

# Intelligent system with computer vision to improve avocado crop management in an agricultural company

Courtney L. Vaca Honores, Bachelor<sup>1</sup> ; Diego F. Solano Portocarrero, Bachelor<sup>1</sup> ; Carlos D. Rodríguez Vilcarromero, Master<sup>1</sup> ; Rolando J. Berrú Beltrán, Master<sup>1</sup> 

<sup>1</sup>Universidad Privada del Norte, Perú, [N00290023@upn.pe](mailto:N00290023@upn.pe), [N00295974@upn.pe](mailto:N00295974@upn.pe), [carlos.vilcarromero@upn.pe](mailto:carlos.vilcarromero@upn.pe), [rolando.berru@upn.edu.pe](mailto:rolando.berru@upn.edu.pe)

**Abstract**– *This research evaluated the impact of an intelligent system with computer vision to improve avocado crop management in an agricultural entity during the year 2025. To this end, a pre-experimental design was applied with a sample of 15 workers selected according to inclusion criteria. The methodology included data collection using structured questionnaires, which were processed in XLSTAT software using Student's t-test and Wilcoxon's test. The statistical analysis showed substantial improvements in key management indicators: information availability increased by 50.18%, operational planning increased by 45.16%, monitoring frequency improved by 35.32%, and resource efficiency increased by 28.42%. These findings confirm that the proposed technological solution significantly optimizes monitoring and decision-making processes within the agricultural organization.*

**Keywords**-- *Computer vision, agriculture, intelligent system, crop management, Hass avocado.*

# Sistema inteligente con visión computacional para mejorar la gestión de cultivos de palta en una empresa agropecuaria

Courtney L. Vaca Honores, Bachiller<sup>1</sup> ; Diego F. Solano Portocarrero, Bachiller<sup>1</sup> ; Carlos D. Rodríguez Vilcarromero, Magister<sup>1</sup> ; Rolando J. Berrú Beltrán, Magister<sup>1</sup> 

<sup>1</sup>Universidad Privada del Norte, Perú, [N00290023@upn.pe](mailto:N00290023@upn.pe), [N00295974@upn.pe](mailto:N00295974@upn.pe), [carlos.vilcarromero@upn.pe](mailto:carlos.vilcarromero@upn.pe), [rolando.berru@upn.edu.pe](mailto:rolando.berru@upn.edu.pe)

**Resumen**– Esta investigación evaluó el impacto de un sistema inteligente con visión computacional para mejorar la gestión de cultivos de palta en una entidad agropecuaria durante el año 2025. Para ello, se aplicó un diseño pre-experimental con una muestra de 15 trabajadores seleccionados bajo criterios de inclusión. La metodología incluyó la recolección de datos mediante cuestionarios estructurados, los cuales fueron procesados en el software XLSTAT aplicando las pruebas de T-Student y Wilcoxon. El análisis estadístico evidenció mejoras sustanciales en los indicadores clave de gestión: la disponibilidad de la información creció un 50.18%, la planificación operativa aumentó un 45.16%, la frecuencia del monitoreo mejoró un 35.32% y la eficiencia de los recursos se incrementó en un 28.42%. Estos hallazgos confirman que la solución tecnológica propuesta optimiza significativamente los procesos de supervisión y la toma de decisiones dentro de la organización agrícola.

**Palabras clave**-- Visión computacional, agricultura, sistema inteligente, gestión de cultivos, palta Hass.

## I. INTRODUCCIÓN

A nivel internacional, un estudio experimental reciente realizado en Nigeria demostró que la dependencia del scouting o inspección visual manual genera brechas significativas de tiempo y cobertura en el monitoreo agrícola. Los resultados evidenciaron que, debido a la dificultad de desplazamiento entre cultivos, el levantamiento de datos manual requirió tres días de trabajo para completarse, mientras que la implementación de un sistema basado en drones (UAV) permitió ejecutar la misma labor en apenas cuatro horas. Persistir en métodos manuales obliga a los gerentes agrícolas a tomar decisiones con información parcial y desactualizada [1].

Asimismo, un estudio reciente realizado en los huertos comerciales de Tzaneen, Sudáfrica, expuso la inviabilidad de los métodos tradicionales, calificando a la inspección visual y el registro manual como procesos estructuralmente 'intensivos en mano de obra, subjetivos y carentes de escalabilidad'. La investigación determinó que depender de la caminata humana genera un cuello de botella crítico: el agrónomo invierte la mayor parte de su jornada en la recolección física y lenta de datos, agotando recursos en tareas repetitivas en lugar de analíticas. Ante este escenario de ineficiencia, es imperativo transitar hacia la automatización del análisis, ya que es la única vía para sustituir los días de recorrido por una interfaz de resultados inmediata, liberando así tiempo valioso para que el profesional se enfoque en la gestión estratégica del cultivo en lugar del desgaste físico de la inspección [2].

Del mismo modo, la dificultad para programar la cosecha y la incertidumbre sobre el volumen real de producción han sido ampliamente reconocidas como una vulnerabilidad crítica en la gestión de huertos comerciales, debido a la dependencia histórica de estimaciones manuales y subjetivas [3]. En Rezekne, Letonia, se expusieron las graves limitaciones de los métodos tradicionales de aforo, demostrando que la dependencia de la 'estimación visual' y los muestreos manuales resulta en datos subjetivos que ignoran la variabilidad espacial del cultivo. El estudio detalla que esta falta de precisión genera una 'ceguera logística' que impide a los productores calcular con exactitud recursos críticos, como la cantidad necesaria de cajas de almacenamiento y el número de trabajadores estacionales a contratar. Esta carencia de información veraz obliga a la gerencia a planificar la logística bajo especulaciones y márgenes de error financieros, evidenciando que la ausencia de herramientas de conteo automático condena a la operación agrícola a sufrir ineficiencias y sobrecostos permanentes por no saber realmente cuánto hay en el campo [4].

En Perú, el sector agroexportador enfrenta una paradoja. Según un análisis de competitividad, aunque la exportación de palta crece a un ritmo promedio anual del 8.04%, este desempeño es engañoso debido a su alta inestabilidad (desviación estándar de 22.14). Esto se confirma al ver que la eficiencia real no ha mejorado: el Índice de Ventaja Comparativa Revelada (RCA) se quedó estancado en 0.966 entre 2019 y 2023. El estudio concluye que este estancamiento ocurre porque los productores siguen confiando únicamente en las buenas condiciones naturales del suelo y el clima (gestión empírica), sin aplicar tecnologías que aseguren el rendimiento. Por ello, se advierte que para dejar de depender de la suerte y lograr un desarrollo sólido, es urgente invertir en agricultura de precisión que permita optimizar la productividad por hectárea mediante datos objetivos [5].

En el ámbito local, la gestión operativa en La Libertad enfrenta limitaciones críticas, tal como se evidencia en el caso de la empresa Agrícola Nuestra Tierra S.A.C. A pesar de contar con certificaciones internacionales (HACCP, Global GAP, GRASP, BASC y FLO), la empresa diagnosticó un 'bajo nivel tecnológico' como una debilidad interna crítica, especificando que carecen de software especializado y dependen de 'programas clásicos' para la elaboración manual de sus cuadros de exportación. Esta gestión precaria provocó que, en las auditorías de revalidación, se tuvieran que levantar de 5 a 10 observaciones moderadas por periodo. El impacto de estas

ineficiencias trascendió a lo económico: los retrasos en pedidos y la pérdida de ventas derivaron en una reducción del 10.30% en el volumen de exportación de paltas al cierre de 2020, demostrando que la falta de sistemas automatizados es una vulnerabilidad financiera estructural [6].

Durante la investigación, se observó que la gestión operativa de la empresa Inka Perú presentaba limitaciones críticas en el monitoreo de palta Hass debido a su dependencia de inspecciones manuales, lo que generaba información fragmentada y deficiencias en la planificación agrícola. Ante esta problemática, se propuso un sistema inteligente que integre visión computacional y análisis de imágenes aéreas, diseñado para superar estas brechas tecnológicas y transitar hacia una toma de decisiones automatizada y basada en datos objetivos en la región La Libertad.

## II. ANTECEDENTES

Ampatzidis y Partel [7] desarrollaron una técnica automatizada de fenotipado de alto rendimiento para la evaluación de características fenotípicas en cultivos de cítricos en Estados Unidos, que incluyó la detección de árboles, identificación de brechas, estimación del tamaño del dosel e índices de salud vegetal. Para ello, implementaron un sistema basado en un vehículo aéreo no tripulado (UAV) tipo hexacóptero equipado con una cámara multispectral, integrando algoritmos de aprendizaje profundo mediante la arquitectura YOLOv3 y redes neuronales convolucionales (CNN) para el procesamiento de mapas multispectrales. Los resultados evidenciaron la detección de 4,931 árboles con una precisión del 99.9% y un recall del 99.7%, además de la identificación de brechas con una precisión del 100% y una estimación del tamaño del dosel con una exactitud del 85.5% en comparación con mediciones manuales. En consecuencia, los autores concluyeron que el uso de UAV combinados con aprendizaje profundo proporcionó un método consistente, rentable y eficiente para el monitoreo automatizado de cultivos, superando las limitaciones de los métodos tradicionales de inspección manual.

Worachairungreung et al. [8] evaluaron la eficacia del modelo de aprendizaje profundo YOLOv5 para la identificación y clasificación de árboles económicos y estructuras artificiales en Tailandia, a partir de imágenes aéreas de alta resolución obtenidas mediante vehículos aéreos no tripulados (UAV). El estudio empleó la arquitectura YOLOv5m, entrenada con un conjunto de 700 imágenes capturadas a una altura de 90 m, las cuales fueron sometidas a técnicas de aumento de datos y divididas en conjuntos de entrenamiento, validación y prueba para la clasificación de cinco categorías de uso de suelo. Los resultados mostraron una precisión de detección superior al 90 % para las principales clases de árboles frutales y estructuras construidas, aunque se evidenció una disminución en la exactitud para cultivos jóvenes debido a la similitud visual con el fondo. Estos resultados demostraron que la integración de imágenes UAV con modelos YOLOv5 constituye una solución eficiente para el mapeo

orientado a objetos, apoyando la gestión agrícola y la planificación del uso del suelo con alta precisión espacial.

Jamali et al. [9] propusieron un método basado en aprendizaje profundo para el mapeo de la distribución del virus scorch en cultivos de arándano en la provincia de Columbia Británica, Canadá, a partir de imágenes aéreas de alta resolución adquiridas mediante vehículos aéreos no tripulados (UAV). El sistema, denominado Scorch Mapper, empleó una arquitectura híbrida que combina Redes Neuronales Convolucionales (CNN) y Vision Transformers (ViT) con el fin de capturar tanto características locales como globales del cultivo, siendo evaluado en campos comerciales reales. Los resultados obtenidos evidenciaron una precisión media del 78.15 % y un puntaje F1 de 0.78, superando el desempeño de modelos tradicionales y demostrando una adecuada capacidad de generalización espacial. Estos hallazgos confirmaron que la integración de arquitecturas híbridas con plataformas UAV permitió el monitoreo automatizado y escalable del estado fitosanitario en cultivos extensivos.

Jamali et al. [10] presentaron un enfoque para la detección y mapeo de la incidencia del virus scorch en cultivos de arándano en Columbia Británica, Canadá, utilizando imágenes de alta resolución capturadas por vehículos aéreos no tripulados (UAV). El estudio comparó el desempeño de sensores RGB y multispectrales mediante el desarrollo de la arquitectura de aprendizaje profundo InceptionLSA, la cual integraba redes neuronales convolucionales con mecanismos de autoatención lineal para la extracción de características locales y globales. El modelo fue evaluado utilizando imágenes re-muestreadas a resoluciones espaciales entre 2 y 50 cm, alcanzando su mejor desempeño con un tamaño de píxel de 20 cm, donde obtuvo una precisión promedio del 76.33% con imágenes multispectrales y del 70.00% con imágenes RGB, superando a arquitecturas convencionales como EfficientNet. Los resultados demostraron que el uso de imágenes UAV con resolución espacial optimizada y modelos híbridos de aprendizaje profundo constituyó una solución eficaz y escalable para el monitoreo del estado fitosanitario de los cultivos, validando además la viabilidad de sensores RGB como alternativa de bajo costo.

Mesías-Ruiz et al. [11] desarrollaron una metodología para la detección, clasificación y georreferenciación de especies de malezas en cultivos de maíz y tomate en parcelas agrícolas experimentales de España, mediante el uso de imágenes adquiridas por vehículos aéreos no tripulados (UAV) y técnicas de aprendizaje profundo. Para ello, implementaron un sistema basado en una cámara RGB comercial acoplada a un UAV, empleando el algoritmo de detección de objetos YOLOv8m junto con estrategias de aprendizaje por transferencia. Los resultados mostraron una precisión de clasificación superior al 99% para la mayoría de las ocho especies analizadas, lo que permitió la generación efectiva de mapas georreferenciados orientados a la toma de decisiones en tiempo real. En consecuencia, los autores concluyeron que la integración de drones y redes neuronales profundas de última generación constituyó una solución eficaz y aplicable para el manejo

localizado de cultivos, contribuyendo a la sostenibilidad agrícola mediante la reducción del uso de herbicidas.

Bautista Huamán [12] desarrolló un sistema de detección y clasificación automática de vegetación agrícola a partir de imágenes de alta resolución adquiridas mediante vehículos aéreos no tripulados (UAV) en el distrito de Manzanares, provincia de Concepción, región Junín (Perú). El sistema se basó en el modelo de detección de objetos YOLOv8 y en la aplicación de la metodología KDD para las etapas de entrenamiento y validación. Los resultados obtenidos alcanzaron una precisión del 92% y una velocidad de procesamiento promedio de 5.4 s por imagen, permitiendo diferenciar cultivos de maíz y papa frente a diversas especies de malezas. Estos resultados evidenciaron que la integración de drones y técnicas de aprendizaje profundo constituyó una herramienta eficaz para el monitoreo agrícola y el apoyo a la toma de decisiones en campo.

### III. OBJETIVOS

#### A. *Objetivo General*

Determinar la influencia de un sistema inteligente con visión computacional en la gestión de cultivos de palta, en una empresa agropecuaria en el año 2025.

#### B. *Objetivos Específicos*

- Determinar la influencia de un sistema inteligente con visión computacional en la frecuencia del monitoreo de la gestión de cultivos de palta en una empresa agropecuaria en el año 2025.
- Definir la influencia de un sistema inteligente con visión computacional en la disponibilidad de la información de la gestión de cultivos de palta en una empresa agropecuaria en el año 2025.
- Establecer la influencia de un sistema inteligente con visión computacional en la eficiencia de los recursos de la gestión de cultivos de palta en una empresa agropecuaria en el año 2025.
- Definir la influencia de un sistema inteligente con visión computacional en la planificación operativa de la gestión de cultivos de palta en una empresa agropecuaria en el año 2025.

### IV. METODOLOGÍA

La investigación utilizó un enfoque pre-experimental con una población de 54 trabajadores de una organización agropecuaria durante el año 2025. Mediante muestreo no probabilístico se seleccionaron 15 trabajadores seleccionados por criterios de inclusión (participación en monitoreo y toma de decisiones) para recopilar la información.

#### A. *Diagnóstico Pretest:*

Para realizar el diagnóstico inicial, se establecieron indicadores específicos agrupados en dos dimensiones clave, los cuales se detallan en la Tabla I.

TABLA I  
INDICADORES DE EVALUACIÓN DE GESTIÓN DE CULTIVOS

| Nº | Dimensión                    | Indicador                                  | Descripción de la medición                                                                                      |
|----|------------------------------|--------------------------------------------|-----------------------------------------------------------------------------------------------------------------|
| 1  | Monitoreo del cultivo        | Frecuencia del monitoreo (Fre-Mon)         | Mide la periodicidad con la que se inspecciona el estado sanitario y fenológico de las plantas.                 |
| 2  |                              | Disponibilidad de la información (Dis-Inf) | Evalúa el acceso inmediato a datos e imágenes actualizadas sobre la condición real del huerto.                  |
| 3  | Toma de decisiones agrícolas | Eficiencia de los recursos (Efi-Rec)       | Mide la optimización en el uso de insumos (agua, fertilizantes) y mano de obra basada en datos objetivos.       |
| 4  |                              | Planificación Operativa (Pla-Ope)          | Evalúa la capacidad para organizar la logística de campo (cosecha, mantenimiento) con precisión y anticipación. |

Como instrumento de recolección de datos, se diseñó y aplicó el "Cuestionario de gestión de cultivos de palta", el cual constó de ítems estructurados en una escala de Likert de 5 puntos. Dicho instrumento fue validado por juicio de expertos obteniendo una validez de contenido del 93.9% y una confiabilidad mediante Alfa de Cronbach de 0.923.

Para obtener el valor del diagnóstico pretest de cada trabajador, se utilizó la siguiente formulación matemática estandarizada de promedio simple:

$$I_x = \frac{\sum_{i=1}^n P_i}{n} \quad (1)$$

Donde:

- $I_x$ : Puntaje promedio asignado al indicador.
- $P_i$ : Puntaje obtenido en cada ítem del indicador.
- $n$ : Número total de ítems que componen dicho indicador.

#### B. *Desarrollo del producto:*

El sistema fue desarrollado como una solución tecnológica para apoyar la gestión de cultivos de palta, enfocada en la automatización del monitoreo agrícola y en la generación de información objetiva para la toma de decisiones. Su desarrollo se organizó en tres etapas: adquisición y análisis de datos, diseño del sistema inteligente e implementación de una aplicación de escritorio para la visualización de resultados.

##### 1) Adquisición y análisis de datos

En esta etapa se definieron los parámetros técnicos para la captura de imágenes aéreas y la construcción del conjunto de datos empleado en el entrenamiento del modelo de visión computacional. El área de estudio correspondió a un fundo agrícola dedicado al cultivo de palta. Dentro de este, se seleccionó una parcela específica para la validación del sistema, la cual fue utilizada para la evaluación detallada de los resultados obtenidos.

La ubicación general del fundo agrícola y la delimitación de la parcela empleada para la validación del sistema se presentan de manera conjunta en la Fig. 1.



Fig. 1. Área de estudio del sistema propuesto, mostrando el fundo agrícola (área general) utilizado para la adquisición de datos y la parcela seleccionada para la validación del sistema.

La adquisición de imágenes se realizó mediante un Vehículo Aéreo No Tripulado (VANT) modelo DJI Flip, seleccionado por su capacidad para capturar imágenes de alta resolución espacial, adecuadas para la segmentación de cultivos arbóreos, específicamente plantas de palta.

Los vuelos se ejecutaron a diferentes alturas con el objetivo de evaluar el impacto de la resolución espacial en la identificación del follaje individual. Las configuraciones seleccionadas permitieron obtener un nivel de detalle suficiente para una segmentación precisa, descartándose alturas mayores debido a la pérdida de información espacial requerida para el análisis.

La cámara fue configurada en orientación nadir con el fin de minimizar distorsiones geométricas y facilitar la generación de productos fotogramétricos. Asimismo, se definieron parámetros de solape frontal y lateral que garantizaron una adecuada superposición entre imágenes, asegurando la correcta reconstrucción bidimensional del cultivo. Los parámetros técnicos de vuelo y captura se resumen en la Tabla II.

TABLA II  
 PARÁMETROS TÉCNICOS DE VUELO Y CAPTURA

| Parámetro         | Configuración             | Objetivo                               |
|-------------------|---------------------------|----------------------------------------|
| Equipo            | DJI Flip                  | Alta resolución y seguridad operativa  |
| Altura de vuelo   | 20 m – 50 m               | Obtener GSD cm/px                      |
| Ángulo de cámara  | -90° (Nadir)              | Reducir distorsión geométrica          |
| Formato de imagen | JPEG (48 MP)              | Optimizar calidad y procesamiento      |
| Solape            | 80% frontal / 70% lateral | Reconstrucción precisa del ortomosaico |

Las imágenes con óptimo solape y nitidez se fragmentaron en teselas de 1024x1024 píxeles para construir el dataset de entrenamiento. Mediante Label Studio, se etiquetaron manualmente 116 imágenes (1532 instancias de palto validadas), consolidando el ground truth a nivel de instancia. Esta densidad poblacional (13.2 árboles/imagen) garantizó variabilidad morfológica frente a cambios de iluminación, asegurando consistencia espacial en las máscaras de

segmentación generadas. La Fig. 2 muestra el proceso de etiquetado manual y la Fig. 3 un ejemplo de imagen original con su máscara correspondiente.




Fig. 2. Proceso de etiquetado manual del follaje de plantas de palta mediante la herramienta Label Studio para la generación de máscaras de segmentación utilizadas como datos de referencia (ground truth).




Fig. 3. Ejemplo de imagen aérea original y su correspondiente máscara de segmentación generada durante el proceso de etiquetado del dataset.

Finalmente, las anotaciones obtenidas fueron exportadas en un formato compatible con el modelo YOLOv8-Seg, permitiendo su integración directa en la etapa de entrenamiento del sistema de visión computacional.

## 2) Diseño del sistema

### 2.1) Diseño del modelo de visión computacional

El diseño del sistema se estructuró en dos componentes principales: el modelo de visión computacional basado en inteligencia artificial y la arquitectura de software.

Para la identificación, conteo y estimación del área foliar de las plantas de palta, se diseñó un modelo de segmentación de instancias basado en la arquitectura YOLOv8-Seg. Este enfoque permitió la generación de máscaras poligonales precisas que delimitaron el contorno real del follaje de cada planta, posibilitando la estimación directa del área foliar en metros cuadrados, a diferencia de los métodos tradicionales basados únicamente en detección de objetos.

Con el fin de preservar la resolución espacial de las imágenes originales y evitar pérdidas de información en escenas de gran extensión, se incorporó una etapa de

preprocesamiento mediante tiling, fragmentando las imágenes en teselas de  $1024 \times 1024$  píxeles, tamaño correspondiente a la entrada óptima del modelo YOLOv8-Seg. Esta estrategia permitió un equilibrio adecuado entre precisión en la segmentación y eficiencia computacional, mejorando el desempeño del modelo en áreas con alta densidad vegetal.

El pipeline de procesamiento se estructuró en una secuencia de etapas definidas: (a) carga de imágenes georreferenciadas adquiridas mediante vuelos fotogramétricos con VANT; (b) fragmentación de las imágenes en teselas; (c) ejecución de la inferencia con el modelo YOLOv8-Seg para la generación de máscaras poligonales individuales por planta; (d) reconstrucción espacial de las máscaras a partir de todas las teselas procesadas; y (e) generación de salidas vectoriales georreferenciadas para su análisis e integración en sistemas de información geográfica, cuyo flujo general se ilustra en la Fig. 4.




Fig. 4. Pipeline de procesamiento de visión computacional para segmentación de plantas.

## 2.2 Diseño de la arquitectura del sistema

El sistema fue diseñado bajo una arquitectura desacoplada, permitiendo la separación entre los módulos de procesamiento, almacenamiento y visualización de datos, lo cual facilitó el mantenimiento y la escalabilidad del sistema.

El procesamiento de imágenes y la ejecución del modelo de visión computacional se realizaron en un módulo independiente, mientras que la información generada fue almacenada en una base de datos PostgreSQL con extensión PostGIS, permitiendo el almacenamiento de geometrías poligonales asociadas a cada planta detectada y la ejecución de cálculos espaciales, como la estimación automática del área foliar.

Si bien la implementación final correspondió a una aplicación de escritorio, la arquitectura fue diseñada bajo un enfoque cliente-servidor, con el objetivo de permitir su futura escalabilidad hacia entornos web. La arquitectura general del sistema, que integra el módulo de visión computacional, la base de datos espacial y la aplicación de visualización, se presenta en la Fig. 5.




Fig. 5. Arquitectura general del sistema propuesta basada en un modelo cliente-servidor, integrando un módulo de visión computacional, una base de datos espacial y una aplicación de visualización.

## 3) Implementación del Sistema

### 3.1 Entrenamiento e inferencia del modelo

El modelo de segmentación de instancias (YOLOv8-Seg) fue entrenado localmente mediante aceleración por GPU (NVIDIA RTX 3050) durante 123 épocas con un mecanismo de detención temprana (Early Stopping), utilizando la librería Ultralytics en Python. La evaluación cuantitativa del entrenamiento evidenció una Precisión del 95.5%, Sensibilidad del 93.3% y un desempeño global sobresaliente: mAP@0.5 de 0.978 en detección espacial y 0.966 en segmentación morfológica, optimizado bajo un umbral de confianza de 0.533 (F1-Score máximo de 0.94). Durante la etapa de inferencia, empleando Rasterio para el manejo de imágenes georreferenciadas, la salida del modelo consistió en máscaras vectoriales con coordenadas reales, permitiendo su integración directa en el sistema para el conteo automático de plantas y la estimación del área foliar individual.

### 3.2 Cálculo del índice VARI

Con el fin de analizar el vigor vegetativo del cultivo de palta, se implementó el Índice de Vegetación Visible (VARI), calculado a partir de las bandas RGB de imágenes aéreas adquiridas con cámara convencional, constituyendo una alternativa adecuada en ausencia de información multispectral. El índice se obtuvo mediante la ecuación:

$$VARI = \frac{G - R}{G + R - B} \quad (2)$$

donde  $R$ ,  $G$  y  $B$  representan las bandas roja, verde y azul, respectivamente. Esta formulación permitió resaltar el verdor del follaje, incorporando un término de corrección atmosférica mediante la banda azul para reducir efectos de iluminación y bruma.

El cálculo del VARI fue integrado al sistema como un módulo complementario al proceso de segmentación. Para mejorar la confiabilidad del análisis, se aplicó un filtrado de sombras basado en el brillo de la imagen y una normalización dinámica mediante percentiles. Los valores resultantes se representaron mediante un mapa temático tipo semáforo, facilitando la interpretación visual del vigor vegetativo. Un ejemplo de los resultados obtenidos se presenta en la Fig. 6.




Fig. 6. Mapa temático del índice VARI generado a partir de imágenes aéreas RGB, utilizado para el análisis del vigor vegetativo del cultivo de palta.

### 3.3 Flujo de funcionamiento del sistema propuesto

El sistema implementado operó bajo un flujo secuencial e integrado que combinó la adquisición de datos mediante UAV, el procesamiento automático basado en visión computacional y la visualización de resultados a través de una aplicación de escritorio.

El proceso se inició con la carga de imágenes aéreas georreferenciadas correspondientes a un lote agrícola y una fecha de monitoreo específica, las cuales fueron asociadas a su respectiva campaña agrícola. Posteriormente, el sistema ejecutó de forma automática el pipeline previamente descrito, generando como resultado final la segmentación y clasificación de las plantas analizadas.

Como salida del procesamiento, se generaron entidades vectoriales poligonales georreferenciadas que representaron cada planta detectada, las cuales fueron almacenadas junto con atributos como área estimada, coordenadas espaciales y fecha de monitoreo. Los resultados obtenidos permitieron la segmentación y clasificación de las plantas de palta por categorías de tamaño, como se muestra en la Fig. 7.



Fig. 7. Resultado del procesamiento de imágenes aéreas mediante el sistema desarrollado, mostrando la detección y clasificación de plantas de palta en categorías de tamaño (pequeñas, medianas y grandes).

Adicionalmente, los resultados integrados del sistema, incluyendo métricas de desempeño del modelo, validación humana y la distribución de tamaños de plantas, fueron presentados mediante un panel de visualización consolidado, facilitando el análisis global del cultivo y la interpretación de los resultados, como se muestra en la Fig. 8. Asimismo, la Fig.

9 presenta la interfaz gráfica del sistema durante la ejecución del monitoreo, mostrando la detección y clasificación automática de las plantas a partir de imágenes aéreas procesadas.




Fig. 8. Dashboard de evaluación del sistema: Análisis comparativo de detección y métricas de confusión por sector.



Fig. 9. Interfaz gráfica del sistema de monitoreo de cultivos mostrando la detección y clasificación automática de plantas.

### C. Diagnóstico Posttest:

Tras la implementación del sistema durante un periodo de tres meses, se aplicó nuevamente el mismo instrumento (cuestionario) a la muestra de estudio. Los datos recolectados en esta etapa, junto con los del pretest, fueron procesados utilizando el software estadístico XLSTAT.

Se aplicaron pruebas de normalidad (Shapiro–Wilk) con el fin de determinar la distribución de los datos. En función de estos resultados, se seleccionaron las pruebas de hipótesis correspondientes (T de Student para datos paramétricos o prueba de Wilcoxon para datos no paramétricos), con el objetivo de determinar la significancia de la mejora en la gestión de cultivos tras la intervención tecnológica.

## V. RESULTADOS

En este capítulo se presentarán los hallazgos obtenidos tras el procesamiento estadístico de los datos recolectados. El análisis se centró en la comparación de los puntajes promedio antes (Pre-Test) y después (Post-Test) de la implementación del sistema inteligente, verificando la normalidad de la distribución

y contrastando las hipótesis planteadas para determinar la significancia del cambio en los cuatro indicadores evaluados.

Previo al análisis inferencial, se aplicó la prueba de Shapiro-Wilk a las diferencias de los puntajes (Post-Pre) de cada indicador. Se obtuvo los siguientes resultados:

TABLA III  
PRUEBA DE NORMALIDAD DE SHAPIRO-WILK

| Indicador | Estadístico (W) | Sig. (p-valor) | Decisión estadística |
|-----------|-----------------|----------------|----------------------|
| 1         | Fre-Mon         | 0.848          | No Normal (Wilcoxon) |
| 2         | Dis-Inf         | 0.909          | Normal (T-Student)   |
| 3         | Efi-Rec         | 0.880          | No Normal (Wilcoxon) |
| 4         | Pla-Ope         | 0.955          | Normal (T-Student)   |

A continuación, se presenta la validación estadística para cada indicador, estableciendo un nivel de confianza del 95% ( $\alpha = 0.05$ ).

#### Indicador 1: Frecuencia del monitoreo (Fre-Mon)

$H_0$ : El sistema inteligente con visión computacional no mejora la frecuencia del monitoreo en la gestión de cultivos de palta ( $Me_{pre} = Me_{post}$ ).

$H_a$ : El sistema inteligente con visión computacional mejora la frecuencia del monitoreo en la gestión de cultivos de palta ( $Me_{pre} < Me_{post}$ ).

La Fig. 10 presenta los resultados de la prueba de rangos con signo de Wilcoxon. Se obtuvo un estadístico estandarizado de  $Z = -3.439$  y un valor-p (unilateral) inferior a 0.0001, el cual es menor al nivel de significancia establecido ( $\alpha = 0.05$ ). En consecuencia, **se rechaza la hipótesis nula y se acepta la hipótesis alternativa**.




Fig. 10. Comparativa de medias pre-test y post-test para la Fre-Mon.

Como se observa en la Fig. 11, el valor promedio de la frecuencia del monitoreo incrementó tras la implementación del sistema inteligente con visión computacional, en comparación con el periodo previo a su implementación.




Fig. 11. Valores pre-test y post-test de la Fre-Mon.

#### A. Indicador 2: Disponibilidad de la información (Dis-Inf)

$H_0$ : El sistema inteligente con visión computacional no mejora la disponibilidad de la información en la gestión de cultivos de palta ( $u_{pre} = u_{post}$ ).

$H_a$ : El sistema inteligente con visión computacional mejora la disponibilidad de la información en la gestión de cultivos de palta ( $u_{pre} < u_{post}$ ).

La Fig. 12 presenta los resultados de la prueba de T de Student. El valor  $t(\text{obs}) = -5.798$ , es inferior al valor crítico  $t(\text{crit}) = -1.761$ . En consecuencia, **se rechaza la hipótesis nula y se acepta la hipótesis alternativa**.




Fig. 12. Evaluación del área de aceptación o rechazo de la Dis-Inf.

Como se observa en la Fig. 13, el valor promedio de la disponibilidad de la información incrementó tras la implementación del sistema inteligente con visión computacional, en comparación con el periodo previo a su implementación.




Fig. 13. Valores pre-test y post-test de la Dis-Inf.




Fig. 15. Valores pre-test y post-test de la Efi-Rec.

### B. Indicador 3: Eficiencia de los recursos (Efi-Rec)

$H_0$ : El sistema inteligente con visión computacional no mejora la eficiencia de los recursos en la gestión de cultivos de palta ( $Me_{pre} = Me_{post}$ ).

$H_a$ : El sistema inteligente con visión computacional mejora la eficiencia de los recursos en la gestión de cultivos de palta ( $Me_{pre} < Me_{post}$ ).

La Fig. 14 presenta los resultados de la prueba de rangos con signo de Wilcoxon. Se obtuvo un estadístico estandarizado de  $Z = -3.419$  y un valor-p (unilateral) inferior a 0.0001, el cual es menor al nivel de significancia establecido ( $\alpha = 0.05$ ). En consecuencia, **se rechaza la hipótesis nula y se acepta la hipótesis alternativa**.




Fig. 14. Comparativa de medias pre-test y post-test para la Efi-Rec.

Como se observa en la Fig. 15, el valor promedio de la eficiencia de los recursos incrementó tras la implementación del sistema inteligente con visión computacional, en comparación con el periodo previo a su implementación.

### C. Indicador 4: Planificación Operativa (Pla-Ope)

$H_0$ : El sistema inteligente con visión computacional no mejora la planificación operativa en la gestión de cultivos de palta ( $u_{pre} = u_{post}$ ).

$H_a$ : El sistema inteligente con visión computacional mejora la planificación operativa en la gestión de cultivos de palta ( $u_{pre} < u_{post}$ ).

La Fig. 16 presenta los resultados de la prueba de T de Student. El valor  $t(\text{obs}) = -4.939$ , es inferior al valor crítico  $t(\text{crit}) = -1.761$ . En consecuencia, **se rechaza la hipótesis nula y se acepta la hipótesis alternativa**.




Fig. 16. Evaluación del área de aceptación o rechazo de la Pla-Ope.

Como se observa en la Fig. 17, el valor promedio de la planificación operativa incrementó tras la implementación del sistema inteligente con visión computacional, en comparación con el periodo previo a su implementación.




Fig. 17. Valores pre-test y post-test de la Pla-Ope.

Los resultados de las Figuras 11, 13, 15 y 17 muestran un incremento positivo en los puntajes de cada indicador, evidenciando la influencia favorable del sistema inteligente con visión computacional. La Tabla IV resume los promedios del pre-test y post-test, destacando la diferencia entre ambos.

TABLA IV  
PROMEDIOS GENERALES DE LOS RESULTADOS

| Indicador | Pre-test | Post-test | (Post) – (Pre) | %              |
|-----------|----------|-----------|----------------|----------------|
| 1 Fre-Mon | 2.52     | 3.41      | <b>+0.89</b>   | <b>+35.32%</b> |
| 2 Dis-Inf | 2.71     | 4.07      | <b>+1.36</b>   | <b>+50.18%</b> |
| 3 Efi-Rec | 2.85     | 3.66      | <b>+0.81</b>   | <b>+28.42%</b> |
| 4 Pla-Ope | 2.79     | 4.05      | <b>+1.26</b>   | <b>+45.16%</b> |

## VI. DISCUSIÓN

El análisis estadístico detallado en la Tabla IV revela que la frecuencia del monitoreo partió de una media de 2.52 puntos en la escala del 1 al 5 antes de la intervención del sistema inteligente con visión computacional. Tras la implementación, este valor experimentó un aumento del 35.32%, alcanzando un promedio aprobatorio de 3.41 puntos. Este hallazgo se contextualiza con lo reportado en el artículo “Development of an Unmanned Aerial Vehicle for Intelligent Monitoring: An Insight in Precision Farming”, donde los autores Adetunla et al. [1] demostraron que el uso de VANTs permite reducir drásticamente los tiempos de inspección, pasando de días de labor manual a solo horas de operación aérea.

Esta optimización de los tiempos operativos reportada en el estudio [1], es el factor clave que facilitó el incremento de la frecuencia observado en esta investigación. Si bien emplearon una planificación de vuelo totalmente autónoma, el presente estudio demuestra que un vuelo manual asistido también es capaz de generar mejoras significativas. A pesar de que el enfoque manual mantiene una dependencia del piloto para correcciones y pausas de seguridad, la agilidad propia del sistema aéreo fue suficiente para superar las barreras logísticas del método tradicional, validando que no es indispensable una automatización total para lograr un monitoreo más recurrente y efectivo.

Respecto a la planificación operativa, se registró un puntaje inicial de 2.79 puntos; sin embargo, el uso del sistema impulsó este indicador en un 45.16%, logrando consolidar un promedio final de 4.05 puntos. Este hallazgo concuerda con lo reportado en el reciente estudio de Jamali et al. [9], titulado “High-resolution UAV-based blueberry scorch virus mapping utilizing a deep vision transformer algorithm”, quienes lograron generar mapas de distribución de enfermedades con una precisión de clasificación (Overall Accuracy) del 78.06%, demostrando que la identificación espacial eficaz de zonas críticas es el insumo fundamental para intervenir el cultivo.

La distinción en los alcances de ambos estudios radica en la arquitectura tecnológica empleada: el estudio [9] implementó algoritmos Deep Vision Transformer, los cuales poseen una alta complejidad computacional capaz de identificar patrones sutiles de virus mediante el análisis de dependencias globales en la imagen. A diferencia de ello, la presente investigación utilizó la arquitectura YOLOv8 en conjunto con el índice VARI, un enfoque priorizado hacia la velocidad de inferencia y la segmentación operativa; si bien este método es menos sensible a micro-patologías que un Transformer, demostró ser altamente efectivo para la logística diaria, permitiendo transformar la planificación de un enfoque reactivo manual a uno preventivo basado en mapas de vigor zonificados.

Por otro lado, al evaluar la eficiencia de los recursos, se observó una media base de 2.85 puntos que, tras emplear el sistema, se incrementó en un 28.42% hasta situarse en 3.66 puntos. Este hallazgo se respalda con el estudio de Mesías-Ruiz et al. [11], titulado “Detección y clasificación de malas hierbas mediante drones y redes neuronales profundas: creación de mapas para tratamiento localizado”, quienes evidenciaron que alcanzar una precisión de detección superior al 99% es el factor determinante para lograr una mejora tangible en la eficiencia operativa. Este alto nivel de exactitud permitió a los autores generar mapas de prescripción para aplicar tratamientos de forma selectiva, validando lo que mide nuestro indicador: la optimización en el uso de insumos (herbicidas/agua) y mano de obra basada en datos objetivos, evitando la aplicación masiva en zonas que no lo requieren.

La distinción entre ambos enfoques radica en la granularidad del diagnóstico: el sistema de [11] se especializó en la discriminación taxonómica de malezas específicas —una tarea que exige ese 99% de precisión para decidir la aplicación química—, mientras que la presente investigación se centró en el monitoreo del vigor general mediante el índice VARI. Aunque la complejidad técnica varía según el objetivo, ambos sistemas convergen en el mismo resultado práctico: la capacidad de segmentar el terreno para destinar los recursos estrictamente donde son necesarios, transformando la gestión agrícola de un modelo extensivo a uno de precisión.

Finalmente, el impacto más notable se evidenció en la disponibilidad de la información, indicador que pasó de un promedio inicial de 2.71 puntos a 4.07 puntos tras la intervención del sistema, lo que representa un crecimiento del 50.18%. Este resultado es congruente con la capacidad

tecnológica validada en el estudio de Zheng, Sun, Meng y Nan [13], titulado "Vegetable Size Measurement Based on Stereo Camera and Keypoints Detection", quienes demostraron que mediante visión artificial es posible capturar y procesar datos morfológicos de los cultivos con una fiabilidad superior al 98% (error de 1.99%), garantizando la obtención de información veraz sin contacto físico.

La mejora sustancial en la disponibilidad de la información se debe a que, al igual que el sistema del estudio [13] digitalizó la variable de "tamaño" para hacerla accesible, la presente investigación digitalizó el estado de "vigor" del cultivo. Esta digitalización automática elimina la brecha de tiempo y subjetividad de los reportes manuales, permitiendo que los datos sobre la condición real del huerto estén inmediatamente disponibles para la toma de decisiones, tal como se refleja en el alto porcentaje de mejora percibido por los usuarios.

## VII. CONCLUSIONES

Se demostró que la disponibilidad de la información mostró una mejora sustancial, alcanzando un valor promedio de 4.07 en el post-test frente a los 2.71 obtenidos en el pre-test. Este notable incremento del 50.18%, validado por la prueba T de Student, confirma que la digitalización y el procesamiento de imágenes permiten el acceso inmediato a datos objetivos sobre el estado del huerto, superando la fragmentación de los registros tradicionales.

Se determinó que la planificación operativa se optimizó tras la adopción del sistema, elevando su promedio de 2.79 a 4.05. Esta mejora, respaldada por la prueba T de Student, con un aumento del 45.16%, evidencia que la segmentación precisa del follaje facilita una distribución más estratégica de los insumos y la mano de obra, reduciendo el desperdicio operativo.

Se comprobó que el sistema inteligente con visión computacional tuvo un impacto positivo sobre la frecuencia del monitoreo, logrando que el puntaje promedio pasara de 2.52 en el pre-test a 3.41 en el post-test. Este hallazgo, validado mediante la prueba de Wilcoxon, representa un incremento del 35.32%, lo que demuestra la capacidad del sistema para agilizar la supervisión continua del cultivo frente a las limitaciones de tiempo de la inspección manual.

Finalmente, los resultados confirman que el sistema inteligente perfeccionó significativamente la eficiencia de los recursos, pasado de un promedio de 2.85 a 3.66 tras su implementación. Este aumento del 28.42%, validado mediante la prueba de Wilcoxon, evidencia que la segmentación precisa del follaje facilita una distribución más estratégica de los insumos y la mano de obra, reduciendo el desperdicio operativo.

## AGRADECIMIENTO

Los autores expresan su sincero agradecimiento al Sr. Pablo Solano por permitir el acceso a los campos de cultivo y facilitar la captura de imágenes aéreas con el dron; y al Sr. Jeyssler Solano por su valiosa colaboración en la coordinación

de los horarios con el personal para la efectiva recolección de datos.

## REFERENCIAS

- [1] O. Adetunla, O. O. Igenewari, A. O. Salau, J. O. Dada, and C. C. Kit, "Development of an unmanned aerial vehicle for intelligent monitoring: An insight in precision farming," *J. Eur. Syst. Autom.*, vol. 58, no. 5, pp. 931–941, May 2025. [Online]. Available: <https://doi.org/10.18280/jesa.580507>. [Accessed: Jan. 25, 2026].
- [2] M. M. Rahman, A. Robson, and T. Bekker, "Machine learning approaches for assessing avocado alternate bearing using Sentinel-2 and climate variables—A case study in Limpopo, South Africa," *Remote Sens.*, vol. 17, no. 24, Art. no. 3935, Dec. 2024. [Online]. Available: <https://doi.org/10.3390/rs17243935>. [Accessed: Jan. 25, 2026].
- [3] J. Gongal, S. Amaty, M. Karkee, Q. Zhang, and K. Lewis, "Sensors and systems for fruit detection and localization: A review," *Comput. Electron. Agric.*, vol. 116, pp. 8–19, 2015. [Online]. Available: <https://doi.org/10.1016/j.compag.2015.05.021>. [Accessed: Jan. 25, 2026].
- [4] S. Kodors *et al.*, "Autonomous yield estimation system for small commercial orchards using UAV and AI," *Drones*, vol. 8, no. 12, Art. no. 734, Dec. 2024. [Online]. Available: <https://doi.org/10.3390/drones8120734>. [Accessed: Jan. 25, 2026].
- [5] J. C. Montes-Ninaquispe *et al.*, "Peruvian agro-exports' competitiveness: An assessment of the export development of its main products," *Economies*, vol. 12, no. 6, Art. no. 156, Jun. 2024. [Online]. Available: <https://doi.org/10.3390/economies12060156>. [Accessed: Jan. 25, 2026].
- [6] I. E. Guerra Caro and S. N. Toribio Reyes, "La gestión de calidad y su incidencia en las exportaciones de palta orgánica de la empresa Agrícola Nuestra Tierra S.A.C. del año 2021," B.S. thesis, Univ. Privada del Norte, Trujillo, Peru, 2022. [Online]. Available: <https://hdl.handle.net/11537/33329>. [Accessed: Jan. 25, 2026].
- [7] Y. Ampatzidis and V. Partel, "UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence," *Remote Sens.*, vol. 11, no. 4, Art. no. 410, 2019. [Online]. Available: <https://doi.org/10.3390/rs11040410>. [Accessed: Jan. 25, 2026].
- [8] M. Worachairungreung, N. Kulpanich, P. Sae-Ngow, K. Thanakunwuthirot, and P. Hemwan, "Geospatial monitoring of land use and tree cover using unmanned aerial vehicles and YOLOv5: A case study on tree crops and built-up detection in Thailand," *Geocarto Int.*, vol. 40, no. 1, Art. no. 2598496, 2025. [Online]. Available: <https://doi.org/10.1080/10106049.2025.2598496>. [Accessed: Jan. 25, 2026].
- [9] A. Jamali *et al.*, "High-resolution UAV-based blueberry scorch virus mapping utilizing a deep vision transformer algorithm," *Comput. Electron. Agric.*, vol. 229, Art. no. 109726, 2025. [Online]. Available: <https://doi.org/10.1016/j.compag.2024.109726>. [Accessed: Jan. 25, 2026].
- [10] A. Jamali *et al.*, "High-resolution mapping of blueberry scorch virus incidence using RGB and multispectral UAV images and deep learning," *Remote Sens. Appl. Soc. Environ.*, vol. 36, Art. no. 101390, 2024. [Online]. Available: <https://doi.org/10.1016/j.rsase.2024.101390>. [Accessed: Jan. 25, 2026].
- [11] G. A. Mesías-Ruiz, J. M. Peña, A. I. de Castro, I. Borra-Serrano, and J. Dorado, "Detección y clasificación de malas hierbas mediante drones y redes neuronales profundas: Creación de mapas para tratamiento localizado," *Rev. Cienc. Agrár.*, vol. 47, no. 1, pp. 175–179, 2024. [Online]. Available: <https://doi.org/10.19084/rca.34973>. [Accessed: Jan. 25, 2026].
- [12] C. M. Bautista Huamán, "Sistema de detección de maleza en cultivos agrícolas utilizando imágenes adquiridas por dron, visión computacional y deep learning en el distrito de Manzanares – Concepción," B.S. thesis, Univ. Nacional del Centro del Perú, Huancayo, Peru, 2025. [Online]. Available: <https://repositorio.uncp.edu.pe/server/api/core/bitstreams/ad977514-10c1-4bca-9671-a54105b086c1/content>. [Accessed: Jan. 25, 2026].
- [13] B. Zheng, G. Sun, Z. Meng, and R. Nan, "Vegetable size measurement based on stereo camera and keypoints detection," *Sensors*, vol. 22, no. 4, Art. no. 1617, Feb. 2022. [Online]. Available: <https://doi.org/10.3390/s22041617>. [Accessed: Jan. 25, 2026].