

ResNet-50-Based Vision System for the Classification of *Tetranychus urticae* in Hass Avocado

Jose Antonio Capcha Collazos, Degree¹, Alex Ali Llanto Mallqui, Degree², Alert Mendoza Acosta, Mag.³, Edward Russel Sanchez Penadillo, Mag.⁴

^{1,2,3,4}Universidad Tecnológica del Perú, Perú, 1511949@utp.edu.pe, u19204381@utp.edu.pe, e08141@utp.edu.pe, e10173@utp.edu.pe

Abstract– This paper presents the design of a computer vision system based on convolutional neural networks (CNNs) for the detection of *Tetranychus urticae* in Hass avocado leaves. This pest represents a significant phytosanitary challenge affecting the export quality of Peruvian avocados. The proposed approach uses the ResNet-50 architecture with transfer learning to classify images into two categories: healthy and infested leaves. The model was trained with a proprietary dataset of 900 images, collected under controlled lighting conditions, and split into 70% for training, 15% for validation, and 15% for testing. The images were preprocessed using normalization, resizing to 224×224 pixels, and data augmentation techniques to improve model robustness. The resulting system achieved a classification accuracy of 96% on the test dataset, confirming its effectiveness under controlled conditions. Although the system demonstrated high accuracy in a simulated environment, further validation with field data is necessary to assess its generalization and deployment feasibility in real agricultural scenarios. The development process adhered to the VDI 2206 methodology for mechatronic systems design and was implemented using Python, TensorFlow, Keras, and Jupyter Notebook. This study constitutes a validated proof of concept for intelligent pest classification in precision agriculture, with future work focusing on system validation in field conditions, integration with mobile platforms, and expansion to detect multiple pest types.

Keywords-- *Tetranychus urticae*, Hass avocado, computer vision, convolutional neural networks, ResNet-50, deep learning, pest detection, image classification

Sistema de visión basado en ResNet-50 para la clasificación de *Tetranychus urticae* en palta Hass

Jose Antonio Capcha Collazos, Degree¹, Alex Ali Llanto Mallqui, Degree², Alert Mendoza Acosta, Mag.³, Edward Russel Sanchez Penadillo, Mag.⁴

^{1,2,3,4}Universidad Tecnológica del Perú, Perú, 1511949@utp.edu.pe, u19204381@utp.edu.pe, e08141@utp.edu.pe, e10173@utp.edu.pe

Resumen—Este artículo presenta el diseño de un sistema de visión por computadora basado en redes neuronales convolucionales (CNN) para la detección de *Tetranychus urticae* en hojas de palta Hass. Esta plaga representa un desafío fitosanitario significativo que afecta la calidad de exportación de las paltas peruanas. El enfoque propuesto utiliza la arquitectura ResNet-50 con aprendizaje por transferencia para clasificar imágenes en dos categorías: hojas sanas y hojas infestadas. El modelo fue entrenado con un conjunto de datos propio compuesto por 900 imágenes, recolectadas bajo condiciones de iluminación controlada, y dividido en 70% para entrenamiento, 15% para validación y 15% para prueba. Las imágenes fueron preprocesadas mediante normalización, redimensionamiento a 224×224 píxeles y técnicas de aumento de datos (data augmentation) para mejorar la robustez del modelo. El sistema resultante alcanzó una precisión de clasificación del 96% en el conjunto de prueba, lo que confirma su efectividad en condiciones controladas. Aunque el sistema demostró una alta precisión en un entorno simulado, se requiere validación adicional con datos de campo para evaluar su capacidad de generalización y viabilidad de implementación en escenarios agrícolas reales. El proceso de desarrollo siguió la metodología VDI 2206 para el diseño de sistemas mecatrónicos y fue implementado utilizando Python, TensorFlow, Keras y Jupyter Notebook. Este estudio constituye una prueba de concepto validada para la clasificación inteligente de plagas en el contexto de la agricultura de precisión, y los trabajos futuros se enfocarán en la validación en campo, la integración con plataformas móviles y la ampliación del sistema para detectar múltiples tipos de plagas.

Palabras clave— *Tetranychus urticae*, palta Hass, visión por computadora, redes neuronales convolucionales, ResNet-50, aprendizaje profundo, detección de plagas, clasificación de imágenes

I. INTRODUCCIÓN

La palta Hass (*Persea americana*) es uno de los cultivos de mayor valor comercial en el Perú, país que actualmente ocupa el segundo lugar a nivel mundial en exportaciones de palta, después de México. Solo en el año 2023, el país exportó más de 599,000 toneladas de palta Hass, generando importantes ingresos económicos [1], lo que consolidó al Perú como el segundo mayor exportador mundial de este cultivo [2].

Sin embargo, este logro se ve amenazado por persistentes desafíos fitosanitarios, en particular la infestación de plagas como el ácaro rojo (*Tetranychus urticae*), perteneciente a la familia Tetranychidae. Estos ácaros se alimentan del tejido vegetal, provocando manchas cloróticas, necrosis, caída prematura de hojas y, en general, un deterioro en la calidad y el rendimiento del fruto [3][4].

Los métodos de inspección manual —aún predominantes en muchas zonas agrícolas— resultan inadecuados para la detección en etapas tempranas, debido a su subjetividad, requerimiento intensivo de mano de obra y baja escalabilidad [5]. A medida que aumentan las exigencias de los mercados internacionales, se vuelve cada vez más urgente contar con sistemas automatizados, precisos y escalables para la detección de plagas.

La inteligencia artificial (IA) y la visión por computadora han demostrado un gran potencial para enfrentar estos desafíos agrícolas. En particular, las redes neuronales convolucionales (CNN) han mostrado alta eficacia en tareas de clasificación basadas en imágenes, como el reconocimiento de enfermedades en plantas y la detección de plagas [6], [7]. Estos modelos extraen automáticamente características jerárquicas de las imágenes sin necesidad de ingeniería manual de características, mejorando su robustez ante condiciones diversas.

A pesar de los resultados prometedores en otros cultivos, el uso de CNN para detectar *T. urticae* en hojas de palta sigue siendo limitado. Los enfoques existentes suelen enfocarse en la calidad postcosecha o en la detección general de enfermedades, con pocas soluciones dirigidas a un diagnóstico de plagas en campo, bajo condiciones variables de iluminación o morfología foliar [8].

Investigaciones previas han demostrado el potencial de las CNN para la detección de enfermedades y plagas en cultivos. Mohanty et al. [17] entrenaron modelos de deep learning para la identificación de enfermedades en 14 especies vegetales, alcanzando una precisión superior al 99%. Ferentinos [18] evaluó arquitecturas CNN en más de 87,000 imágenes agrícolas y reportó precisiones de hasta 99.5%. Barbedo [19] exploró la clasificación de lesiones individuales con deep learning, resaltando los desafíos de variabilidad en condiciones reales. Asimismo, Too et al. [20] compararon modelos como ResNet, Inception y DenseNet en identificación de enfermedades foliares, concluyendo que ResNet ofrece un balance óptimo entre precisión y costo computacional. Estos estudios validan el uso de CNN en agricultura, pero ninguno aborda específicamente la detección de *Tetranychus urticae* en palta Hass bajo condiciones locales, lo cual constituye la principal contribución de este trabajo.

Este artículo presenta el diseño y validación de un sistema de visión por computadora basado en la arquitectura ResNet-50 y aprendizaje por transferencia, orientado a detectar la

presencia de *T. urticae* en hojas de palta Hass. Se desarrolló un conjunto de datos propio bajo condiciones controladas, y el sistema fue entrenado y evaluado utilizando métricas estándar del aprendizaje profundo. El desarrollo siguió el marco VDI 2206 para el diseño estructurado de sistemas mecatrónicos.

Este trabajo constituye una prueba de concepto validada, que demuestra la viabilidad técnica de utilizar aprendizaje profundo y visión por computadora para la detección de plagas en condiciones controladas. Como tal, proporciona una base para el desarrollo futuro hacia su implementación práctica en entornos de campo y su integración en sistemas de agricultura de precisión.

Las contribuciones de este trabajo incluyen:

1. El desarrollo de un modelo basado en CNN dirigido a la detección temprana de *T. urticae*.
2. La implementación de un pipeline robusto de preprocesamiento y aumento de datos.
3. La demostración del rendimiento del sistema mediante simulación y evaluación basada en métricas.

La estructura del artículo es la siguiente: la Sección II describe la metodología, incluyendo la arquitectura del sistema, preparación del conjunto de datos y proceso de entrenamiento. La Sección III presenta los resultados y su análisis. Finalmente, la Sección IV concluye con una discusión sobre las limitaciones del estudio y las futuras líneas de investigación.

En investigaciones previas relacionadas con el cultivo de palta, se ha demostrado la efectividad de técnicas de visión por computadora y aprendizaje profundo en la detección de enfermedades como la antracnosis y la pudrición interna. Estudios emplearon segmentación semántica con imágenes hiperespectrales, redes neuronales convolucionales entrenadas con aprendizaje supervisado, y descriptores cromáticos, alcanzando precisiones de clasificación entre el 86% y el 98% [9][10][11].

II. METODOLOGÍA

A. Diseño del Sistema

El desarrollo del sistema propuesto siguió la metodología VDI 2206 para el diseño de sistemas mecatrónicos, la cual establece cinco fases estructuradas: definición de requisitos, diseño del sistema, programación, integración y validación. Este enfoque de ingeniería permitió un flujo de trabajo sistemático, promoviendo la modularidad, la trazabilidad y la coherencia entre las decisiones de diseño y los resultados de implementación. Esta metodología ha sido aplicada en diversos proyectos de automatización y visión artificial por su estructura modular y capacidad de adaptación a sistemas complejos [12].

El sistema integra una canalización de visión por computadora con un clasificador basado en una red neuronal convolucional (CNN). Su función principal es detectar la

presencia o ausencia de *Tetranychus urticae* en hojas de palta Hass, a través de tres procesos centrales: adquisición de imágenes, preprocesamiento y clasificación. La información visual sirve como entrada para la toma de decisiones automatizada en la gestión del control de plagas.

Aunque las subsecciones de la metodología están organizadas por componentes funcionales —como la preparación del conjunto de datos, la arquitectura del modelo y el procedimiento de entrenamiento—, cada etapa se alinea con las fases correspondientes del modelo VDI 2206. Esta alineación garantiza rigor metodológico y trazabilidad, desde la especificación inicial de requisitos hasta la validación del sistema.

El flujo de trabajo del sistema se ilustra en la Fig. 1, que describe la secuencia desde la adquisición de imágenes hasta la clasificación final y la visualización de resultados. Cada componente representa una etapa modular alineada con la metodología de diseño VDI 2206, incluyendo la captura de datos, preprocesamiento, clasificación mediante aprendizaje profundo y la interfaz de salida para el usuario.

El proceso de desarrollo siguió la metodología VDI 2206 para el diseño de sistemas mecatrónicos y fue implementado utilizando Python, TensorFlow, Keras y Jupyter Notebook. Estas herramientas han sido ampliamente utilizadas en investigaciones similares debido a su versatilidad, escalabilidad y compatibilidad con bibliotecas científicas como NumPy, Matplotlib y OpenCV, facilitando el desarrollo de sistemas de visión artificial aplicados a la agricultura [13].




Fig. 1 Diagrama de bloques del sistema de visión para la clasificación de *Tetranychus urticae* en hojas de palta utilizando una red neuronal convolucional ResNet-50.

B. Recolección y preprocesamiento del conjunto de datos

Se desarrolló un conjunto de datos propio de 900 imágenes utilizando una cámara Sony Cyber-shot DSC-HX400V bajo condiciones de iluminación controlada. Las imágenes fueron tomadas en Canta, Lima, y se clasificaron en dos clases balanceadas: 450 imágenes de hojas sanas y 450 imágenes de hojas infestadas con *Tetranychus urticae*. Las hojas se recolectaron en tres tipos de terreno (plano, semi-

plano y campo abierto), representando así diversos entornos agrícolas. Esta práctica sigue lo propuesto en estudios similares sobre clasificación de plagas y enfermedades en palta, donde se prioriza la estandarización de iluminación para reducir el ruido visual [14].

El proceso de etiquetado fue manual y validado por dos agrónomos, quienes confirmaron la presencia de la plaga mediante el uso de una lupa. Esta validación experta garantizó la consistencia de los datos y redujo el sesgo en la clasificación. El conjunto de datos se dividió utilizando una estrategia holdout, en 70% para entrenamiento (630 imágenes), 15% para validación (135 imágenes) y 15% para prueba (135 imágenes).

Todas las imágenes fueron redimensionadas a 224×224 píxeles y normalizadas al rango [0,1]. El aumento de datos (data augmentation) incluyó volteo horizontal, rotaciones de $\pm 10^\circ$ y variación de brillo de $\pm 20\%$ para mejorar la capacidad de generalización del modelo.

Una contribución distintiva de este trabajo es la creación de este conjunto de datos original, diseñado específicamente para la detección de *T. urticae* en hojas de palta Hass cultivadas en Perú. Hasta donde se tiene conocimiento, no existe un conjunto de datos público disponible para esta plaga en este cultivo. Este dataset constituye un recurso valioso para el avance de las aplicaciones de visión por computadora en agricultura de precisión, especialmente en el contexto de la producción peruana de palta. Un subconjunto del conjunto de datos estará disponible previa solicitud para apoyar la reproducibilidad y futuras investigaciones.

C. Arquitectura del modelo

La elección del modelo ResNet-50 se justifica por su capacidad de aprendizaje profundo mediante bloques residuales, los cuales mejoran la estabilidad del entrenamiento y la propagación del gradiente [15]. El modelo está basado en la arquitectura de red neuronal convolucional ResNet-50, la cual emplea bloques residuales para facilitar el entrenamiento en redes profundas. Se implementó aprendizaje por transferencia (transfer learning) utilizando pesos preentrenados de ImageNet.

Para optimizar el entrenamiento con un conjunto de datos limitado, se congelaron las capas iniciales del modelo, preservando las características generales aprendidas en grandes volúmenes de datos. Se descongelaron las últimas seis capas, como se muestra en la Fig. 2, permitiendo que el modelo se especialice en detectar patrones de infestación relevantes para la tarea.

Este enfoque mejoró el rendimiento al mismo tiempo que minimizó el sobreajuste (overfitting). La arquitectura final incluye una capa de global average pooling y una capa densa de salida con activación softmax para realizar una clasificación binaria.

```
# Descongelamos las últimas 6 capas
for layer in modelo_RN50.layers[::-6]:
    layer.trainable = False
```

Fig. 2 Código en Python para congelar todas las capas excepto las últimas seis en ResNet-50 durante el ajuste fino (fine-tuning).

D. Procedimiento de entrenamiento

El entrenamiento se realizó durante 20 épocas, con un tamaño de lote (batch size) de 32, utilizando entropía cruzada categórica como función de pérdida. Se evaluaron dos optimizadores: Adam y Adadelata.

Inicialmente, el modelo mostró signos de sobreajuste (overfitting) al utilizar Adam, evidenciado por una alta precisión en entrenamiento y un menor desempeño en validación después de la época 12. Para mitigar este problema, se implementaron ajustes en los hiperparámetros: se redujo el número de épocas para evitar un sobreentrenamiento excesivo, y se descongelaron únicamente las últimas seis capas de la red preentrenada ResNet-50, permitiendo que estas capas aprendan características específicas de la tarea, mientras se conservaban las características generales previamente aprendidas en ImageNet.

Además, se seleccionó Adadelata como optimizador final, ya que logró una mejor generalización, con un aumento de aproximadamente 2.1% en la precisión de validación en comparación con Adam.

El proceso de ajuste de hiperparámetros se ilustra en la Fig. 3, donde Adadelata muestra una mejor alineación entre el rendimiento en entrenamiento y validación, una reducción del sobreajuste y curvas de pérdida más estables.

El rendimiento del modelo fue evaluado mediante métricas como precisión (accuracy), precisión positiva (precision), recall, F1-score, matriz de confusión, curva ROC-AUC y curva precisión-recall, con el fin de proporcionar una evaluación integral de la efectividad del sistema de clasificación.




Fig. 3 Curvas de precisión y pérdida en entrenamiento y validación para Adam (arriba) y Adadelata (abajo).

III. RESULTADOS Y DISCUSIONES

El desempeño del modelo ResNet-50 fue evaluado utilizando un conjunto de prueba compuesto por 135 imágenes. El modelo alcanzó una precisión (accuracy) del 96.0%, un recall del 97.96% y un F1-score de 97.96%, como se resume en la Tabla 1. Estas métricas reflejan un clasificador altamente eficaz para la detección de *Tetranychus urticae* en hojas de palta.

TABLA I.
MÉTRICAS DE DESEMPEÑO DEL MODELO RESNET-50 EN EL CONJUNTO DE DATOS DE PRUEBA.

Metric	Value
Accuracy	96.00%
Recall	97.96%
F1-Score	97.96%

Como se observa en la Fig. 4, el modelo mantuvo una pérdida y precisión estables durante el entrenamiento y la validación a lo largo de las 20 épocas, lo que indica una convergencia sin sobreajuste.




Fig. 4 Pérdida y precisión en entrenamiento y validación durante 20 épocas.

La matriz de confusión mostrada en la Fig. 5 revela solo un falso positivo y un falso negativo, lo que demuestra la robustez del modelo en una clasificación binaria bajo condiciones controladas.

Un análisis más detallado de estas clasificaciones erróneas sugiere que el falso positivo probablemente se debió a una hoja sana con manchas naturales o sombras que simulan daños causados por ácaros. El falso negativo pudo haberse producido por la presencia de síntomas visuales mínimos o atípicos de infestación, lo que dificultó su detección por parte del modelo. Estos casos resaltan la importancia de enriquecer el conjunto de datos con ejemplos más complejos y de explorar estrategias de aumento de datos específicas, para mejorar la resiliencia del modelo frente a condiciones límite.




Fig. 5 Matriz de confusión del desempeño de clasificación del modelo ResNet-50.

Además de las métricas de precisión, recall y F1-score, se calcularon la especificidad (98.52%) y el área bajo la curva ROC (AUC = 1.00), que confirman la capacidad del modelo para discriminar entre hojas sanas e infestadas en distintos umbrales de decisión. También se evaluó el tiempo promedio de inferencia, resultando en 28 ms por imagen en GPU NVIDIA Tesla T4, lo cual demuestra la factibilidad de implementar el modelo en aplicaciones cercanas al tiempo real. Estas métricas adicionales refuerzan la robustez y aplicabilidad práctica del sistema.

La curva ROC-AUC en la Fig. 6 y la curva Precisión-Recall en la Fig. 7 confirman aún más el buen comportamiento del clasificador, mostrando alta sensibilidad y especificidad a lo largo de los distintos umbrales.




Fig. 6. Curva ROC-AUC del modelo ResNet-50.




Fig. 7 Curva Precisión-Recall para la clasificación binaria.

El modelo ResNet-50 propuesto alcanzó un accuracy del 96.0% y un recall del 97.96%. Estos resultados son comparables con los reportados por Ferentinos [18], quien alcanzó hasta un 99.5% en distintos cultivos bajo condiciones controladas, y Mohanty et al. [17], quienes reportaron una precisión del 99.3% en 26 enfermedades. Sin embargo, a diferencia de estos enfoques basados en datasets públicos y homogéneos, el presente estudio aporta un dataset original de palta Hass peruana y una validación específica para *Tetranychus urticae*. Asimismo, el rendimiento obtenido supera el reportado por Picon et al. [21] en clasificación de plagas en campo (92%), y es consistente con lo señalado por Too et al. [20], quienes destacaron la superioridad de ResNet frente a otras arquitecturas como VGG y MobileNet en tareas agrícolas. Estos hallazgos muestran que, aunque aún es necesaria una validación en campo, el sistema propuesto presenta un desempeño competitivo y adaptado a la realidad local.

A. Comparación con el estado del arte

La Tabla II presenta una comparación de desempeño entre ResNet-50 y otras arquitecturas de redes neuronales convolucionales evaluadas durante las fases de entrenamiento y validación interna para la detección de plagas, incluyendo VGG-16, VGG-19, MobileNet y un modelo CNN personalizado.

ResNet-50 obtuvo los mayores valores de recall y F1-score durante estas fases, superando a las alternativas bajo condiciones idénticas. Con base en estos experimentos intermedios, se seleccionó una configuración final con 6 capas descongeladas, ya que ofrecía el mejor equilibrio entre generalización y precisión.

El modelo final validado alcanzó una precisión del 96% en el conjunto de prueba, bajo condiciones estándar.

TABLA II.
RESULTADOS OBTENIDOS DURANTE EL ENTRENAMIENTO Y LA VALIDACIÓN INTERNA DE LOS MODELOS CNN

CNN Model	# Epochs	Estimated Accuracy	# Unfrozen Layers	Observation
ResNet-50	60	98%	0	Slight oscillations
ResNet-50	60	95%	1	Slight oscillations
ResNet-50	60	97%	2	Slight oscillations
ResNet-50	15	98%	4	Slight oscillations
VGG-16	15	93%	0	Mild overfitting
VGG-19	15	93%	0	Mild overfitting
Mobile Net	15	90%	0	High overfitting
Custom Model	15	90%	-	Moderate overfitting

Aunque MobileNet logró el tiempo de entrenamiento más corto, sus valores de recall y F1-score fueron significativamente más bajos, además de mostrar una marcada tendencia al sobreajuste de los datos de entrenamiento. VGG-16 y VGG-19 presentaron un leve sobreajuste, probablemente debido a que sus arquitecturas son relativamente más simples en comparación con ResNet-50.

Para brindar una comprensión adicional sobre la dinámica de aprendizaje de estos modelos alternativos, la Fig. 8 presenta las curvas de precisión y pérdida en entrenamiento y validación para MobileNet, el modelo CNN personalizado, VGG-19 y VGG-16. Estas visualizaciones ilustran el grado de sobreajuste exhibido por estas arquitecturas y complementan las métricas cuantitativas proporcionadas en la Tabla II.




Fig. 8 Curvas de precisión y pérdida en entrenamiento y validación para MobileNet, CNN personalizado, VGG-16 y VGG-19.

Estos resultados cuantitativos y visuales confirman que ResNet-50 mantuvo un equilibrio superior entre capacidad de aprendizaje y generalización, lo que justifica su selección como modelo final para esta aplicación.

El desempeño sobresaliente de ResNet-50 puede atribuirse a su arquitectura residual [16], la cual facilita el flujo del gradiente y estabiliza el aprendizaje en redes más profundas. Además, la descongelación selectiva de las últimas seis capas durante el ajuste fino (fine-tuning) permitió que el modelo se adaptara de manera efectiva a la tarea de detección de plagas, minimizando al mismo tiempo el sobreajuste.

Esta combinación de ventajas arquitectónicas y estrategias de ajuste de hiperparámetros posiciona a ResNet-50 como la opción más equilibrada en términos de precisión, robustez y eficiencia computacional dentro del presente estudio.

B. Limitaciones

Si bien el sistema propuesto demuestra un alto rendimiento en condiciones controladas, existen ciertas

limitaciones que restringen su capacidad de generalización inmediata a entornos agrícolas reales.

En primer lugar, toda la recolección de datos se realizó en una estación fotográfica estandarizada, utilizando condiciones uniformes de iluminación y fondo. Si bien esto reduce la variabilidad del conjunto de datos, también puede limitar la capacidad del modelo para manejar condiciones no controladas, típicas del campo, como cambios en la luz natural, sombras, oclusiones, variabilidad en la orientación de las hojas y movimientos inducidos por el viento.

En segundo lugar, aunque el conjunto de datos es balanceado y de autoría propia, su tamaño es modesto para el entrenamiento de modelos de aprendizaje profundo. Aunque el aprendizaje por transferencia ayuda a mitigar parcialmente esta limitación, un conjunto de datos más amplio y diverso probablemente mejoraría la robustez y capacidad de generalización del modelo. Además, el sistema está actualmente diseñado solo para detectar *Tetranychus urticae* y no contempla la presencia simultánea de otras plagas o enfermedades que puedan presentar síntomas visuales similares.

Finalmente, esta prueba de concepto fue validada exclusivamente mediante pruebas offline con imágenes estáticas. La ausencia de validación en campo y de integración con hardware agrícola (por ejemplo, drones, robots o estaciones de monitoreo fijo) significa que aún no se han abordado desafíos prácticos como la latencia en el procesamiento en tiempo real, la conectividad y la fiabilidad operativa.

Estas limitaciones serán el enfoque de trabajos futuros, con el objetivo de transicionar el sistema desde una simulación controlada hacia una herramienta operativa dentro del contexto de la agricultura de precisión.

Además, la capacidad de generalización del modelo puede verse afectada por la variabilidad natural, como cambios en la iluminación, orientación de las hojas, oclusiones y movimiento inducido por el viento. En trabajos futuros se explorarán técnicas avanzadas de aumento de datos (data augmentation) para simular estas condiciones y mejorar la robustez del modelo.

C. Trabajos futuros

Este estudio establece una base sólida para la detección automatizada de *Tetranychus urticae* en hojas de palta Hass, utilizando una red neuronal convolucional ResNet-50. Para avanzar más allá de la prueba de concepto y aproximarse a una implementación práctica, los trabajos futuros se centrarán en los siguientes aspectos clave:

1. Plan de implementación en campo

Se ha planificado una fase integral de validación en campo para la temporada agrícola 2025–2026, con el fin de evaluar el desempeño del modelo en condiciones agrícolas reales. Las pruebas se llevarán a cabo en campos comerciales de palta ubicados en Canta y Huaral, Perú.

Las imágenes serán capturadas in situ, sin iluminación ni fondo controlado, lo que introducirá variabilidad natural en la iluminación, orientación de las hojas, oclusiones y factores ambientales como el viento y el polvo. El objetivo es alcanzar niveles de precisión superiores al 90% bajo estas condiciones. Se utilizarán las mismas métricas de evaluación aplicadas en el estudio controlado —precisión (accuracy), recall, precisión (precision), F1-score, matriz de confusión, ROC-AUC y curva Precisión-Recall— para permitir una comparación directa. Además, se explorarán pruebas de procesamiento en tiempo real mediante el uso de dispositivos móviles o drones, con el fin de evaluar la latencia y usabilidad del sistema.

2. Ampliación del conjunto de datos

Se ampliará el conjunto de datos propietario para incluir imágenes de múltiples temporadas, diferentes etapas de crecimiento foliar, así como otras plagas o enfermedades que puedan presentar síntomas visuales similares. Esto contribuirá a mejorar la robustez y capacidad de generalización del modelo, habilitando una clasificación multiclase y una mayor aplicabilidad en la agricultura de precisión.

3. Integración con sistemas móviles y de agricultura de precisión

Se desarrollará la integración del sistema con plataformas móviles, como drones o dispositivos portátiles, para permitir una detección de plagas en tiempo real y directamente en campo. Además, el sistema de visión será vinculado con componentes de agricultura de precisión, como sistemas automatizados de fumigación o plataformas de alerta, para facilitar intervenciones oportunas y focalizadas en el control de plagas.

Esta integración tiene como objetivo reducir el uso de pesticidas y fomentar prácticas agrícolas sostenibles.

4. Diseño preliminar del sistema para implementación

Para cerrar la brecha entre la prueba de concepto y un sistema completamente operativo, se propone un diseño preliminar de integración. El sistema proyectado combinará el clasificador basado en ResNet-50 con plataformas móviles de adquisición de datos, como drones, dispositivos portátiles o estaciones de monitoreo fijo equipadas con cámaras de alta resolución.

Las imágenes capturadas serán procesadas localmente o mediante unidades de cómputo perimetral (edge computing), lo que permitirá una clasificación casi en tiempo real. El sistema incluirá una interfaz de comunicación para transmitir los resultados de detección hacia plataformas de gestión agrícola o fumigadoras automatizadas, permitiendo así intervenciones focalizadas y eficientes.

La Fig. 9 ilustra la arquitectura conceptual de este sistema integrado. Este diseño busca ofrecer una solución escalable que respalde el manejo sostenible y preciso de plagas en la producción comercial de palta.




Fig. 9 Diagrama conceptual del sistema de visión integrado.

V. CONCLUSIONES

Este trabajo presenta el diseño e implementación de un sistema inteligente de detección basado en visión artificial para *tetranychus urticae* en hojas de palta, utilizando una red neuronal convolucional resnet-50. la solución propuesta automatiza con éxito la identificación de plagas en condiciones controladas, combinando aprendizaje por transferencia (transfer learning), curaduría del conjunto de datos y una arquitectura de modelo ajustada finamente.

El modelo alcanzó una precisión (accuracy) del 96.0%, un recall del 97.96% y un f1-score del 97.96%, superando a otros modelos CNN como mobilenet, vgg-16 y vgg-19. herramientas de visualización como la matriz de confusión, la curva roc-auc y la curva precisión-recall confirmaron la robustez del sistema y su capacidad discriminativa.

Los resultados demuestran la viabilidad de integrar visión por computadora y aprendizaje profundo en la agricultura de precisión. si bien el sistema establece una base sólida para su implementación en entornos reales, su alcance actual está limitado a una sola especie de plaga y ha sido validado únicamente en condiciones controladas.

Los trabajos futuros se centrarán en la ampliación del conjunto de datos, el abordaje de la variabilidad ambiental y la validación en campo, con el fin de permitir un soporte práctico en la toma de decisiones en tiempo real para los agricultores.

Al habilitar la detección temprana de plagas, el sistema propuesto ofrece beneficios potenciales para la producción comercial de palta, incluyendo la reducción en el uso de pesticidas, mejora en la calidad del fruto y optimización del trabajo agrícola, lo que contribuye a prácticas agrícolas más sostenibles y rentables. estos resultados posicionan al sistema como una herramienta prometedora para fortalecer la competitividad agrícola del Perú en los mercados internacionales.

Por lo tanto, este estudio debe entenderse como una prueba de concepto validada: demuestra la viabilidad técnica del enfoque propuesto en condiciones controladas, pero requiere de trabajo adicional para lograr una implementación práctica en entornos agrícolas reales. Esto incluye abordar la variabilidad en la iluminación, la orientación de las hojas y las condiciones del campo, así como la integración del sistema en plataformas de agricultura de precisión para el manejo de plagas en tiempo real.

REFERENCES

- [1] Ministerio de Agricultura y Riego del Perú, Exportaciones de palta Hass en el Perú: Situación actual y perspectivas, Dirección de Estudios Económicos, Lima, Perú, 2023.
- [2] Servicio Nacional de Sanidad Agraria del Perú (SENASA), "Informe anual de exportaciones agrícolas 2023 – Palta Hass," Ministerio de Desarrollo Agrario y Riego, Lima, Perú, 2024.
- [3] Agraria.pe, "Ácaro genera serios daños a los cultivos," Agraria.pe, 2023. [En línea]. Disponible en: <https://agraria.pe>.
- [4] G. Apaza et al., Monitoreo y control de Tetranychus urticae en palto Hass en zonas productoras del Perú, Universidad Privada del Norte, 2023.
- [5] E. Castillo, J. Sánchez y A. Vargas, "Detección de plagas en cultivos mediante visión artificial y redes neuronales," Revista Científica AgroSoft, vol. 9, no. 1, pp. 35–42, 2020.
- [6] Y. LeCun, Y. Bengio y G. Hinton, "Deep learning," Nature, vol. 521, no. 7553, pp. 436–444, mayo 2015.
- [7] A. Flores, M. Ramírez y R. Gómez, "Aplicación de aprendizaje profundo para la clasificación de frutas mediante visión artificial," Revista de Ciencia y Tecnología Agropecuaria, vol. 17, no. 2, pp. 48–56, 2022.
- [8] S. Nakamura y L. Zhang, "Hyperspectral imaging and deep learning for fruit disease classification," Computers and Electronics in Agriculture, vol. 175, pp. 105–118, 2020.
- [9] H. Nishiyama, Y. Okamoto, and T. Yamaguchi, "Non-destructive detection of internal defects in avocado using hyperspectral imaging and deep learning," Computers and Electronics in Agriculture, vol. 145, pp. 22–30, 2018.
- [10] L. D. Salinas and A. Mejía, "Análisis hiperespectral para la detección de madurez y enfermedades en palta," Revista de Tecnología Agroindustrial, vol. 12, no. 2, pp. 47–54, 2022.
- [11] M. Quispe et al., "Uso de descriptores de color y texturas en la clasificación automática de frutos tropicales," Congreso Nacional de Ingeniería Electrónica, Lima, Perú, 2021.
- [12] VDI-Richtlinie 2206, Entwicklungsmethodik für mechatronische Systeme, Verein Deutscher Ingenieure (VDI), Düsseldorf, Alemania, 2004.
- [13] I.F. Chollet, Deep Learning with Python, 2nd ed., Shelter Island, NY: Manning Publications, 2021.
- [14] C. Llanto and R. Capcha, "Taller de investigación: Detección inteligente de Tetranychus urticae en hojas de palta Hass usando visión por computadora," Universidad Privada del Norte, 2024.
- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770–778.
- [16] K. He, X. Zhang, S. Ren y J. Sun, "Deep residual learning for image recognition," in Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 770–778.
- [17] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," Frontiers in Plant Science, vol. 7, p. 1419, 2016.
- [18] K. P. Ferentinos, "Deep learning models for plant disease detection and diagnosis," Computers and Electronics in Agriculture, vol. 145, pp. 311–318, 2018.
- [19] J. G. A. Barbedo, "Plant disease identification from individual lesions and spots using deep learning," Computers and Electronics in Agriculture, vol. 153, pp. 150–157, 2018.
- [20] E. C. Too, L. Yujian, S. Njuki, and L. Yingchun, "A comparative study of fine-tuning deep learning models for plant disease identification," Computers and Electronics in Agriculture, vol. 161, pp. 272–279, 2019.
- [21] A. Picon, A. Alvarez-Gila, M. Seitz, A. Ortiz-Barredo, J. Echazarra, and A. Johannes, "Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild," Computers and Electronics in Agriculture, vol. 161, pp. 280–290, 2019.