SVM mejorado FCN-8S	R ² =0.96	Imágenes RGB	DESIGN DEVELOPMENT AND PERFORMANCE EVALUATION OF A ROBOT FOR YIELD	2021	Computers and Electronics	36

					ESTIMATION OF KIWIFRUIT [33]		in Agriculture	
7	Melon	RetinaNet	92% precision	Imágenes RGB UAV	A DEEP LEARNING SYSTEM FOR SINGLE AND OVERALL WEIGHT ESTIMATION OF MELONS USING UNMANNED AERIAL VEHICLE IMAGES [34]	2020	Computers and Electronics in Agriculture	35
8	Apple	Multi Hypothesis Tracking	97% accuracy	Imágenes RGB	APPLE ORCHARD PRODUCTION ESTIMATION USING DEEP LEARNING STRATEGIES A COMPARISON OF TRACKING BY DETECTION ALGORITHMS [35]	2023	Computers and Electronics in Agriculture	24
9	Cactus pear	ANN	$R^2=0.87$	Datos vegetativos	PREDICTION OF GIGANTE CACTUS PEAR YIELD BY MORPHOLOGICAL CHARACTERS AND ARTIFICIAL NEURAL NETWORKS [36]	2018	Revista Brasileira de Engenharia Agrícola e Ambiental	16
10	Apple	YOLO v5	96.79% <i>mAP</i>	Imágenes RGB	YIELD ESTIMATION METHOD OF APPLE TREE BASED ON IMPROVED LIGHTWEIGHT YOLOV5 [37]	2021	Smart Agriculture	15
11	Strawberry	R-CNN	87.33% <i>mAP</i>	Imágenes RGB	STRAWBERRY RCNN RECOGNITION AND COUNTING MODEL OF STRAWBERRY BASED ON IMPROVED FASTER RCNN [38]	2023	Ecological Informatics	7
12	Coffee	Regresión Lineal Múltiple	$R^2 = 0.89$	Datos meteorológicos	PREDICTING COFFEE YIELD BASED ON AGROCLIMATIC DATA AND MACHINE LEARNING [39]	2022	Theoretical and Applied Climatology	4
13	Coffee	XGBOOST	RMSE = 0.01 MAE = 0.03	Datos meteorológicos	A NON DESTRUCTIVE TIME SERIES MODEL FOR THE ESTIMATION OF CHERRY COFFEE PRODUCTION [40]	2022	Computers, Materials and Continua	3
14	Strawberry	Regresión Lineal	99.55% accuracy	Imágenes multiespectrales	ESTIMATION OF STRAWBERRY CROP PRODUCTIVITY BY MACHINE LEARNING ALGORITHMS USING DATA FROM MULTISPECTRAL IMAGES [41]	2023	Agronomy	2
15	Peppers	DeepSORT	85.7% accuracy	Imágenes RGB	MATURITY RECOGNITION AND FRUIT COUNTING FOR SWEET PEPPERS IN GREENHOUSES USING DEEP LEARNING NEURAL NETWORKS [42]	2024	Agriculture (Switzerland)	2
16	Yellow horn	YOLO v3-tiny	98.05% accuracy	Imágenes RGB	RESEARCH ON FRUIT COUNTING OF XANTHOCERAS SORBIFOLIUM BUNGE BASED ON DEEP LEARNING [43]	2022	2022 7th International Conference	2

							on Image, Vision and Computing, ICIVC 2022	
17	Mango	YOLO v5	R2=0.66	Imágenes RGB	FRUIT YIELD ESTIMATION USING IMAGE ANALYSIS IS ALSO ABOUT CORRECTING THE NUMBER OF DETECTIONS [44]	2023	XXXI International Horticultural Congress, IHC2022	1
18	Apple	ANN	92% accuracy	Datos vegetativos	NEURAL NETWORK MODEL FOR PREDICTING APPLE YIELD BASED ON ARRIVAL OF PHENOLOGICAL STAGE IN CONJUNCTION WITH LEAF DISEASE SOIL AND WEATHER PARAMETERS [45]	2024	SN Computer Science	1
19	Mango	YOLO v4	-	Imágenes RGB	ON TREE MANGO FRUIT DETECTION AND COUNTING SYSTEM [46]	2023	International Journal of Next-Generation Computing	0
20	Apple	YOLO v5	-	Imágenes RGB	APPLE DETECTION AND YIELD ESTIMATION BASED ON YOLOV5 [47]	2024	2024 7th International Conference on Advanced Algorithms and Control Engineering, ICAACE 2024	0
21	Mango	ResNet 50	98.2%	Imágenes RGB	FAST REGION BASED CONVOLUTIONAL NEURAL NETWORK RESNET50 MODEL FOR ON TREE MANGO FRUIT YIELD ESTIMATION [48]	2024	Indonesian Journal of Electrical Engineering and Computer Science	0

Entre los cultivos que se han realizado estudios para estimar su producción son la manzana (apple), el mango, café (coffee), fresa (strawberry), Yellowhorn, plátano (banana), melón, pimientos (peppers), cítricos (citrus), kiwi, uva (grape) y la tuna (Cactus pear). En la figura 10 se muestran los cultivos frutales en las que más se aplican técnicas de machine learning para la estimación de la producción.



Figura 10. Cultivos con investigaciones para estimar su producción.

El cultivo que tiene la mayor cantidad de estudios para estimar su producción es la manzana (Apple), aquí podemos destacar el estudio “A novel apple fruit detection and counting methodology based on Deep Learning and trunk tracking in modern orchard” [28], que tiene la mayor cantidad de citas; en este trabajo no se realizó la estimación de la producción directamente, pero desarrolló un método automatizado para mejorar la precisión en el conteo de manzanas en huertos con arquitectura vertical moderna. En lugar de seguir los frutos, se rastrea el tronco del árbol, más grande y visible. Se utilizó una red YOLOv4-tiny integrada con el algoritmo CSR-DCF para predecir la ubicación de los frutos y emparejarlos entre cuadros consecutivos mediante la distancia euclidiana mínima. El método logró una precisión media del 99.35% en la detección de frutos y troncos, y una precisión de conteo del 91.49% con un coeficiente de correlación R^2 de 0.9875 respecto al conteo manual. El método, aplicable en CPU a 2-5 cuadros por segundo, demuestra un alto potencial para la estimación precisa de la producción de manzanas y otros frutos.

Otro estudio para estimar la producción de manzana es el titulado “Apple orchard production estimation using Deep Learning strategies a comparison of tracking by detection Algorithms” [35], en este estudio se compara algoritmos de seguimiento

por detección para la estimación de rendimiento mediante el conteo de manzanas. Se evaluaron cinco algoritmos: Kalman Filter, Kernelized Correlation Filter, Simple Online Real-Time Tracking, Multi Hypothesis Tracking, y Deep Simple Online Real-Time Tracking (DeepSORT), utilizando dos bases de datos nuevas en formato Multiple Object Tracking (MOT). La estrategia más robusta fue Multi Hypothesis Tracking, con una precisión MOT de 97.00%, seguida de DeepSORT con 93.00%. En un caso práctico con detección basada en aprendizaje profundo, DeepSORT mostró el menor error de conteo (20.07% con YoloV5 y 31.52% con Faster R-CNN), con resultados estadísticamente similares al Kalman Filter (errores de 20.5% y 31.9%, respectivamente)

También se han realizado estudios para la estimación de la producción de mango, en el estudio "Fruit yield estimation using image analysis is also about correcting the number of detections" [44], se adquirieron imágenes de 325 árboles de mango 'Kent' en 27 huertos de dos regiones en África Occidental. Se detectaron los frutos con una red neuronal YOLOv5 y se calibraron modelos de corrección basados en el conteo real de frutos. Los resultados indican que un modelo lineal con región y sistema de cultivo como covariables categóricas obtuvo el mejor desempeño ($R^2 = 0.66$, NRMSE = 11%) frente a un modelo lineal simple ($R^2 = 0.34$, NRMSE = 20%). Las transformaciones de raíz cuadrada fueron necesarias para ajustar las suposiciones de regresión.

Además, como se aprecia en la figura 11, existe un interés creciente en las investigaciones sobre estimación de la producción en cultivos agrícolas.



Figura 11. Investigaciones por año.

b. Métodos de inteligencia artificial y machine learning utilizados para la estimación de la producción de cultivos frutales

De los trabajos analizados la mayor cantidad de ellos utilizan como datos de entrada imágenes RGB (red, green, blue) para estimar la producción de cultivos frutales, en la figura 12 podemos apreciar la frecuencia de los datos analizados en los estudios.

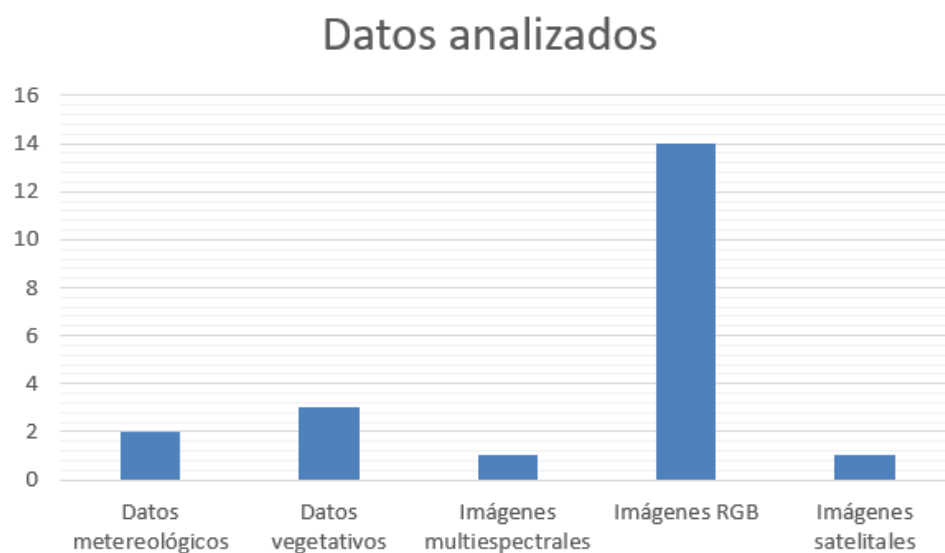


Figura 12. Datos analizados para estimar la producción de los cultivos frutales.

En la investigación “Green citrus detection and counting in orchards based on YoloV5CS and AI Edge System” [29], se utiliza imágenes de cítricos verdes en entornos naturales, y se introduce el modelo YOLOv5-CS (Citrus Sort), diseñado para la detección y conteo de cítricos verdes. El modelo se optimiza mediante rotación de imágenes, un módulo de atención convolucional en lugar de una capa convolucional, y una capa de detección adicional. Se emplean la función de pérdida CloU y el algoritmo de enfriamiento cosenoidal para mejorar el entrenamiento. Desplegado en un sistema de IA en el borde, el modelo utiliza segmentación de escena con "región virtual" para un conteo preciso. YOLOv5-CS alcanza un mAP@.5 del 98.23% y un recall del 97.66%, con velocidades de inferencia de 0.017 s en el servidor y 0.037 s en Nvidia Jetson Xavier NX, y una tasa de fotogramas de 28 FPS en el sistema de IA en el borde.

Los datos meteorológicos también son utilizados para estimar la producción en cultivos frutales, en la investigación “Predicting coffee yield based on agroclimatic data and machine learning” [39], se predice el rendimiento del café arábica utilizando modelos de regresión basados en datos meteorológicos del estado de Paraná, Brasil. Se recopilaron datos climáticos desde 1989 hasta 2020 mediante la plataforma NASA/POWER y datos de rendimiento del café (sacas/ha) de 2003 a 2018 proporcionados por la Companhia Nacional de Abastecimento (CONAB). Se utilizaron métodos como Penman–Monteith para calcular la evapotranspiración y el balance hídrico climatológico, y se aplicó la regresión lineal múltiple para modelar el rendimiento del café en función de variables climáticas como temperatura del aire, precipitación y radiación solar.

La predicción de la estimación también se ha realizado tomando como datos de entrada los datos vegetativos de las plantas o árboles, en el estudio [36], que tuvo como objetivo evaluar el uso de redes ANN para predecir la producción de tuna 'Gigante' y determinar los caracteres morfológicos más relevantes en dicha predicción. El experimento se realizó entre 2009 y 2011 en el Instituto Federal Baiano, Brasil, evaluando caracteres agronómicos en 500 plantas durante el tercer ciclo productivo, las características agronómicas evaluadas fueron el largo de cladodio, ancho de cladodio, espesor de cladodio, número de cladodios, altura de planta, biomasa de cladodio, área de cladodio y área total de cladodios. En este estudio probaron diez arquitecturas de RNA con el software R, de las cuales la red con cinco neuronas en la capa intermedia obtuvo los mejores resultados, con un coeficiente de determinación (R^2) de 0.87. Los caracteres más influyentes en la predicción fueron el área total del cladodio, la altura de la planta, el grosor y la longitud del cladodio.

En el estudio [45], se propone un método utilizando una red ANN para predecir el rendimiento de los cultivos de manzana en un huerto. La predicción se realiza considerando la identificación de la etapa fenológica y el momento de su aparición, además de integrar factores como las características del suelo, el clima y las enfermedades de las hojas. El modelo propuesto de predicción de rendimiento muestra una puntuación f1 de 0.91, precisión de 0.91, recall de 0.92 y una exactitud del 92%. Se compara con otros algoritmos populares de ML como Random Forest, Árbol de Decisión y Gradient Boosting.

YOLO en sus diferentes versiones y modificaciones se presenta como la técnica más utilizada para la estimación de la producción en cultivos frutales y conteo de frutos, en la figura 13, vemos la representación de los métodos más utilizados.

En la investigación “On Tree Mango Fruit Detection and Counting System” [46], se comparó los algoritmos Faster R-CNN, YOLOv3 y YOLOv4, ampliamente utilizados en el reconocimiento de objetos, para identificar el mejor modelo para la detección de frutas de mango. Los resultados mostraron que el algoritmo YOLOv4, desarrollado bajo el marco CSPDarknet53, demostró ser el más eficaz para el reconocimiento de frutas de mango.

RetinaNet también es un método utilizado para la estimación de producción de cultivos frutales, en la investigación “A deep learning system for single and overall weight estimation of melons using unmanned aerial vehicle images” [34], se presenta un sistema para la detección y estimación del rendimiento de melones a partir de imágenes en color capturadas por una cámara digital montada en un vehículo aéreo no tripulado. El sistema proporciona tanto el número de melones como el peso de cada uno, y consta de tres etapas principales: detección de melones, extracción de características geométricas y estimación del rendimiento individual de los melones. La detección se realizó utilizando la red neuronal convolucional profunda RetinaNet, con un aprendizaje transferido que permitió una detección precisa de objetos pequeños en imágenes de alta resolución, alcanzando una puntuación de precisión promedio de 0.92 y un F1 score superior a 0.9. La extracción de características se llevó a cabo con el algoritmo de contorno activo Chan–Vese y el método de ajuste de elipses por análisis de componentes principales.



Figura 13. Métodos de inteligencia artificial más utilizados para la estimación de la producción de cultivos frutales.

c. Desempeño de los métodos de inteligencia artificial y machine learning utilizados para la estimación de la producción de cultivos frutales

Entre los métodos más efectivos considerando la precisión podemos indicar que la Regresión Lineal utilizando imágenes multiespectrales de cultivos de fresa, ResNet 50 utilizando imágenes RGB de cultivos de mango y Yolo en imágenes RGB de cultivos de YellowHorn se presentan como los de mayor desempeño.

En la investigación “Estimation of Strawberry Crop Productivity by Machine Learning Algorithms Using Data from Multispectral Images” [41], se evaluó la precisión de dos algoritmos de regresión, Regresión Lineal (LR) y SVM para estimar el peso, número de frutas y número de hojas en fresas usando imágenes multiespectrales obtenidas por un vehículo aéreo no tripulado (VANT). Se encontró que el LR fue más preciso, con una exactitud del 99.91% en el peso promedio de frutas, 99.55% en el número de frutas y 99.94% en el número de hojas. SVM mostró precisiones de 89.62%, 84.26% y 98.12%, respectivamente.

YOLO también ha obtenido un desempeño considerable en la estimación o conteo de cultivos frutales, en la investigación “Research on Fruit Counting of Xanthoceras Sorbifolium Bunge Based on Deep Learning” [43], se abordó la optimización del proceso de plantación y la mejora de la calidad del fruto de Xanthoceras sorbifolium Bunge mediante métodos automáticos de conteo y estimación del rendimiento. Evaluaron diversos modelos de aprendizaje profundo, incluyendo SSD, YOLOv2, YOLOv3, YOLOv4, YOLOv5s, y YOLOv5x. Los resultados indicaron que el modelo YOLOv3 obtuvo un rendimiento óptimo con un IOU del 98,84%, y YOLOv3-tiny mostró la mayor precisión en el conteo, alcanzando el 98,05%.

d. Propuesta de investigación que priorice los temas emergentes y tendencias en la investigación sobre el uso de machine learning para la estimación de la producción en cultivos frutales

En el contexto actual de la agricultura de precisión, la estimación precisa de la producción de cultivos frutales se ha convertido en una necesidad crítica para optimizar la gestión de recursos y mejorar los procesos de cultivo [1] [2]. A medida que la tecnología de machine learning y el análisis de imágenes avanzan, surgen nuevas oportunidades para refinar estos métodos y superar las limitaciones existentes. La siguiente agenda de investigación propone abordar las lagunas identificadas y explorar temas emergentes que podrían revolucionar la estimación de producción en cultivos frutales:

Integración de algoritmos avanzados de detección de objetos

La combinación de algoritmos actualizados de detección de objetos, como YOLOv10, con técnicas de machine learning ofrece una prometedora vía para mejorar la precisión en la estimación de producción frutal. Actualmente se presentan las Redes Kolmogorov-Arnold (KAN) como una alternativa en aplicaciones que

requieren modelado complejo de relaciones no lineales y predicciones precisas en contextos de alta dimensionalidad, su uso está emergiendo en modelado de sistemas dinámicos, predicción de series temporales, reconocimiento de patrones. La combinación de arquitecturas CNN y KAN podría ser una alternativa para mejorar la estimación de producción de cultivos frutales, debido a la flexibilidad de las KAN podría reducir la necesidad de una gran cantidad de parámetros y recursos computacionales, además de ofrecer una mayor interpretabilidad de las decisiones del modelo.

Integración de datos climáticos en modelos predictivos

La combinación de Internet of Things (IoT) con machine learning y el análisis de imágenes puede revolucionar la estimación de producción de cultivos frutales. Los dispositivos IoT no solo recopilan datos en tiempo real sobre las condiciones climáticas (temperatura, humedad, luminosidad, etc.), sino que también pueden integrarse con sistemas de visión por computador para analizar imágenes de los cultivos, ya sea mediante drones o cámaras fijas en los campos.

Las imágenes capturadas por drones o cámaras instaladas en los campos pueden procesarse utilizando técnicas de machine learning, como redes CNN, que permiten identificar automáticamente los frutos, su tamaño, color y estado de madurez. Al combinar estos análisis de imagen con los datos climáticos obtenidos por IoT, los modelos de machine learning pueden mejorar significativamente la precisión en la estimación de producción. Por ejemplo, si los sensores IoT detectan condiciones subóptimas de riego o una baja radiación solar, el análisis de imágenes puede detectar cambios en el crecimiento de la fruta y ajustar las predicciones de rendimiento en consecuencia.

Desarrollo de sistemas de estimación en tiempo real

El desarrollo de sistemas de estimación en tiempo real basados en machine learning y análisis de imágenes no solo debe quedarse en el ámbito de la investigación, sino que es crucial que estos avances se implementen de manera efectiva en la agricultura. Para maximizar su impacto, es esencial que estos sistemas sean lo suficientemente ligeros para ejecutarse en dispositivos de campo, como drones o sensores IoT, smartphones, garantizando una operatividad en tiempo real sin comprometer los recursos de los agricultores. La aplicación práctica de estas tecnologías permitiría una gestión más eficiente de los cultivos, optimizando el uso de agua, fertilizantes y otros insumos, al tiempo que se responde de manera rápida a las condiciones cambiantes del entorno y del clima, lo que es especialmente relevante en el contexto del cambio climático. Así, estos sistemas no solo proporcionarían predicciones precisas, sino que también ayudarían a los agricultores a tomar decisiones informadas en el momento adecuado.

Evaluación de modelos en cultivos de alto valor y especializados

Finalmente, la evaluación de modelos de machine learning en cultivos de alto valor y especializados, como frutas exóticas o de temporada, es fundamental debido a los desafíos únicos que presentan en términos de tamaño, forma y condiciones de cultivo. Estos cultivos, que suelen ser más sensibles a las fluctuaciones climáticas, requieren soluciones más sofisticadas para la estimación precisa de su producción. Además, el cambio climático impone variaciones abruptas en la temperatura, precipitación y humedad, afectando el rendimiento agrícola de manera impredecible. La integración de datos climáticos en tiempo real con imágenes satelitales y drones, junto con técnicas avanzadas de machine learning, podría mejorar significativamente las predicciones y ayudar a los agricultores a adaptar sus estrategias de gestión para optimizar los recursos y mitigar los efectos del cambio climático.

IV. DISCUSIÓN Y CONCLUSIONES

a. Discusión

La estimación precisa de la producción de cultivos frutales es un pilar esencial en la gestión agrícola, contribuyendo a una planificación más eficiente en la cosecha, almacenamiento y distribución, lo que impacta directamente en la cadena de suministro. La aplicación de métodos de IA y ML está transformando este ámbito al permitir estimaciones más precisas, rápidas y escalables, abordando las limitaciones de las técnicas convencionales. Mediante la aplicación de una revisión sistemática siguiendo el enfoque PRISMA, este estudio ha identificado un conjunto de 21 trabajos que destacan por su enfoque en la aplicación de estos métodos en la agricultura de precisión, subrayando la necesidad de un análisis más profundo sobre los cultivos, datos y algoritmos que ofrecen los mejores resultados en la estimación de la producción frutal.

Los resultados obtenidos muestran que los cultivos como la fresa, el mango y el Yellowhorn han sido objeto de estudios exitosos utilizando técnicas de regresión y deep learning. Los modelos como YOLO, ResNet50 y la Regresión Lineal han demostrado un alto desempeño en términos de precisión. Por ejemplo, el uso de Regresión Lineal para estimar la producción de fresas con imágenes multiespectrales obtuvo precisiones superiores al 99%, destacando su aplicabilidad en la agricultura de precisión. Asimismo, YOLOv3-tiny ha mostrado un desempeño sobresaliente en la estimación de la producción de Yellowhorn, con una precisión del 98%, lo que sugiere que las técnicas de detección de objetos en tiempo real tienen un gran potencial para su implementación en campo.

En la literatura revisada, se han identificado tendencias emergentes que sugieren nuevas direcciones de investigación. Entre ellas destaca la integración de variables

climáticas mediante el uso de tecnologías como IoT, que facilitan la recolección de información en tiempo real sobre el entorno ambiental y, al combinarlas con imágenes capturadas por drones o cámaras fijas, se pueden generar modelos más robustos para la estimación de la producción. Esta combinación de datos multifuente puede mejorar la precisión en la predicción y, al mismo tiempo, permitir respuestas más rápidas a cambios en el entorno, optimizando la gestión de los cultivos frente a factores como el cambio climático.

A pesar de los avances alcanzados, existen brechas importantes en la investigación actual. Muchos estudios se han centrado en un número limitado de cultivos y en contextos climáticos específicos, lo que complica la extrapolación de los resultados. Además, aunque las técnicas actualmente utilizadas ofrecen altos niveles de precisión, la necesidad de recursos computacionales limita su implementación en sistemas en tiempo real, especialmente en áreas rurales con acceso limitado a infraestructura tecnológica. Es en este contexto se están desarrollando nuevas arquitecturas, como las Redes Kolmogorov-Arnold (KAN como una vía prometedora para reducir la complejidad computacional y mejorar la interpretabilidad de los modelos, permitiendo una implementación más accesible y eficaz. A medida que las KAN emergen como herramientas clave para el modelado de sistemas dinámicos y la predicción en entornos de alta dimensionalidad, su uso en la agricultura de precisión puede aportar soluciones ligeras y escalables.

Finalmente, el avance en el desarrollo de sistemas de estimación en tiempo real debería ser considerado una prioridad en la agenda de investigación. Estos sistemas deben ser eficientes, de bajo costo y capaces de operar en dispositivos de campo como drones, sensores IoT e incluso smartphones, garantizando que la tecnología esté al alcance de los agricultores. Este enfoque no solo mejorará la productividad, sino que también fomentará la sostenibilidad en el sector agrícola,

adaptando las prácticas de cultivo a las condiciones ambientales cambiantes y asegurando un uso óptimo de los recursos.

b. Conclusiones

Esta revisión de la literatura ha examinado 21 estudios sobre la estimación de la producción de cultivos frutales, evidenciando un creciente interés en la aplicación de técnicas de inteligencia artificial y machine learning en este ámbito. Diversos estudios destacan el uso de algoritmos avanzados como YOLO, RetinaNet, ResNet50, Regresión Lineal, Redes Neuronales Artificiales, SVM entre otros, para mejorar la precisión y eficiencia en la detección y conteo de frutos. Sin embargo, persisten brechas en la investigación relacionadas con la aplicación de estas tecnologías en diferentes tipos de cultivos y en condiciones climáticas variadas.

El análisis de los métodos utilizados muestra que las técnicas de deep learning, como YOLOv3 y YOLOv4, han demostrado ser altamente efectivas para el reconocimiento y conteo de frutos en tiempo real para lograr la estimación de la producción. Al mismo tiempo, los algoritmos de regresión como el SVM y la regresión lineal han mostrado buenos resultados en la predicción de parámetros cuantitativos como el peso y el número de frutos. Sin embargo, la eficiencia de estos modelos depende de la calidad de las imágenes y de la cantidad de datos, lo que sugiere la necesidad de un mayor esfuerzo en la mejora de la adquisición y preprocesamiento de datos agrícolas.

Las comparaciones entre diferentes métodos han demostrado que, si bien las técnicas basadas en deep learning como ResNet50, YOLOv4 ofrecen un desempeño superior en términos de precisión de detección, los algoritmos más ligeros como YOLOv3-tiny son más adecuados para la implementación en sistemas

en tiempo real debido a su menor demanda computacional. Además, los métodos tradicionales de regresión pueden ser útiles en entornos con datos limitados, pero presentan limitaciones frente a la complejidad de las condiciones de campo.

La agenda de investigación debe centrarse en la integración de factores climáticos y la adaptación de los modelos a cultivos especializados y de alto valor, los cuales presentan desafíos particulares en términos de morfología y entorno. Además, se debe priorizar el desarrollo de sistemas de estimación en tiempo real que sean eficientes y de bajo costo, de modo que puedan implementarse de manera práctica en la agricultura. La inclusión de IoT y sensores en el análisis de imágenes agrícolas también representa un área clave para mejorar la precisión de las predicciones y responder de manera proactiva a las variaciones ambientales inducidas por el cambio climático.

V. REFERENCIAS

- [1] S. Manonmani, S. Senthilkumar, U. S. A. Govind, and S. Manivannan, "Application of Artificial Intelligence in Fruit Production: A Review," *Agricultural Science Digest - A Research Journal*, no. Of, Apr. 2022, doi: 10.18805/ag.D-5482.
- [2] A. Koirala, K. B. Walsh, Z. Wang, and C. McCarthy, "Deep learning – Method overview and review of use for fruit detection and yield estimation," *Computers and Electronics in Agriculture*, vol. 162, pp. 219–234, Jul. 2019, doi: 10.1016/j.compag.2019.04.017.
- [3] A. A. Boatswain Jacques, V. I. Adamchuk, J. Park, G. Cloutier, J. J. Clark, and C. Miller, "Towards a Machine Vision-Based Yield Monitor for the Counting and Quality Mapping of Shallots," *Frontiers in Robotics and AI*, vol. 8, Apr. 2021, doi: 10.3389/frobt.2021.627067.
- [4] J. Li, Z. Zhu, H. Liu, Y. Su, and L. Deng, "Strawberry R-CNN: Recognition and counting model of strawberry based on improved faster R-CNN," *Ecological Informatics*, vol. 77, p. 102210, Nov. 2023, doi: 10.1016/j.ecoinf.2023.102210.
- [5] N. Managali Vasanth and R. PPandian, "Fast region based convolutional neural network ResNet-50 model for on tree Mango fruit yield estimation," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 33, no. 2, p. 1084, Feb. 2024, doi: 10.11591/ijeecs.v33.i2.pp1084-1091.
- [6] D. J. G. Romero, O. E. Apolo-Apolo, and M. P. Ruíz, "Estimating Optimal Harvest Time and Yield in Tomatoes Using Deep Learning Techniques: A Preliminary Study," in *2023 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)*, IEEE, Nov. 2023, pp. 81–85. doi: 10.1109/MetroAgriFor58484.2023.10424131.
- [7] L. S. de Oliveira, R. Castoldi, G. D. Martins, and M. H. Medeiros, "Estimation of Strawberry Crop Productivity by Machine Learning Algorithms Using Data from Multispectral Images," *Agronomy*, vol. 13, no. 5, p. 1229, Apr. 2023, doi: 10.3390/agronomy13051229.
- [8] Y. Xu and others, "Artificial intelligence: A powerful paradigm for scientific research," *The Innovation*, vol. 2, no. 4, p. 100179, 2021, doi: 10.1016/j.xinn.2021.100179.
- [9] J. Zhang and Z. Zhang, "Ethics and governance of trustworthy medical artificial intelligence," *BMC Medical Informatics and Decision Making*, vol. 23, no. 1, 2023, doi: 10.1186/s12911-023-02103-9.
- [10] R. Rani, J. Sahoo, S. Bellamkonda, S. Kumar, and S. K. Pippal, "Role of Artificial Intelligence in Agriculture: An Analysis and Advancements With Focus on Plant Diseases," *IEEE Access*, vol. 11, pp. 137999–138019, 2023, doi: 10.1109/ACCESS.2023.3339375.
- [11] OpenCV, "Image Processing in OpenCV." [Online]. Available: https://docs.opencv.org/4.x/d4/d13/tutorial_py_filtering.html
- [12] D. A. van Dyk and X.-L. Meng, "The Art of Data Augmentation," *Journal of Computational and Graphical Statistics*, vol. 10, no. 1, pp. 1–50, Mar. 2001, doi: 10.1198/10618600152418584.
- [13] C. Ningthoujam and C. T. Singh, "Study of Various Types of Data Annotation," in *Advanced Computational Paradigms and Hybrid Intelligent Computing*, T. K.

- Gandhi, D. Konar, B. Sen, and K. Sharma, Eds., Singapore: Springer Singapore, 2022, pp. 597–605.
- [14] A. Alanazi, “Using machine learning for healthcare challenges and opportunities,” *Inform. Med. Unlocked*, vol. 30, p. 100924, 2022, doi: 10.1016/j.imu.2022.100924.
- [15] T. Jiang, J. L. Gradus, and A. J. Rosellini, “Supervised Machine Learning: A Brief Primer,” *Behav. Ther.*, vol. 51, no. 5, pp. 675–687, 2020, doi: 10.1016/j.beth.2020.05.002.
- [16] Sebastian Raschka, David Julian, and John Hearty, *Python: Deeper Insights into Machine Learning*. Packt Publishing, 2017.
- [17] Y. Sun, Z. Sun, and W. Chen, “The evolution of object detection methods,” *Engineering Applications of Artificial Intelligence*, vol. 133, p. 108458, 2024, doi: <https://doi.org/10.1016/j.engappai.2024.108458>.
- [18] R. Girshick, J. Donahue, T. Darrell, and J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation.” 2014. [Online]. Available: <https://arxiv.org/abs/1311.2524>
- [19] R. Girshick, “Fast R-CNN,” in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Dec. 2015.
- [20] S. Ren, K. He, R. B. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *CoRR*, vol. abs/1506.01497, 2015, [Online]. Available: <http://arxiv.org/abs/1506.01497>
- [21] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” Jan. 06, 2016, *arXiv*: arXiv:1506.01497. doi: 10.48550/arXiv.1506.01497.
- [22] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Jun. 2016, pp. 779–788. doi: 10.1109/CVPR.2016.91.
- [23] C. Yu and Y. Shin, “An efficient YOLO for ship detection in SAR images via channel shuffled reparameterized convolution blocks and dynamic head,” *ICT Express*, Feb. 2024, doi: 10.1016/j.ict.2024.02.007.
- [24] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollar, “Focal Loss for Dense Object Detection,” in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Oct. 2017.
- [25] M. J. Page *et al.*, “The PRISMA 2020 statement: An updated guideline for reporting systematic reviews,” *International Journal of Surgery*, vol. 88, p. 105906, 2021, doi: <https://doi.org/10.1016/j.ijsu.2021.105906>.
- [26] J. Zhu and W. Liu, “A tale of two databases: the use of Web of Science and Scopus in academic papers,” *Scientometrics*, vol. 123, no. 1, pp. 321–335, Apr. 2020, doi: 10.1007/s11192-020-03387-8.
- [27] G. Urrútia and X. Bonfill, “PRISMA declaration: A proposal to improve the publication of systematic reviews and meta-analyses,” *Medicina Clínica*, vol. 135, no. 11, pp. 507–511, 2010, doi: 10.1016/j.medcli.2010.01.015.
- [28] F. Gao *et al.*, “A novel apple fruit detection and counting methodology based on deep learning and trunk tracking in modern orchard,” *Computers and Electronics in Agriculture*, vol. 197, p. 107000, 2022, doi: <https://doi.org/10.1016/j.compag.2022.107000>.

- [29] S. Lyu, R. Li, Y. Zhao, Z. Li, R. Fan, and S. Liu, "Green Citrus Detection and Counting in Orchards Based on YOLOv5-CS and AI Edge System," *Sensors*, vol. 22, no. 2, 2022, doi: 10.3390/s22020576.
- [30] S. T. Arab, R. Noguchi, S. Matsushita, and T. Ahamed, "Prediction of grape yields from time-series vegetation indices using satellite remote sensing and a machine-learning approach," *Remote Sensing Applications: Society and Environment*, vol. 22, p. 100485, 2021, doi: <https://doi.org/10.1016/j.rsase.2021.100485>.
- [31] J. D. R. Soares, M. Pasqual, W. S. Lacerda, S. O. Silva, and S. L. R. Donato, "Utilization of artificial neural networks in the prediction of the bunches' weight in banana plants," *Scientia Horticulturae*, vol. 155, pp. 24–29, 2013, doi: <https://doi.org/10.1016/j.scienta.2013.01.026>.
- [32] S. Liu, X. Zeng, and M. Whitty, "A vision-based robust grape berry counting algorithm for fast calibration-free bunch weight estimation in the field," *Computers and Electronics in Agriculture*, vol. 173, p. 105360, 2020, doi: <https://doi.org/10.1016/j.compag.2020.105360>.
- [33] J. Massah, K. A. Vakilian, M. Shabanian, and S. M. Shariatmadari, "Design, development, and performance evaluation of a robot for yield estimation of kiwifruit," *Computers and Electronics in Agriculture*, vol. 185, p. 106132, 2021, doi: <https://doi.org/10.1016/j.compag.2021.106132>.
- [34] A. Kalantar, Y. Edan, A. Gur, and I. Klapp, "A deep learning system for single and overall weight estimation of melons using unmanned aerial vehicle images," *Computers and Electronics in Agriculture*, vol. 178, p. 105748, 2020, doi: <https://doi.org/10.1016/j.compag.2020.105748>.
- [35] J. Villacrés, M. Viscaino, J. Delpiano, S. Vougioukas, and F. A. Cheein, "Apple orchard production estimation using deep learning strategies: A comparison of tracking-by-detection algorithms," *Computers and Electronics in Agriculture*, vol. 204, p. 107513, 2023, doi: <https://doi.org/10.1016/j.compag.2022.107513>.
- [36] A. del artículo, "Prediction of Gigante Cactus Pear Yield by Morphological Characters and Artificial Neural Networks," *Revista Brasileira de Engenharia Agrícola e Ambiental*, vol. 22, no. 5, pp. 315–319, 2018.
- [37] Z. Y. LI Zhijun YANG Shenghui, SHI Deshuai, LIU Xingxing, "Yield Estimation Method of Apple Tree Based on Improved Lightweight YOLOv5," *Smart Agriculture*, vol. 3, no. 2, p. 100, 2021, doi: 10.12133/j.smartag.2021.3.2.202105-SA005.
- [38] J. Li, Z. Zhu, H. Liu, Y. Su, and L. Deng, "Strawberry R-CNN: Recognition and counting model of strawberry based on improved faster R-CNN," *Ecological Informatics*, vol. 77, p. 102210, 2023, doi: <https://doi.org/10.1016/j.ecoinf.2023.102210>.
- [39] L. E. de Oliveira Aparecido, J. A. Lorençone, P. A. Lorençone, G. B. Torsoni, R. F. Lima, and J. R. da Silva Cabral Moraes, "Predicting coffee yield based on agroclimatic data and machine learning," *Theoretical and Applied Climatology*, vol. 148, no. 3, pp. 899–914, May 2022, doi: 10.1007/s00704-022-03983-z.
- [40] J. C. C. Jhonn Pablo Rodríguez David Camilo Corrales, David Griol, Zoraida Callejas, "A Non-Destructive Time Series Model for the Estimation of Cherry

- Coffee Production,” *Computers, Materials & Continua*, vol. 70, no. 3, pp. 4725–4743, 2022, doi: 10.32604/cmc.2022.019135.
- [41] L. S. de Oliveira, R. Castoldi, G. D. Martins, and M. H. Medeiros, “Estimation of Strawberry Crop Productivity by Machine Learning Algorithms Using Data from Multispectral Images,” *Agronomy*, vol. 13, no. 5, 2023, doi: 10.3390/agronomy13051229.
- [42] L. D. Viveros Escamilla, A. Gómez-Espinosa, J. A. Escobedo Cabello, and J. A. Cantoral-Ceballos, “Maturity Recognition and Fruit Counting for Sweet Peppers in Greenhouses Using Deep Learning Neural Networks,” *Agriculture*, vol. 14, no. 3, 2024, doi: 10.3390/agriculture14030331.
- [43] G. Xia, J. Dan, H. Jinyu, H. Jiming, and S. Xiaoyong, “Research on Fruit Counting of *Xanthoceras Sorbifolium* Bunge Based on Deep Learning,” in *2022 7th International Conference on Image, Vision and Computing (ICIVC)*, 2022, pp. 790–798. doi: 10.1109/ICIVC55077.2022.9886298.
- [44] J. Sarron *et al.*, “Fruit yield estimation using image analysis is also about correcting the number of detections,” *Acta Horticulturae*, vol. 1360. International Society for Horticultural Science, pp. 347–354, 2023. doi: 10.17660/ActaHortic.2023.1360.42.
- [45] R. M. Datt and V. Kukreja, “Neural Network Model for Predicting Apple Yield Based on Arrival of Phenological Stage in Conjunction with Leaf disease, Soil and Weather Parameters,” *SN Computer Science*, vol. 5, no. 1, p. 141, Jan. 2024, doi: 10.1007/s42979-023-02463-z.
- [46] R. Mahajan, A. Haridas, M. Chandak, R. Sharma, and C. Dadiyala, “On Tree Mango Fruit Detection and Counting System,” *International Journal of Next-Generation Computing*, 2023, [Online]. Available: <https://api.semanticscholar.org/CorpusID:257350937>
- [47] Z. Li, X. Bai, C. He, and P. Jiang, “Apple Detection and Yield Estimation Based on YOLOv5,” in *2024 7th International Conference on Advanced Algorithms and Control Engineering (ICAACE)*, 2024, pp. 754–758. doi: 10.1109/ICAACE61206.2024.10549754.
- [48] N. M. Vasanth and R. Pandian, “Fast region based convolutional neural network ResNet-50 model for on tree Mango fruit yield estimation,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 33, no. 2. Institute of Advanced Engineering and Science, pp. 1084–1091, 2024. doi: 10.11591/ijeecs.v33.i2.pp1084-1091.

NOMBRE DEL TRABAJO

Trabajo investigación-bachiller-turnitin.docx

RECuento DE PALABRAS

8676 Words

RECuento DE CARACTERES

49163 Characters

RECuento DE PÁGINAS

40 Pages

TAMAÑO DEL ARCHIVO

1.1MB

FECHA DE ENTREGA

Sep 20, 2024 5:38 PM GMT-5

FECHA DEL INFORME

Sep 20, 2024 5:38 PM GMT-5**● 21% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 14% Base de datos de Internet
- Base de datos de Crossref
- 15% Base de datos de trabajos entregados
- 7% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● Excluir del Reporte de Similitud

- Material bibliográfico
- Coincidencia baja (menos de 8 palabras)
- Material citado