



Artículo original / Original article

Clasificación de imágenes de manchas marrones en cacao mediante visión artificial y transferencia de conocimiento en la región de San Martín

Classification of brown spot images in cocoa using artificial vision and knowledge transfer in the San Martín Region

Aldahir Eduardo Altamirano-Reategui ^{1*}; Cristian Werner García-Estrella ¹; Jhosep Sánchez-Flores ¹

¹ Universidad Nacional de San Martín, Tarapoto, Perú

Recibido: 06/04/2026

Aceptado: 28/06/2026

Publicado: 25/07/2026

*Autor de correspondencia: alaltamiranor@alumno.unsm.edu.pe

Resumen: La mancha parda afecta la productividad y calidad del cacao, generando pérdidas económicas en la región San Martín. El estudio tuvo como objetivo diseñar un sistema para clasificar imágenes de frutos de cacao afectados por esta enfermedad mediante visión artificial y transferencia de aprendizaje en condiciones reales de campo. La investigación se desarrolló en Chazuta durante 2024. Se recopilieron 3.003 imágenes de frutos sanos y enfermos, segmentadas mediante Mask R-CNN y sometidas a aumento de datos, obteniéndose 12.012 imágenes. Se evaluaron las arquitecturas preentrenadas VGG16, ResNet50 y MobileNetV2 como extractores de características, combinadas con máquinas de vectores de soporte (SVM). El desempeño se evaluó mediante validación cruzada y análisis estadísticos con las pruebas de Levene, ANOVA y Tukey. Todos los modelos superaron el 98,6 % de precisión; VGG16 + SVM alcanzó el mejor desempeño, con una precisión promedio del 99,51 % y diferencias estadísticamente significativas frente a los demás modelos. Se concluye que el enfoque híbrido basado en extracción profunda de características y clasificación mediante SVM es eficaz para detectar automáticamente la mancha parda del cacao y presenta potencial de aplicación en agricultura de precisión.

Palabras clave: aprendizaje profundo; clasificación binaria; fitopatología digital; redes neuronales convolucionales; visión por computadora

Abstract: Brown spot disease affects cocoa productivity and fruit quality, causing economic losses in the San Martín region. This study aimed to design a system for classifying images of cocoa fruits affected by this disease using computer vision and transfer learning under real field conditions. The research was conducted in Chazuta during 2024. A total of 3,003 images of healthy and diseased fruits were collected, segmented using Mask R-CNN, and subjected to data augmentation, resulting in a final dataset of 12,012 images. The pretrained VGG16, ResNet50, and MobileNetV2 architectures were evaluated as feature extractors and combined with support vector machines (SVM) for classification. Performance was assessed using cross-validation and statistical analyses, including Levene's test, one-way ANOVA, and Tukey's test. All models achieved accuracy above 98.6%; VGG16 + SVM showed the best performance, with a mean accuracy of 99.51% and statistically significant differences compared with the other models. The study concludes that the hybrid approach combining deep feature extraction and SVM classification is effective for automated cocoa brown spot detection and has potential applications in precision agriculture.

Keywords: binary classification; computer vision; convolutional neural networks; deep learning; digital phytopathology

1. Introducción

El cacao constituye uno de los cultivos de mayor relevancia económica y social en América Latina (Cortez et al., 2024), debido a su aporte al desarrollo rural y al incremento sostenido de la demanda de productos derivados en los mercados internacionales (Becerra et al., 2024; Vargas Ramírez, 2023). En el Perú, este cultivo ha adquirido una posición estratégica dentro del sector agrícola (Delgado et al., 2023), destacando la región San Martín como una de las principales zonas productoras del país (Ministerio de Desarrollo Agrario y Riego [MIDAGRI], 2023). Esta región cuenta con condiciones favorables para el desarrollo de la actividad cacaotera (Rios-Jara & Lévano-Rodríguez, 2022), factores que han favorecido el desarrollo de la producción y transformación del cacao en el ámbito regional (Tello Púa & Flores Ramírez, 2022). Sin embargo, la productividad del cultivo se encuentra amenazada por enfermedades fitosanitarias asociadas a *Phytophthora palmivora* (Araujo Horna, 2023; Muzuni et al., 2023).

La mancha parda afecta directamente a los frutos de cacao y puede comprometer su estado fitosanitario y calidad productiva (Arham et al., 2024; Rojas Castillo, 2024; Sunaryanto et al., 2024). Su identificación ha dependido tradicionalmente de la evaluación visual de las características del fruto; sin embargo, actualmente se han desarrollado métodos de análisis de imágenes para apoyar su clasificación (Ayikpa et al., 2023; Nyarko, 2024). Estos procedimientos pueden verse afectados por las características visuales consideradas durante la clasificación y por las condiciones de adquisición de las imágenes (Eric et al., 2023; Nyarko, 2024). Asimismo, el fortalecimiento de la cadena productiva del cacao requiere incorporar herramientas que contribuyan a mejorar sus procesos de gestión y competitividad (Philips Paredes, 2022; Rodríguez Delzo et al., 2023). En este sentido, las tecnologías basadas en inteligencia artificial constituyen una alternativa para reducir limitaciones de información y apoyar la toma de decisiones de los productores (De la Peña & Granados, 2023).

En este contexto, la inteligencia artificial y la visión por computadora han emergido como alternativas tecnológicas con potencial para automatizar el análisis de imágenes agrícolas (Jesse et al., 2024; Javaid et al., 2023; Kouassi et al., 2024; Villalobos-Culqui et al., 2025). En particular, los modelos de aprendizaje profundo permiten extraer características visuales complejas y desarrollar soluciones aplicables al sector agrícola (Albaaji & S.S., 2023; Figiel, 2022). No obstante, la detección automatizada de enfermedades del cacao continúa enfrentando desafíos relacionados con la adquisición de imágenes, las condiciones de campo y la capacidad de generalización de los modelos (Lomotey et al., 2024; Soh et al., 2024).

La presente investigación propone un sistema de clasificación automática de imágenes de frutos de cacao afectados por mancha parda, utilizando arquitecturas de transferencia de conocimiento como ResNet-50 (Lopes et al., 2022), VGG16 (Raut et al., 2024) y MobileNetV2 como extractores de características, en combinación con un clasificador basado en máquinas de vectores de soporte (SVM). Para ello, se construyó un conjunto de datos conformado por 3.003 imágenes recolectadas en la región San Martín y etiquetadas por especialistas en agronomía. Esta estrategia permitió aprovechar el conocimiento previamente aprendido mediante modelos preentrenados y transferirlo al contexto específico de la clasificación de frutos de cacao.

El objetivo del estudio fue diseñar y evaluar un sistema de clasificación de imágenes de frutos de cacao afectados por mancha parda en la región San Martín mediante técnicas de visión artificial con transferencia de conocimiento. Los modelos fueron evaluados mediante métricas de clasificación y procedimientos estadísticos con el propósito de determinar comparativamente su desempeño.

2. Materiales y métodos

La aplicación de técnicas de inteligencia artificial y visión por computadora ha mostrado resultados prometedores en la automatización de tareas de inspección y clasificación en productos agrícolas, particularmente en el cultivo de cacao. Diversos estudios han demostrado

que los modelos de aprendizaje profundo con transferencia de conocimiento permiten extraer características visuales discriminativas y alcanzar altos niveles de precisión incluso con conjuntos de datos de tamaño moderado.

En el ámbito específico del cacao, Villamonte et al. (2021) desarrollaron un modelo basado en la arquitectura VGG16 con transferencia de conocimiento para la clasificación automática de defectos en granos de cacao. El estudio consideró siete categorías de defectos y empleó imágenes capturadas en un entorno controlado con iluminación LED. El modelo fue entrenado con el optimizador Adam y la función de pérdida categorica crossentropy, alcanzando una precisión de 95,33 % durante el entrenamiento y 97,29 % en pruebas con muestras reales. Estos resultados evidenciaron el potencial de las arquitecturas preentrenadas para mejorar el control de calidad en productos derivados del cacao.

De manera similar, Taspinar et al. (2022) aplicaron técnicas de transferencia de conocimiento para clasificar 14 tipos de frijoles haricot utilizando un conjunto de 33.064 imágenes. Se evaluaron las arquitecturas InceptionV3, VGG16 y VGG19, cuyos resultados fueron posteriormente combinados con clasificadores tradicionales como Support Vector Machine y regresión logística. Esta estrategia permitió mejorar el desempeño de clasificación y evidenció la utilidad de integrar extractores profundos con clasificadores convencionales en aplicaciones agrícolas.

En relación con la detección de enfermedades en frutos de cacao, Cano Ortega y Pineda Molina (2023) propusieron un sistema inteligente basado en redes neuronales profundas y transferencia de conocimiento para identificar enfermedades como moniliasis, mazorca negra y Lasiodiplodia. El sistema fue desplegado en Google Cloud mediante contenedores Docker e integrado con una aplicación móvil desarrollada en Android Studio, alcanzando una eficacia superior al 91 %. De manera complementaria, Buenaño Vera et al. (2024) emplearon la arquitectura EfficientDet-Lite4 para identificar monilia y vaina negra en frutos de cacao, orientando su implementación hacia aplicaciones móviles para apoyar el diagnóstico en campo.

A nivel general, Shafik et al. (2024) propusieron modelos de clasificación de enfermedades vegetales basados en transferencia de aprendizaje y redes neuronales convolucionales preentrenadas. Los resultados mostraron un desempeño elevado en la clasificación de enfermedades de plantas, respaldando el uso de arquitecturas profundas y estrategias de transferencia de conocimiento para mejorar la robustez de los sistemas automatizados de diagnóstico.

Finalmente, Anduyan et al. (2025) desarrollaron un enfoque basado en transferencia de aprendizaje y métodos de ensamblaje para mejorar la clasificación de enfermedades en frutos de cacao. El estudio evidenció el potencial de combinar arquitecturas profundas y estrategias de ensamblaje para obtener modelos de clasificación más robustos y aplicables al diagnóstico automatizado de enfermedades del cacao.

En conjunto, los estudios revisados evidencian que la transferencia de conocimiento y los modelos híbridos basados en redes neuronales convolucionales constituyen estrategias prometedoras para la clasificación de enfermedades y defectos en productos agrícolas. Sin embargo, persisten desafíos relacionados con la disponibilidad de conjuntos de datos locales, la variabilidad de las condiciones de captura y la evaluación comparativa de diferentes arquitecturas en escenarios reales de campo. En este contexto, la presente investigación contribuye mediante la construcción de un conjunto de datos de frutos de cacao recolectados en la región San Martín y la evaluación sistemática de las arquitecturas ResNet-50, VGG16 y MobileNetV2, combinadas con Support Vector Machine, para la clasificación automática de frutos sanos y afectados por mancha parda.

3. Materiales y métodos

3.1. Ámbito y condiciones de la investigación

La presente investigación se desarrolló en el distrito de Chazuta, ubicado en la provincia de San Martín, en el nororiente peruano. Este distrito se localiza aproximadamente a 28 km al sur de la ciudad de Tarapoto y presenta un clima tropical cálido y húmedo, condiciones favorables para el cultivo del cacao, pero también propicias para el desarrollo de enfermedades fitosanitarias como la mancha parda. La zona de estudio se encuentra a una altitud que oscila entre 189 y 260 m s. n. m. La Figura 1 muestra la ubicación geopolítica y satelital del área de estudio.

3.2. Diseño de la investigación

La investigación fue de tipo aplicada y de nivel experimental, orientada al diseño y evaluación de un sistema de visión artificial para la clasificación automática de imágenes de frutos de cacao. La variable independiente estuvo constituida por los modelos de transferencia de conocimiento empleados para la extracción de características, mientras que la variable dependiente correspondió a la presencia o ausencia de mancha parda en los frutos de cacao. Este enfoque ha sido utilizado en estudios relacionados con la clasificación automatizada de imágenes de cacao y la detección de enfermedades mediante modelos de aprendizaje profundo (Ariawan et al., 2025; Lopes et al., 2022; Sudjud et al., 2025).

Adicionalmente, se controlaron variables secundarias como las condiciones ambientales durante la captura de imágenes, el ángulo de toma, la posición del fruto, el fondo de la imagen, el dispositivo de captura y el etiquetado realizado por un especialista en agronomía, con el fin de garantizar consistencia y confiabilidad en los resultados.

3.3. Población y muestra

La muestra estuvo conformada por 3003 imágenes de frutos de cacao recolectadas en parcelas productoras de la región San Martín. Las imágenes incluyeron frutos sanos y afectados por mancha parda, considerando diferentes grados de madurez e infección. Cada imagen fue revisada y etiquetada por un especialista en agronomía, quien asignó una de las dos clases correspondientes: sano o enfermo.

Con el propósito de mejorar la capacidad de generalización de los modelos, se aplicaron técnicas de aumento de datos sobre las imágenes segmentadas, incrementando la diversidad del conjunto de entrenamiento mediante transformaciones geométricas y fotométricas [55].

3.4. Objetivo específico 1: Construcción del conjunto de datos

El primer objetivo consistió en crear un conjunto de imágenes de frutos de cacao afectados por mancha parda, etiquetadas por profesionales del área agronómica. El proceso se dividió en tres etapas principales: recolección de imágenes, etiquetado y almacenamiento, tal como se muestra en la Figura 1.




Figura 1. Modelo conceptual del objetivo específico 1

3.4.1. Recolección de imágenes

Antes de iniciar el trabajo de campo, se gestionó la autorización de ingreso a las parcelas mediante la firma de consentimientos informados por parte de los propietarios (Mduma & Laizer, 2023). Posteriormente, las visitas se realizaron con el acompañamiento de un especialista en agronomía, quien facilitó la identificación de frutos representativos para cada clase (Christakakis et al., 2024). Las imágenes fueron capturadas utilizando un Samsung Galaxy A22 bajo condiciones reales de iluminación natural y diferentes estados climáticos (Yang et al., 2022).

3.4.2. Etiquetado de imágenes

Las imágenes recolectadas fueron revisadas manualmente por un especialista en agronomía, quien asignó las etiquetas “sano” o “enfermo” según el estado fitosanitario observado en cada fruto (Rola et al., 2024). Este procedimiento permitió establecer las clases utilizadas posteriormente en el proceso de clasificación.

3.4.3. Almacenamiento del conjunto de datos

Las imágenes fueron organizadas inicialmente en una Lenovo Legion 5 equipada con procesador Intel Core i7, 16 GB de memoria RAM y una GPU NVIDIA RTX 2060. Posteriormente, el conjunto de datos fue almacenado en Google Drive, organizado en carpetas independientes de acuerdo con las clases definidas. Las prácticas de preservación y gestión de datos digitales favorecen su organización, disponibilidad y reutilización durante los procesos de investigación (Mwinami et al., 2024; Oh, 2024).

3.5. Objetivo específico 2: Diseño de los modelos de clasificación

El segundo objetivo consistió en diseñar modelos con transferencia de conocimiento para la extracción de características y la clasificación de imágenes de frutos de cacao afectados por mancha parda. El proceso incluyó seis etapas: configuración del entorno, segmentación de imágenes, aumento de datos, extracción de características, clasificación con SVM y visualización de resultados, como se muestra en la Figura 2.




Figura 2. Modelo conceptual del objetivo específico 2

3.5.1. Configuración del entorno de trabajo

Los experimentos fueron desarrollados en Google Colab, donde se configuraron las librerías necesarias para el procesamiento de imágenes, aprendizaje profundo, análisis estadístico y visualización. El uso de entornos computacionales para el procesamiento de imágenes constituye un componente relevante en aplicaciones de agricultura inteligente (Marković et al., 2024).

Asimismo, se definieron parámetros generales como el tamaño de entrada de las imágenes, las clases de salida y la configuración del proceso de validación (Pei et al., 2025).

3.5.2. Segmentación de imágenes

Se utilizó Mask R-CNN para eliminar automáticamente el fondo de las imágenes y aislar únicamente la región correspondiente al fruto. Esta arquitectura permite realizar tareas de detección y segmentación de instancias en imágenes agrícolas (Huang et al., 2024). La máscara generada fue refinada y aplicada sobre la imagen original, produciendo imágenes segmentadas con fondo negro uniforme.

3.5.3. Aumento de datos

Se aplicaron transformaciones de volteo horizontal, volteo vertical y ajustes de brillo para incrementar la diversidad visual del conjunto de datos. Estas técnicas de aumento de datos permiten generar variaciones de las imágenes originales y pueden contribuir a mejorar la capacidad de generalización de los modelos de clasificación (Alomar et al., 2023).

3.5.4. Extracción de características

Se emplearon tres arquitecturas preentrenadas como extractores de características: ResNet-50, VGG16 y MobileNetV2, siguiendo enfoques de aprendizaje profundo y transferencia de conocimiento utilizados en aplicaciones agrícolas (J. et al., 2022; Al Sahili & Awad, 2022). Las capas convolucionales se mantuvieron congeladas para preservar las representaciones previamente aprendidas, y las características extraídas fueron utilizadas posteriormente como entrada para el clasificador SVM, siguiendo un enfoque híbrido de extracción profunda de características y clasificación mediante máquinas de vectores de soporte (Sonmez et al., 2024).

3.5.5. Clasificación con Support Vector Machine

Los vectores de características fueron clasificados mediante un modelo Support Vector Machine (SVM). La optimización de los hiperparámetros se realizó utilizando RandomizedSearchCV, explorando diferentes valores del parámetro de regularización C, el tipo de kernel y el parámetro gamma, como parte del proceso de optimización del clasificador (Khan et al., 2024). El rendimiento se estimó mediante validación cruzada de cinco pliegues ($k = 5$), procedimiento utilizado para obtener estimaciones más robustas del desempeño de modelos de aprendizaje automático (Malakouti et al., 2023). Los resultados obtenidos en cada partición fueron almacenados para su posterior análisis comparativo (Lumumba et al., 2024).

3.5.6. Visualización de resultados

Para cada modelo se generaron matrices de confusión, curvas ROC y representaciones gráficas de las métricas obtenidas durante el proceso de validación, recursos empleados para evaluar comparativamente el desempeño de modelos de clasificación (Uzer, 2025). Además, se calcularon los valores promedio de accuracy, precisión, recall, F1-score, ROC-AUC y log loss, los cuales fueron organizados y exportados para su posterior análisis estadístico (Martinović et al., 2025).

3.6. Objetivo específico 3: Evaluación del desempeño de los modelos

El tercer objetivo consistió en evaluar comparativamente el desempeño de los modelos propuestos. El proceso incluyó la preparación de un conjunto de prueba independiente, la ejecución de múltiples corridas experimentales y el análisis estadístico de los resultados, tal como se muestra en la Figura 3.




Figura 3. Modelo conceptual del objetivo específico 3

3.6.1. Preparación del conjunto de prueba

Se seleccionaron 1020 imágenes (510 por clase) que no fueron utilizadas durante las etapas de entrenamiento ni validación, con el propósito de disponer de un conjunto independiente para evaluar la capacidad de generalización de los modelos. La utilización de conjuntos de datos independientes constituye un aspecto relevante para evaluar el desempeño de modelos de reconocimiento de enfermedades vegetales (Xu et al., 2024). Las imágenes fueron organizadas en bloques balanceados para realizar múltiples corridas de evaluación y analizar la estabilidad del desempeño.

3.6.2. Evaluación experimental

Cada modelo fue evaluado en 16 corridas independientes, calculando en cada una las métricas de clasificación correspondientes. Los resultados fueron almacenados en archivos Excel para su posterior análisis comparativo.

3.6.3. Análisis estadístico

El desempeño de los modelos fue analizado mediante estadísticos descriptivos, incluyendo la media, desviación estándar, error estándar e intervalos de confianza. Posteriormente, se verificó el supuesto de homogeneidad de varianzas mediante la prueba de Levene. Una vez comprobado este supuesto, se aplicó un análisis de varianza (ANOVA) de una vía para determinar la existencia de diferencias estadísticamente significativas entre el desempeño medio de los modelos. Cuando el ANOVA mostró diferencias significativas ($p < .05$), se utilizó la prueba post hoc de Tukey HSD para efectuar comparaciones múltiples entre pares de modelos. Finalmente, se generaron representaciones gráficas para facilitar la interpretación y comparación de los resultados.

4. Modelos de clasificación y métricas de evaluación

En esta investigación se implementaron tres modelos híbridos de clasificación, conformados por un extractor de características basado en transferencia de conocimiento y un clasificador Support Vector Machine (SVM). Las arquitecturas seleccionadas fueron ResNet-50, VGG16 y MobileNetV2, siguiendo enfoques de transferencia de conocimiento aplicados a la clasificación de imágenes agrícolas (Al Sahili & Awad, 2022; J. et al., 2022). Las capas convolucionales de cada red se mantuvieron congeladas y se utilizaron como extractores de características visuales profundas, cuyas representaciones fueron posteriormente procesadas por el clasificador SVM (Sonmez et al., 2024).

Los vectores de características generados por cada arquitectura fueron utilizados como entrada de un clasificador SVM con estimación de probabilidades habilitada. La selección de los hiperparámetros se realizó mediante RandomizedSearchCV, evaluando diferentes

combinaciones del parámetro de regularización C , el tipo de kernel y el parámetro γ . El ajuste de parámetros constituye un componente relevante para optimizar el desempeño de clasificadores SVM (Khan et al., 2024). Posteriormente, cada modelo fue entrenado y validado mediante validación cruzada de cinco pliegues ($k = 5$), estrategia utilizada para obtener estimaciones más robustas del desempeño y evaluar la capacidad de generalización del modelo (Malakouti et al., 2023).

Las métricas empleadas para evaluar el desempeño de los modelos fueron accuracy, precisión (precision), exhaustividad (recall), F1-score, área bajo la curva ROC (ROC-AUC) y log loss. Estas métricas permiten analizar el desempeño de los modelos desde diferentes perspectivas y complementar la evaluación global de la clasificación (Lumumba et al., 2024; Martinović et al., 2025; Uzer, 2025). El accuracy representa la proporción total de predicciones correctas; la precisión cuantifica la proporción de predicciones positivas que fueron correctamente clasificadas; el recall mide la capacidad del modelo para identificar los casos positivos; y el F1-score corresponde a la media armónica entre precisión y recall. Por su parte, el ROC-AUC evalúa la capacidad discriminativa del modelo a través de diferentes umbrales de decisión, mientras que el log loss cuantifica el error asociado a las probabilidades estimadas, donde valores menores representan un mejor desempeño probabilístico.

Además de la validación cruzada, se reservó un conjunto independiente de 1020 imágenes, distribuido equitativamente entre las dos clases (510 por clase), para realizar una evaluación complementaria mediante corridas experimentales. El empleo de datos independientes del proceso de entrenamiento y validación permite examinar el desempeño de los modelos frente a observaciones no utilizadas durante su construcción (Xu et al., 2024). Los valores de accuracy obtenidos en estas corridas fueron utilizados para efectuar el análisis estadístico comparativo entre los modelos. Se calcularon estadísticos descriptivos y se verificó la homogeneidad de varianzas mediante la prueba de Levene. Posteriormente, se aplicó un análisis de varianza (ANOVA) de una vía y, cuando se identificaron diferencias estadísticamente significativas ($p < .05$), se utilizó la prueba post hoc de Tukey HSD para efectuar las comparaciones múltiples entre pares de modelos.

5. Resultados Experimentales

5.1. Construcción del conjunto de datos

Como resultado del trabajo de campo realizado en parcelas del distrito de Chazuta, se recolectaron 3003 imágenes de frutos de cacao, de las cuales 1501 correspondieron a frutos sanos y 1502 a frutos afectados por mancha parda. Las imágenes fueron capturadas bajo condiciones reales de iluminación y variabilidad ambiental, lo que permitió construir un conjunto de datos representativo del entorno agrícola local. Posteriormente, todas las imágenes fueron revisadas y etiquetadas por un especialista en agronomía, garantizando la confiabilidad del proceso de clasificación.



Figura 4. Resultados de la etapa de etiquetado de imágenes

Después del proceso de segmentación mediante Mask R-CNN (Huang et al., 2024), se eliminó el fondo de cada imagen y se aisló únicamente la región correspondiente al fruto. Sobre el conjunto de imágenes segmentadas se aplicaron técnicas de aumento de datos, incluyendo volteo horizontal, volteo vertical y ajustes de brillo (Alomar et al., 2023). Como resultado, el conjunto de datos se incrementó de 3.003 a 12.012 imágenes, distribuidas en 6.004 imágenes de frutos sanos y 6.008 imágenes de frutos enfermos.

5.2. Desempeño de los modelos híbridos

Los tres modelos híbridos evaluados mostraron un desempeño sobresaliente en la validación cruzada, alcanzando valores superiores al 99 % en todas las métricas principales. La Tabla 1 resume los resultados promedio obtenidos por cada configuración.

Tabla 1. Resumen de las métricas obtenidas en los 3 modelos

Modelo	Accuracy	Precision	Recall	F1-Score	ROC AUC	Log Loss
ResNet50 + SVM	0.992896	0.991117	0.994718	0.992911	0.999667	0.0215594
VGG16 + SVM	0.995811	0.995274	0.996357	0.995812	0.999893	0.0129173
MobileNetV2 + SVM	0.995811	0.99509	0.996539	0.995813	0.999922	0.0108204

El modelo ResNet50 + SVM alcanzó un accuracy promedio de 99.29 %, una precisión de 99.11 %, un recall de 99.47 %, un F1-score de 99.29 %, un ROC-AUC de 0.9997 y un log loss de 0.0216. Por su parte, VGG16 + SVM obtuvo un accuracy de 99.58 %, una precisión de 99.53 %, un recall de 99.64 %, un F1-score de 99.58 %, un ROC-AUC de 0.9999 y un log loss de 0.0129. Finalmente, MobileNetV2 + SVM registró un accuracy de 99.58 %, una precisión de 99.51 %, un recall de 99.66 %, un F1-score de 99.58 %, un ROC-AUC de 0.9999 y el menor log loss (0.0108), lo que indica la mayor certeza probabilística en sus predicciones.

Las matrices de confusión mostraron que todos los modelos cometieron un número mínimo de errores de clasificación, con menos de 50 observaciones mal clasificadas sobre un total superior a 10,900 imágenes evaluadas por validación cruzada. Asimismo, las curvas ROC presentaron valores de AUC prácticamente iguales a 1, confirmando una excelente capacidad para distinguir entre frutos sanos y enfermos.




Figura 5. Matrices de confusión

5.3. Comparación estadística de los modelos

Para evaluar la estabilidad y comparar el rendimiento de los modelos, se realizaron 16 corridas independientes sobre un conjunto de prueba conformado por 1020 imágenes que no fueron utilizadas durante el entrenamiento ni la validación (Xu et al., 2024). Los valores de accuracy obtenidos en cada corrida fueron sometidos posteriormente a un análisis estadístico inferencial para determinar la existencia de diferencias significativas entre los modelos.

Los estadísticos descriptivos mostraron que VGG16 + SVM alcanzó la mayor media de accuracy (0.9951) y la menor desviación estándar (0.0005), lo que evidencia un comportamiento altamente consistente. MobileNetV2 + SVM y ResNet50 + SVM presentaron medias prácticamente idénticas (0.9863), con una variabilidad ligeramente mayor.

Tabla 2. Estadísticos descriptivos obtenidos de los 3 modelos

	N	Media	Desv. Desviación	Desv. Error	95% del intervalo de confianza para la media		Mínimo	Máximo
					Límite inferior	Límite superior		
MobileNetV2 + SVM	16	0.9863	0.0008	0.0002	0.9858	0.9867	0.9854	0.9885
ResNet50 + SVM	16	0.9863	0.0007	0.0002	0.9859	0.9867	0.9854	0.9875
VGG16 + SVM	16	0.9951	0.0005	0.0001	0.9949	0.9954	0.9948	0.9958
Total	48	0.9892	0.0043	0.0006	0.9880	0.9905	0.9854	0.9958

La prueba de Levene indicó que no existieron diferencias significativas en las varianzas entre los modelos ($p = 0.720$), cumpliéndose el supuesto de homogeneidad requerido para aplicar ANOVA. El análisis de varianza de una vía reveló diferencias estadísticamente significativas entre los modelos ($F = 877.118$; $p < 0.001$), lo que confirmó que al menos uno de ellos presentó un desempeño superior.

Tabla 3. Homogeneidad de varianzas obtenidas de los 3 modelos

		Estadístico de Levene	gl1	gl2	Sig.
Accuracy	Se basa en la media	0.330	2	45	0.720
	Se basa en la mediana	0.491	2	45	0.615
	Se basa en la mediana y con gl ajustado	0.491	2	42.546	0.616
	Se basa en la media recortada	0.492	2	45	0.615

La prueba post hoc de Tukey HSD mostró que no existieron diferencias significativas entre MobileNetV2 + SVM y ResNet50 + SVM ($p = 0.9613$). En contraste, VGG16 + SVM presentó diferencias significativas frente a ambos modelos ($p < 0.001$), evidenciando un accuracy superior. Este resultado fue corroborado mediante el análisis de subconjuntos homogéneos, donde VGG16 + SVM conformó un grupo independiente, mientras que MobileNetV2 + SVM y ResNet50 + SVM fueron agrupados en un mismo subconjunto.

Tabla 4. Comparaciones múltiples aplicadas a los 3 modelos

					Intervalo de confianza al 95%	
(I) Identificador		Diferencia de medias (I-J)	Desv. Error	Sig.	Límite inferior	Límite superior
MobileNetV2 + SVM	ResNet50 + SVM	-0.0001	0.0002	0.9613	-0.0007	0.0005
	VGG16 + SVM	-0.0089	0.0002	0.0000	-0.0094	-0.0083
ResNet50 + SVM	MobileNetV2 + SVM	0.0001	0.0002	0.9613	-0.0005	0.0007
	VGG16 + SVM	-0.0088	0.0002	0.0000	-0.0094	-0.0082

VGG16 + SVM	MobileNetV2 + SVM	0.0089	0.0002	0.0000	0.0083	0.0094
	ResNet50 + SVM	0.0088	0.0002	0.0000	0.0082	0.0094




Figura 6. Gráfica comparativa de la media del accuracy de los modelos

Discusión

La transferencia de conocimiento combinada con la clasificación mediante Support Vector Machine (SVM) constituye una estrategia efectiva para la detección automática de mancha parda en frutos de cacao. Las tres configuraciones evaluadas alcanzaron niveles elevados de accuracy; sin embargo, el modelo VGG16 + SVM presentó el mejor desempeño y mostró diferencias estadísticamente significativas frente a ResNet-50 + SVM y MobileNetV2 + SVM. Estos resultados fueron superiores a los reportados por Villamonte et al. (2021), quienes alcanzaron una precisión del 97,29 % mediante VGG16 para la clasificación de defectos en granos de cacao, y por Cano Ortega y Pineda Molina (2023), cuyo sistema de detección de enfermedades en frutos de cacao registró una eficacia superior al 91 %. Asimismo, los resultados son consistentes con la evidencia reciente sobre el potencial de los modelos de transferencia de aprendizaje y ensamblaje para la clasificación de enfermedades del cacao reportada por Anduyan et al. (2025).

El elevado desempeño observado podría estar relacionado con la construcción de un conjunto de datos propio conformado por 3.003 imágenes recolectadas en condiciones reales, el proceso de segmentación automática mediante Mask R-CNN, el aumento de datos y la optimización de los hiperparámetros del clasificador SVM. En conjunto, estos hallazgos respaldan la utilidad del enfoque propuesto para la clasificación automatizada de frutos de cacao y proporcionan una base para su futura evaluación e implementación en aplicaciones móviles o plataformas en la nube orientadas al monitoreo fitosanitario y la agricultura de precisión.

4. Conclusiones

Los resultados obtenidos demuestran que los modelos híbridos basados en transferencia de conocimiento y clasificación mediante Support Vector Machine constituyen una estrategia altamente efectiva para la detección automática de mancha parda en frutos de cacao. Entre las configuraciones evaluadas, el modelo VGG16 + SVM presentó el mejor desempeño, alcanzando una exactitud promedio de 99.51 % y mostrando una superioridad estadísticamente significativa frente a ResNet-50 + SVM y MobileNetV2 + SVM. El alto rendimiento alcanzado se atribuye a la combinación de un conjunto de datos propio de 3003 imágenes recolectadas en condiciones reales en el distrito de Chazuta, el uso de segmentación automática con Mask R-CNN, técnicas de aumento de datos y una validación estadística rigurosa mediante las pruebas de Levene, ANOVA y Tukey HSD. En conjunto, estos hallazgos confirman que es posible alcanzar niveles de precisión

comparables o superiores a los de enfoques más complejos mediante esquemas híbridos simples y robustos. proporcionando una solución replicable y escalable con alto potencial de implementación en aplicaciones móviles o plataformas en la nube para apoyar el monitoreo fitosanitario y la toma de decisiones en la agricultura de precisión.

Financiamiento

Ninguno.

Conflicto de intereses

Los autores declaran no tener ningún conflicto de intereses.

Contribución de autores

Los autores declaran haber realizado todas las etapas de la investigación y redacción del manuscrito.

Referencias bibliográficas

- Al Sahili, Z., & Awad, M. (2022). The power of transfer learning in agricultural applications: AgriNet. *arXiv*. <https://arxiv.org/abs/2207.03881v3>
- Albaaji, G. F., & S.S., V. C. (2023). Artificial intelligence SoS framework for sustainable agricultural production. *Computers and Electronics in Agriculture*, 213, 108182. <https://doi.org/10.1016/j.compag.2023.108182>
- Alomar, K., Aysel, H. I., & Cai, X. (2023). Data augmentation in classification and segmentation: A survey and new strategies. *Journal of Imaging*, 9(2), 46. <https://doi.org/10.3390/jimaging9020046>
- Aly, M., & Behiry, M. H. (2025). Enhancing anomaly detection in IoT-driven factories using Logistic Boosting, Random Forest, and SVM: A comparative machine learning approach. *Scientific Reports*, 15(1), 23694. <https://doi.org/10.1038/s41598-025-08436-x>
- Anduyan, D., Cabillo, N., Gultiano, N., & Pacot, M. P. (2025). Enhancing cocoa pod disease classification via transfer learning and ensemble methods: Toward robust predictive modeling. *arXiv*. <https://arxiv.org/abs/2504.12992>
- Arham, Z., et al. (2024). Green pesticide high activity based on TiO₂ nanosuspension incorporated silver microspheres against *Phytophthora palmivora*. *Indian Journal of Microbiology*. <https://doi.org/10.1007/s12088-024-01239-0>
- Ariawan, K. R., Ekayana, A. A. G., Indrawan, I. P. Y., Winatha, K. R., & Setiawan, I. N. A. F. (2025). Performance comparasion of DenseNet-121 and MobileNetV2 for cacao fruit disease image classification. *Indonesian Journal of Data and Science*, 6(1), 30–38. <https://doi.org/10.56705/ijodas.v6i1.233>
- Araujo Horna, L. J. (2023). *Propagación en cacao (Theobroma cacao L.) en la región San Martín durante los últimos cinco años*. Universidad Nacional de San Martín.

- Ayikpa, K. J., Mamadou, D., Gouton, P., & Adou, K. J. (2023). Classification of cocoa pod maturity using similarity tools on an image database: Comparison of feature extractors and color spaces. *Data*, 8(6), 99. <https://doi.org/10.3390/data8060099>
- Becerra, L. D., Quintanilla-Carvajal, M. X., Escobar, S., & Ruiz, R. Y. (2023). Correlation between color parameters and bioactive compound content during cocoa seed transformation under controlled process conditions. *Food Bioscience*, 53, 102526. <https://doi.org/10.1016/j.fbio.2023.102526>
- Becerra, L. D., Quintanilla-Carvajal, M. X., Escobar, S., & Ruiz Pardo, R. Y. (2024). From controlled transformed cocoa beans to chocolate: Bioactive properties, metabolomic profile, and in vitro bioaccessibility. *Food Chemistry*, 433, 137321. <https://doi.org/10.1016/j.foodchem.2023.137321>
- Borromeo, K. O., Bonotan, M. R., Llagas, A. P., Juan, J. M. O., Sanchez, P. D. C., & Berro, N. K. A. (2025). Classification of cacao pods ripeness using convolutional neural networks. *Procedia Computer Science*, 257, 1197–1204. <https://doi.org/10.1016/j.procs.2025.03.160>
- Buenaño Vera, D., Oviedo, B., Chiriboga Casanova, W., & Zambrano-Vega, C. (2024). Deep learning-based computational model for disease identification in cocoa pods (*Theobroma cacao* L.). *arXiv*. <https://doi.org/10.48550/arXiv.2401.01247>
- Cano Ortega, C., & Pineda Molina, J. (2023). *Development of a mobile application for the detection of diseases in cocoa fruits*. <http://hdl.handle.net/10554/65284>
- Christakakis, P., et al. (2024). Smartphone-based citizen science tool for plant disease and insect pest detection using artificial intelligence. *Technologies*, 12(7), 101. <https://doi.org/10.3390/technologies12070101>
- Cortez, D., et al. (2024). From the seed to the cocoa liquor: Traceability of bioactive compounds during the postharvest process of cocoa in Amazonas-Peru. *Microchemical Journal*, 201, 110607. <https://doi.org/10.1016/j.microc.2024.110607>
- De la Peña, N., & Granados, O. M. (2023). Artificial intelligence solutions to reduce information asymmetry for Colombian cocoa small-scale farmers. *Information Processing in Agriculture*. <https://doi.org/10.1016/j.inpa.2023.03.001>
- Delgado, C., Couturier, G., Balcazar, L., & Chichipe, A. (2023). Insect pests of *Theobroma cacao* (Malvaceae) in the Peruvian Amazon. *Tropical Agriculture*, 100(2), 110–114.
- Eric, O., Gyening, R.-M. O. M., Appiah, O., Takyi, K., & Appiahene, P. (2023). Cocoa beans classification using enhanced image feature extraction techniques and a regularized artificial neural network model. *Engineering Applications of Artificial Intelligence*, 125, 106736. <https://doi.org/10.1016/j.engappai.2023.106736>
- Figiel, S. (2022). Development of artificial intelligence and potential impact of its applications in agriculture on labor use and productivity. *Zagadnienia Ekonomiki Rolnej / Problems of Agricultural Economics*, 373(4), 5–21. <https://doi.org/10.30858/zer/153583>
- Gopalakrishna, K. M., & Lingaraju, R. M. (2025). A prediction of coconut and coconut leaf disease using MobileNetV2 based classification. *International Journal of Electrical and Computer Engineering*, 15(3), 2834–2844. <https://doi.org/10.11591/ijece.v15i3.pp2834-2844>

- Huang, X., Peng, D., Qi, H., Zhou, L., & Zhang, C. (2024). Detection and instance segmentation of grape clusters in orchard environments using an improved Mask R-CNN model. *Agriculture*, 14(6), 918. <https://doi.org/10.3390/agriculture14060918>
- J., A., Eunice, J., Popescu, D. E., Chowdary, M. K., & Hemanth, J. (2022). Deep learning-based leaf disease detection in crops using images for agricultural applications. *Agronomy*, 12(10), 2395. <https://doi.org/10.3390/agronomy12102395>
- Javaid, M., Haleem, A., Khan, I. H., & Suman, R. (2023). Understanding the potential applications of artificial intelligence in agriculture sector. *Advanced Agrochem*, 2(1), 15–30. <https://doi.org/10.1016/j.aac.2022.10.001>
- Jesse, A., Douha, N. Y.-R., & Lenka, P. (2024). Image classification for CSSVD detection in cacao plants. *arXiv*. <https://arxiv.org/abs/2405.04535>
- Karim, M. J., Goni, M. O. F., Nahiduzzaman, M., Ahsan, M., Haider, J., & Kowalski, M. (2024). Enhancing agriculture through real-time grape leaf disease classification via an edge device with a lightweight CNN architecture and Grad-CAM. *Scientific Reports*, 14(1), 16022. <https://doi.org/10.1038/s41598-024-66989-9>
- Khan, M., et al. (2024). Ensemble and optimization algorithm in support vector machines for classification of wheat genotypes. *Scientific Reports*, 14(1), 22728. <https://doi.org/10.1038/s41598-024-72056-0>
- Kouassi, K. S., Diarra, M., Edi, K. H., & Koua, B. J.-C. (2024). Detection of cocoa leaf diseases using the CNN-based feature extractor and XGBOOST classifier. *Open Journal of Applied Sciences*, 14(10), 2955–2972. <https://doi.org/10.4236/ojapps.2024.1410193>
- Kouassi, K. S., Diarra, M., Edi, K. H., & Koua, B. J.-C. (2025). Detection of cocoa pod diseases using a hybrid feature extractor combining CNN and vision transformer with dual classifier. *Edelweiss Applied Science and Technology*, 9(1), 668–681. <https://doi.org/10.55214/25768484.v9i1.4209>
- Lomotey, R. K., Kumi, S., Orji, R., & Deters, R. (2024). Automatic detection and diagnosis of cocoa diseases using mobile tech and deep learning. *International Journal of Sustainable Agricultural Management and Informatics*, 10(1), 92–119. <https://doi.org/10.1504/IJSAMI.2024.135403>
- Lopes, J. F., da Costa, V. G. T., Barbin, D. F., Cruz-Tirado, L. J. P., Baeten, V., & Barbon Junior, S. (2022). Deep computer vision system for cocoa classification. *Multimedia Tools and Applications*, 81(28), 41059–41077. <https://doi.org/10.1007/s11042-022-13097-3>
- Lumumba, V., Kiprotich, D., Mpaine, M., Makena, N., & Kavita, M. (2024). Comparative analysis of cross-validation techniques: LOOCV, K-folds cross-validation, and repeated K-folds cross-validation in machine learning models. *American Journal of Theoretical and Applied Statistics*, 13(5), 127–137. <https://doi.org/10.11648/j.ajtas.20241305.13>
- Malakouti, S. M., Menhaj, M. B., & Suratgar, A. A. (2023). The usage of 10-fold cross-validation and grid search to enhance ML methods performance in solar farm power generation prediction. *Cleaner Engineering and Technology*, 15, 100664. <https://doi.org/10.1016/j.clet.2023.100664>
- Marković, D., Stamenković, Z., Đorđević, B., & Randić, S. (2024). Image processing for smart agriculture applications using cloud-fog computing. *Sensors*, 24(18), 5965. <https://doi.org/10.3390/s24185965>

Martinović, M., Dokic, K., & Pudić, D. (2025). Comparative analysis of machine learning models for predicting innovation outcomes: An applied AI approach. *Applied Sciences*, 15(7), 3636. <https://doi.org/10.3390/app15073636>

Mduma, N., & Laizer, H. (2023). Machine learning imagery dataset for maize crop: A case of Tanzania. *Data in Brief*, 48, 109108. <https://doi.org/10.1016/j.dib.2023.109108>

Ministerio de Desarrollo Agrario y Riego. (2023). *Observatorio de commodities: Cacao*. <https://cdn.www.gob.pe/uploads/document/file/5264502/%20Commodities%20Cacao%3A%20ene-mar%202023.pdf?v=1697059698>

Muzuni, Ambardini, S., Widyaningsih, A. S., & Ismaun. (2023). Morphological and physiological characteristics of cocoa (*Theobroma cacao* L. var. criollo) infected by *Phytophthora palmivora* in cocoa plantations in Southeast Sulawesi Indonesia. *AIP Conference Proceedings*, 020015. <https://doi.org/10.1063/5.0138524>

Mwinami, N. V., Dulle, F. W., & Mtega, W. P. (2024). Data preservation practices for enhancing agricultural research data usage among agricultural researchers in Tanzania. *Journal of Librarianship and Information Science*, 56(1), 198–210. <https://doi.org/10.1177/09610006221138110>

Nyarko, B. N. E., Wu, W., Zhou, Z. J., & Mohd, M. J. (2024). Improved YOLOv5m model based on Swin Transformer, K-means++, and EIoU loss function for cocoa tree disease detection. *Journal of Plant Protection Research*, 64(3), 265–274. <https://doi.org/10.24425/jppr.2024.151253>

Oh, K. E. (2024). A comprehensive investigation of researchers' shared file management practices in cloud storage. *Human-Computer Interaction*, 1–20. <https://doi.org/10.1080/07370024.2024.2310551>

Pei, G., Qian, X., Zhou, B., Liu, Z., & Wu, W. (2025). Research on agricultural disease recognition methods based on very large Kernel convolutional network-RepLKNet. *Scientific Reports*, 15(1), 16843. <https://doi.org/10.1038/s41598-025-01553-7>

Philips Paredes, M. H. (2022). *Modelo de asociatividad para la mejora de la competitividad de las pymes productoras de cacao de la región San Martín*. Universidad Nacional de San Martín.

Raut, R., et al. (2024). Transfer learning based leaf disease detection model using convolution neural network. *Indonesian Journal of Electrical Engineering and Computer Science*, 36(3), 1857–1865. <https://doi.org/10.11591/ijeecs.v36.i3.pp1857-1865>

Restrepo-Arias, J. F., Montoya-Castaño, M. J., Moreno-De La Espriella, M. F., & Branch-Bedoya, J. W. (2025). An application of deep learning models for the detection of cocoa pods at different ripening stages: An approach with Faster R-CNN and Mask R-CNN. *Computation*, 13(7), 159. <https://doi.org/10.3390/computation13070159>

Rios-Jara, J., & Lévano-Rodríguez, D. (2022). Importancia de los dispositivos usados en la fermentación de cacao (*Theobroma cacao* L.). *Revista Agrotecnológica Amazónica*, 2(1). <https://doi.org/10.51252/raa.v2i1.281>

Rodríguez Delzo, E. E., Huerta Guillén, R., & Montañez Artica, A. G. (2023). Identificación de variables que mejoren la cadena productiva de cacao (*Theobroma cacao* L.) y su importancia para el desarrollo del VRAEM - Perú. *Revista Agrotecnológica Amazónica*, 3(2).

- Rojas Castillo, J. A. (2024). *Identificación y distribución de Phytophthora spp., agente causante de la pudrición negra del fruto de cacao (Theobroma cacao L.) en la Amazonia Noroccidental*. Universidad Nacional de Colombia. <https://repositorio.unal.edu.co/handle/unal/86413>
- Rola, J. B., et al. (2024). Convolutional neural network model for cacao *Phytophthora palmivora* disease recognition. *International Journal of Advanced Computer Science and Applications*, 15(8). <https://doi.org/10.14569/IJACSA.2024.0150897>
- Shafik, W., Tufail, A., De Silva Liyanage, C., & Apong, R. A. A. H. M. (2024). Using transfer learning-based plant disease classification and detection for sustainable agriculture. *BMC Plant Biology*, 24(1), 136. <https://doi.org/10.1186/s12870-024-04825-y>
- Soh, K. S., Moun, E. G., Danker, K. J. J., Dargham, J. A., & Farzamnia, A. (2024). Cocoa diseases classification using deep learning algorithm. *ITM Web of Conferences*, 63, 01014. <https://doi.org/10.1051/itmconf/20246301014>
- Sonmez, M. E., Sabanci, K., & Aydin, N. (2024). Convolutional neural network-support vector machine-based approach for identification of wheat hybrids. *European Food Research and Technology*, 250(5), 1353–1362. <https://doi.org/10.1007/s00217-024-04473-4>
- Sousa-Ortega, C., Alcántara, C., Leon, R. G., Barranco-Elena, D., & Saavedra, M. (2024). The impact of burial depth on *Centaurea diluta* emergence and modelling of its growth using a nonlinear regression and artificial neural network. *Pest Management Science*, 80(3), 1182–1192. <https://doi.org/10.1002/ps.7848>
- Sudjud, S., Jamil, M., & Melati, R. (2025). Development of cocoa pod rot disease identification model using You Only Look Once (YOLO-v9). *Mathematical Modelling of Engineering Problems*, 12(4). <https://doi.org/10.18280/mmep.120418>
- Sunaryanto, R., Dewi, Y. S., Nurhayati, N., & Sitompul, J. (2024). Isolation and screening of actinomycetes active against plant pathogenic fungi. *AIP Conference Proceedings*, 040003. <https://doi.org/10.1063/5.0194400>
- Tantiphanwadi, P., & Malithong, K. (2022). Bread browning stage classification model using VGG-16 transfer learning and fine-tuning with small training dataset. *Engineering Journal*, 26(11), 1–12. <https://doi.org/10.4186/ej.2022.26.11.1>
- Taspinar, Y. S., Dogan, M., Cinar, I., Kursun, R., Ozkan, I. A., & Koklu, M. (2022). Computer vision classification of dry beans (*Phaseolus vulgaris* L.) based on deep transfer learning techniques. *European Food Research and Technology*, 248(11), 2707–2725. <https://doi.org/10.1007/s00217-022-04080-1>
- Tello Púa, A. N., & Flores Ramírez, R. J. (2022). *Lineamientos arquitectónicos de diseño de una planta industrial de cacao para mejorar la economía de la población de Chazuta*, 2019.
- Uzer, M. S. (2025). Deep learning-based classification consisting of pre-trained models and proposed model using K-fold cross-validation for pistachio species. *Applied Sciences*, 15(8), 4516. <https://doi.org/10.3390/app15084516>
- Vargas Ramírez, M. (2023). *Nivel de conocimiento sobre fertilización de suelos de los productores cacaoteros de la provincia Mariscal Cáceres*. Universidad Nacional de San Martín.
- Villalobos-Culqui, C., Valles-Coral, M. A., García-Rivas-Plata, C., & Tuesta-Hidalgo, O. A. (2025). Modelo de visión artificial basada en redes neuronales convolucionales para

identificación de mazorca negra en plantaciones de cacao. *Revista Científica de Sistemas e Informática*, 5(1), e678. <https://doi.org/10.51252/rcsi.v5i1.678>

Villamonte, A. F., Silva, P. J. S., Ronquillo, D. G. D., Rosales, M. A., Bandala, A. A., & Dadios, E. P. (2021). Python based defect classification of *Theobroma cacao* bean using fine-tuned Visual Geometry Group16. In *2021 IEEE 13th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)* (pp. 1-6). IEEE. <https://doi.org/10.1109/HNICEM54116.2021.9731887>

Xu, M., Park, J.-E., Lee, J., Yang, J., & Yoon, S. (2024). Plant disease recognition datasets in the age of deep learning: Challenges and opportunities. *Frontiers in Plant Science*, 15. <https://doi.org/10.3389/fpls.2024.1452551>

Yang, C., Teng, Z., Dong, C., Lin, Y., Chen, R., & Wang, J. (2022). In-field citrus disease classification via convolutional neural network from smartphone images. *Agriculture*, 12(9), 1487. <https://doi.org/10.3390/agriculture12091487>

Zhou, Y., Zhu, Y., & Wong, W. K. (2023). Statistical tests for homogeneity of variance for clinical trials and recommendations. *Contemporary Clinical Trials Communications*, 33, 101119. <https://doi.org/10.1016/j.conctc.2023.101119>