



Esta obra está bajo una
[Licencia Creative Commons
Atribución - 4.0 Internacional \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)
Vea una copia de esta licencia en
<https://creativecommons.org/licenses/by/4.0/deed.es>





FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

Tesis

Modelo de visión artificial basada en redes neuronales convolucionales para la clasificación de frutos de aguaymanto

Para optar el título profesional de Ingeniero de Sistemas e Informática

Autor:

Hector Luis Saavedra Caballero

<https://orcid.org/0009-0007-5977-8246>

Asesor:

Ing. Mg. Richard Enrique Injante Ore

<https://orcid.org/0000-0002-2449-8937>

Tarapoto, Perú

2025



FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

Tesis

Modelo de visión artificial basada en redes neuronales convolucionales para la clasificación de frutos de aguaymanto

Para optar el título profesional de Ingeniero de Sistemas e Informática

Presentado por

Hector Luis Saavedra Caballero

Sustentado y aprobado el 13 de marzo de 2025, ante el honorable jurado:

Presidente de Jurado

Ing. Dr. Jorge Damian Valverde
Iparraguirre

Secretario de Jurado

Ing. Mg. Segundo Roger Ramirez
Shupingahua

Vocal de Jurado

Lic. Dr. Wilson Torres Delgado

Asesor

Ing. Mg. Richard Enrique Injante Ore

Tarapoto, Perú

2025



**ACTA DE SUSTENTACIÓN
PARA OPTAR EL TÍTULO DE INGENIERO DE SISTEMAS E INFORMÁTICA**

Resolución N° 007-2025-UNSM/FISI-D (06.03.2025)

FACULTAD DE INGENIERÍA DE SISTEMAS E INFORMÁTICA – ESCUELA PROFESIONAL DE
INGENIERÍA DE SISTEMAS E INFORMÁTICA

A las 11:00 horas del día Jueves, 13 de marzo del año 2025, se inició el acto público de sustentación de la tesis titulada MODELO DE VISIÓN ARTIFICIAL BASADA EN REDES NEURONALES CONVOLUCIONALES PARA LA CLASIFICACIÓN DE FRUTOS DE AGUAYMANTO; presentado por HECTOR LUIS SAAVEDRA CABALLERO, con el Asesor: Ing. Mg. Richard Enrique Injante Ore.

Instalado los miembros de jurado calificador conformado por:

Presidente : Ing. Dr. JORGE DAMIAN VALVERDE IPARRAGUIRRE
Secretario : Ing. Mg. SEGUNDO ROGER RAMÍREZ SHUPINGAHUA
Vocal : Lic. Dr. WILSON TORRES DELGADO

El presidente del jurado dirigió brevemente unas palabras y a continuación el secretario dio lectura a la Resolución N° 007-2025-UNSM/FISI-D.

Seguidamente el autor expuso el trabajo de investigación y el jurado realizó las preguntas pertinentes, respondidas por el sustentante y eventualmente por el asesor, con la venia del jurado.

Una vez terminada la ronda de preguntas el jurado procedió a deliberar para determinar la calificación final, para lo cual dispuso un receso de quince (15) minutos, con participación del asesor con voz, pero sin voto y sin la presencia del sustentante y otros participantes del acto público.

Luego de aplicar los criterios de calificación con estricta observancia del principio de objetividad y de acuerdo con los puntajes en escala vigesimal (de 0 a 20), según el Anexo 4.2. del RG-CTI, la nota de sustentación otorgada resultante del promedio aritmético de los calificativos emitidos por cada uno de los miembros del jurado fue *diecisiete (17)*.

De acuerdo con el Artículo 40° del RG – CTI, la nota obtenida es *aprobado*..... y correspondiente a la calificación de *muy. bueno*....; leído este resultado en presencia de todos los participantes del acto de sustentación, el secretario dio lectura a las observaciones subsanables al informe final que el autor deberá corregir y alcanzar al jurado en un plazo máximo de treinta (30) días calendario.



Universidad Nacional de San Martín
Facultad de Ingeniería de Sistema e Informática
Ciudad Universitaria - Jr. Amorarca # 315 - Morales



Firman los integrantes del jurado calificador, asesor y el autor de la tesis en señal de conformidad, dando por concluido el acto a las 12.00 horas, el mismo día 13 de marzo del 2025.

.....
**Ing. Dr. JORGE DAMIAN VALVERDE
IPARRAGUIRRE**
Presidente

.....
**Ing. Mg. SEGUNDO ROGER RAMÍREZ
SHUPINGAHUA**
Secretario

.....
Lic. Dr. WILSON TORRES DELGADO
Vocal

.....
**Ing. Mg. RICHARD ENRIQUE
INJANTE ORE**
Asesor

.....
HECTOR LUIS SAAVEDRA CABALLERO
Autor

Declaratoria de autenticidad

Héctor Luis Saavedra Caballero, con DNI N° 73235334, egresado de la Escuela Profesional de Ingeniería de Sistemas e Informática Facultad de Ingeniería de Sistemas e Informática de la Universidad Nacional de San Martín, autor de la tesis titulada: **Modelo de visión artificial basada en redes neuronales convolucionales para la clasificación de frutos de aguaymanto**

Declaramos bajo juramento que:

1. La tesis presentada es de mi autoría.
2. La redacción fue realizada respetando las citas y referencia de las fuentes bibliográficas consultadas, siguiendo las normas APA actuales.
3. Toda información que contiene la tesis no ha sido plagiada.
4. Los datos presentados en los resultados son reales, no han sido alterados ni copiados, por tanto, la información de esta investigación debe considerarse como aporte a la realidad investigada.

Por lo antes mencionado, asumo bajo responsabilidad las consecuencias que deriven de mi accionar, sometiéndome a las leyes de nuestro país y normas vigentes de la Universidad Nacional de San Martín.

Tarapoto, 13 de marzo del 2025



Hector Luis Saavedra Caballero

73235334

Autor

Ficha de identificación

Título: Modelo de visión artificial basada en redes neuronales convolucionales para la clasificación de frutos de aguaymanto	Área de investigación: Ciencias Naturales Línea de investigación: Ciencias de la Computación Sublínea de investigación: Inteligencia Artificial y Recuperación de Información. Grupo de investigación: Grupo de Investigación IA, Resolución N° 134-2021-UNSM/FISI/CFT Tipo de investigación: Básica <input type="checkbox"/> , Aplicada <input checked="" type="checkbox"/> , Desarrollo experimental <input type="checkbox"/>
--	---

Autor: Hector Luis Saavedra Caballero	Facultad de Ingeniería de Sistemas e Informática Escuela Profesional de Ingeniería de Sistemas e Informática https://orcid.org/0009-0007-5977-8246
---	--

Asesor: Ing. Mg. Richard Enrique Injante Ore	Dependencia local de soporte: Facultad de Ingeniería de Sistemas e Informática Escuela Profesional de Ingeniería de Sistemas e Informática Unidad o Laboratorio Ingeniería de Sistemas e Informática https://orcid.org/0000-0002-2449-8937
--	---

Índice general

Ficha de identificación	6
Índice general.....	7
Índice de tablas	9
Índice de figuras	10
RESUMEN	11
ABSTRACT	12
CAPÍTULO I INTRODUCCIÓN A LA INVESTIGACIÓN	13
CAPÍTULO II MARCO TEÓRICO	15
2.1. Antecedentes de la investigación.....	15
2.2. Fundamentos teóricos	18
CAPÍTULO III MATERIALES Y MÉTODOS	27
3.1. Ámbito y condiciones de la investigación.....	27
3.1.1 Contexto de la investigación.....	27
3.1.2 Periodo de ejecución.....	27
3.1.3 Autorizaciones y permisos.....	27
3.1.4 Control ambiental y protocolos de bioseguridad	27
3.1.5 Aplicación de principios éticos internacionales	28
3.2. Sistema de variables	28
3.3 Procedimientos de la investigación.....	29
3.3.1 Objetivo específico 1: Analizar las características distintivas de los frutos de aguaymanto	29
3.3.2 Objetivo específico 2: Diseñar un modelo de visión artificial basado en redes neuronales convolucionales que considere las características clave de los frutos de aguaymanto y las limitaciones técnicas.....	32
3.3.3 Objetivo específico 3: Evaluar el rendimiento del modelo propuesto con otros enfoques tradicionales de clasificación de frutos de aguaymanto, utilizando métricas de precisión, eficiencia y confiabilidad.....	37
CAPÍTULO IV RESULTADOS Y DISCUSIÓN	38

4.1	Resultado específico 1: Analizar las características distintivas de los frutos de aguaymanto	38
4.2	Resultado específico 2: Diseñar un modelo de visión artificial basado en redes neuronales convolucionales que considere las características clave de los frutos de aguaymanto y las limitaciones técnicas.....	39
4.3	Resultado específico 3: Evaluar el rendimiento del modelo propuesto con otros enfoques de clasificación de frutos de aguaymanto.	45
4.4	Discusión	51
	CONCLUSIONES	54
	RECOMENDACIONES.....	55
	REFERENCIAS BIBLIOGRÁFICAS.....	56
	ANEXOS	61

Índice de tablas

Tabla 1	Operacionalización de la variable dependiente.	28
Tabla 2	Operacionalización de la variable independiente.	29
Tabla 3	Características visuales de los estados de madurez de los frutos de papaya	38
Tabla 4	Parámetros críticos para el entrenamiento.	41
Tabla 5	Resultados finales del modelo CNN.	43
Tabla 6	Resultados obtenidos con el modelo SVM.	46
Tabla 7	Resultados obtenidos con el modelo KNN.	47
Tabla 8	Resultados obtenidos con el modelo RFC.	48
Tabla 9	Comparación de métricas entre CNN y enfoques tradicionales.	49
Tabla 10	Comparación de accuracy en la clasificación de aguaymanto.	52
Tabla 11	Comparación de accuracy de diferentes investigaciones que utilizan CNN para clasificación de productos agrícolas.	53

Índice de figuras

Figura 1 Estructura típica de una CNN	19
Figura 2 Hiperplano de separación en SVM.....	22
Figura 3 Representación básica del algoritmo KNN	23
Figura 4 Árbol de decisión en Random Forest	24
Figura 5 Fases de la metodología SEMMA.....	25
Figura 6 Frutos de aguaymanto almacenados en caja.....	30
Figura 7 Captura de las imágenes de aguaymanto	31
Figura 8 Secuencia de procesamiento de frutos de aguaymanto	32
Figura 9 Resumen detallado de la arquitectura del modelo CNN.....	34
Figura 10 Resumen general del procedimiento del modelo CNN.....	36
Figura 11 Muestras de frutos de aguaymanto en tres estados de madurez	39
Figura 12 Matriz de confusión promedio del modelo CNN, donde las clases de 0 a 2 representan “Maduro”, “Semimaduro” y “Verde”, respectivamente.....	43
Figura 13 Evolución del entrenamiento y validación de la precisión y pérdida	44
Figura 14 Matriz de confusión del modelo SVM, donde las clases de 0 a 2 representan “Maduro”, “Semimaduro” y “Verde”, respectivamente	46
Figura 15 Matriz de confusión del modelo KNN, donde las clases de 0 a 2 representan “Maduro”, “Semimaduro” y “Verde”, respectivamente	47
Figura 16 Matriz de confusión del modelo RFC.	48
Figura 17 Comparación de precisión de los modelos de clasificación	50

RESUMEN

Modelo de visión artificial basada en redes neuronales convolucionales para la clasificación de frutos de aguaymanto

El estudio se centra en el desarrollo de un modelo de visión artificial mediante redes neuronales convolucionales (CNN) para clasificar frutos de aguaymanto (*Physalis peruviana*) en tres niveles de madurez: verde, semimaduro y maduro. La investigación se realizó en la ciudad de Tarapoto, Perú, durante 2023 y 2024. El objetivo principal fue mejorar la precisión y eficiencia en la clasificación del aguaymanto frente a métodos manuales y algoritmos tradicionales. El diseño del modelo incluyó etapas de adquisición de datos, procesamiento y entrenamiento. Se capturaron imágenes en un entorno controlado y se emplearon técnicas de aumento de datos para mejorar la robustez del modelo. Para la evaluación, se compararon los resultados con algoritmos tradicionales como K-Nearest Neighbors (KNN), Support Vector Machines (SVM) y Random Forest Classifier (RFC), usando métricas de precisión, exactitud y F1-Score. Se implementó una validación cruzada con 5 pliegues para evaluar el rendimiento del modelo. El modelo CNN alcanzó una precisión del 99.22%, superando a los otros métodos. Los resultados indican que el modelo es altamente efectivo para la clasificación de frutos en función de su madurez, mejorando la velocidad y precisión respecto a métodos manuales. Se concluye que el modelo CNN desarrollado es altamente efectivo para la clasificación de frutos de aguaymanto según su madurez, y que la automatización de este proceso puede contribuir significativamente a la mejora de la eficiencia y la calidad en la industria agrícola.

Palabras clave: inteligencia artificial, aguaymanto, CNN, visión artificial, *Physalis peruviana*, uchuva.

ABSTRACT

Computer vision model based on convolutional neural networks for the classification of aguaymanto fruits

The study focuses on the development of a computer vision model using convolutional neural networks (CNN) to classify aguaymanto (*Physalis peruviana*) fruits into three maturity levels: green, semi-ripe and ripe. The research was conducted in the city of Tarapoto, Peru, during 2023 and 2024. The main objective was to improve the accuracy and efficiency of aguaymanto classification compared to manual methods and traditional algorithms. The model design included data acquisition, processing and training stages. Images were captured in a controlled environment and data augmentation techniques were employed to improve the robustness of the model. For evaluation, results were compared with traditional algorithms such as K-Nearest Neighbors (KNN), Support Vector Machines (SVM) and Random Forest Classifier (RFC), using precision, accuracy and F1-Score metrics. A cross-validation with 5 folds was implemented to evaluate the model performance. The CNN model achieved an accuracy of 99.22%, outperforming the other methods. The results indicate that the model is highly effective for the classification of fruits according to their maturity, improving the speed and accuracy with respect to manual methods. It is concluded that the CNN model developed is highly effective for the classification of aguaymanto fruits according to their maturity, and that the automation of this process can contribute significantly to the improvement of efficiency and quality in the agricultural industry.

Keywords: artificial intelligence, aguaymanto, CNN, artificial vision, *Physalis peruviana*, cape gooseberry.



CAPÍTULO I

INTRODUCCIÓN A LA INVESTIGACIÓN

El aguaymanto (*Physalis peruviana*), también conocido como "golden berry" o "uchuva" en algunas zonas geográficas (Carbajal et al., 2021), es un fruto autóctono que prospera en los valles interandinos de Sudamérica (Álvarez-Herrera et al., 2022). Se destaca por su distintivo sabor agridulce y se ha consolidado como un superalimento apreciado debido a su riqueza nutricional y propiedades medicinales, como lo mencionado en (Navarro-Hoyos et al., 2022). En Perú, su importancia económica es innegable, ya que juega un papel fundamental en el sustento de las comunidades rurales y contribuye de manera significativa a la economía agrícola del país (Álvarez-Herrera et al., 2022).

En la agricultura, la calidad comercial de los cultivos se basa en un conjunto diverso de características, entre las que se incluyen el tamaño, la coloración, la forma y el contenido de azúcar, por nombrar algunas de las mencionadas en (Knott et al., 2023), (Sabzi et al., 2022) y (Masuda et al., 2023). Para evaluar estas características, se ha recurrido comúnmente a la inspección visual o a la experiencia de expertos en el campo (Zhang et al., 2023). Sin embargo, la clasificación manual de los frutos de aguaymanto ha resultado ser un proceso subjetivo, propenso a errores y con consecuencias negativas tanto en la eficiencia de la producción como en la calidad del producto final, tal como se mencionan en (Wang et al., 2023) y (Azadnia et al., 2023).

La clasificación de los aguaymantos se ve afectada por la falta de métodos precisos y eficientes, así como por la escasez de personal capacitado y la ausencia de sistemas automáticos de clasificación (Sabzi et al., 2022). Estas deficiencias generan retrasos significativos en el proceso de categorización, lo que tiene un impacto negativo en la calidad de los productos. Los errores y confusiones resultantes provocan pérdidas y desperdicios (Rizwan Iqbal & Hakim, 2022), y también afectan la satisfacción de los clientes (Azadnia et al., 2023), quienes no reciben productos de calidad ni en el momento adecuado (Lu et al., 2021). Esta situación deteriora la economía, imagen y reputación de la industria del aguaymanto. Además, el problema se agrava debido a las limitaciones inherentes de la percepción humana, lo que puede llevar a aceptar frutos de calidad insuficiente o rechazar frutos de calidad adecuada (Qadri et al., 2021).

Es esencial destacar que la evaluación de las características internas da lugar a una disminución del valor comercial debido a la necesidad de realizar evaluaciones destructivas (Sabzi et al., 2022). Para abordar este problema, optamos por técnicas no destructivas

más rápidas y efectivas que los algoritmos de clasificación supervisada, como se menciona en (Ratha et al., 2023). En la última década, se han desarrollado diversas técnicas para abordar la detección de frutos (Phan et al., 2023), en particular, aquellas que se basan en enfoques no destructivos

Por lo tanto, el estudio se ha centrado en el desarrollo de un modelo de visión artificial basado en redes neuronales convolucionales (CNN) para la clasificación de frutos de aguaymanto. Las CNN han demostrado de manera sobresaliente su eficacia en la clasificación de imágenes y la identificación de patrones visuales complejos de manera no destructiva, lo que las convierte en una elección idónea para esta tarea, respaldado por (Phan et al., 2023). Anticipamos que nuestra solución proporciona mayor velocidad y precisión en comparación con los algoritmos de clasificación supervisada de clasificación, como lo realizado en el estudio de (Tamayo-Monsalve et al., 2022).

El estudio se limitó al desarrollo de un modelo de visión artificial basado en redes neuronales convolucionales para la clasificación de frutos de aguaymanto que tome en cuenta características clave. El modelo se desarrolló empleando CNN, compuesta por varias capas. Los resultados obtenidos se compararon con otros enfoques tradicionales, como lo realizado en (Rizwan Iqbal & Hakim, 2022). En el proceso, tomamos en cuenta únicamente las características externas de la fruta para la clasificación, como lo planteado en (Tamayo-Monsalve et al., 2022).

Una parte esencial de una industria agrícola eficiente radica en la producción y suministro de frutas y verduras frescas al mercado (Azadnia et al., 2023). En nuestro estudio, esta cuestión ha adquirido una relevancia sustancial, dado el creciente interés en el aguaymanto en el mercado, impulsado por sus beneficios medicinales y nutricionales. La variabilidad inherente en la forma, tamaño y color de los frutos ha resaltado la necesidad de una clasificación precisa para garantizar la calidad y satisfacer las demandas del mercado. La implementación de las CNN se ha perfilado como una solución eficaz para superar las limitaciones de los algoritmos de clasificación supervisada y mejorar la eficiencia en la clasificación de los frutos, contribuyendo al avance de la industria del aguaymanto.

En este sentido, el objetivo general de nuestra investigación ha sido desarrollar un modelo de visión artificial basado en CNN para la clasificación de frutos de aguaymanto. Los objetivos específicos incluyeron el análisis de las características distintivas de los frutos de aguaymanto, el diseño del modelo de visión artificial tomando en cuenta estas características y la evaluación comparativa del rendimiento del modelo frente a otros enfoques tradicionales de clasificación.

CAPÍTULO II

MARCO TEÓRICO

2.1. Antecedentes de la investigación

En el artículo de Castro et al. (2019), titulado "Classification of Cape Gooseberry Fruit According to Its Level of Ripeness Using Machine Learning Techniques and Different Color Spaces" desarrollaron un sistema no intrusivo para clasificar las frutas de uchuva según su grado de madurez. Este proceso se llevó a cabo en diversas etapas, que abarcan la recolección de 925 muestras de frutas de uchuva en diferentes estados de maduración, la construcción de un sistema de visión artificial para capturar imágenes de las frutas, la extracción de características de color en tres espacios de color diferentes (RGB, HSV y $L^*a^*b^*$), y el entrenamiento de cuatro modelos de aprendizaje automático (ANN, DT, SVM y KNN) para la clasificación. Los modelos fueron evaluados utilizando una estrategia de validación cruzada de 5 veces con cien repeticiones. Los resultados mostraron que el espacio de color $L^*a^*b^*$ y el clasificador SVM obtuvieron el mejor rendimiento en términos de precisión y medida f . Además, la combinación de información de los tres espacios de color mediante un análisis de componentes principales (PCA) mejoró la precisión de los modelos. En conclusión, el estudio demostró el potencial de las técnicas de aprendizaje automático y el análisis de imágenes para la clasificación no destructiva de la madurez de la fruta de uchuva, con implicaciones para la automatización de procesos en la industria alimentaria.

Taner et al. (2023), en su artículo "Multiclass Apple Varieties Classification Using Machine Learning with Histogram of Oriented Gradient and Color Moments" desarrollaron modelos de aprendizaje automático con el fin de clasificar diez variedades de manzanas. Este proceso se llevó a cabo en diversas etapas, que abarcan la adquisición de imágenes a través de un sistema especializado, la extracción de características de dichas imágenes, la preparación de los clasificadores de aprendizaje automático y la comparación de los diferentes modelos. Los modelos entrenados fueron evaluados utilizando un conjunto de datos de prueba independiente, logrando los siguientes resultados de precisión: SVM (98.17%), RFC (96.67%), MLP (98.62%) y KNN (91.28%). Estos resultados reflejan un alto nivel de precisión en la clasificación de las variedades de manzanas. En conclusión, los hallazgos del estudio evidencian el considerable potencial de los modelos de aprendizaje automático en la clasificación de variedades de manzanas. En particular, la combinación

de descriptores HOG y momentos de color demostró ser altamente efectiva para el entrenamiento de modelos como MLP y SVM.

En el artículo de Hassan et al. (2023), titulado “Quality of performance evaluation of ten machine learning algorithms in classifying thirteen types of apple fruits” proponen un método que combina redes neuronales convolucionales (CNN) con algoritmos tradicionales para la clasificación de tomates. El estudio se realizó en varias etapas, comenzando con la adquisición de imágenes. Se utilizaron cámaras para capturar un total de 2,400 imágenes, que incluían 600 tomates con diversas características. A continuación, se llevó a cabo el preprocesamiento de las imágenes, así como el aumento de datos y la preparación de los algoritmos. Las CNN se emplearon específicamente para la extracción de características, mientras que se utilizaron algoritmos tradicionales de aprendizaje automático, como las máquinas de vectores de soporte (SVM), el bosque aleatorio (RF) y los k-vecinos más cercanos (KNN) para la clasificación de los tomates. Entre los modelos híbridos evaluados, el método CNN-SVM obtuvo los mejores resultados, superando a otros enfoques híbridos. La precisión alcanzada en la clasificación de los tomates fue del 97.50%. En conclusión, el enfoque propuesto aprovecha técnicas de ajuste en redes previamente entrenadas, con el objetivo de optimizar el aprendizaje de las capas profundas en la identificación de características complejas y significativas de las imágenes de tomates.

En el artículo Behera et al. (2021), titulado “Maturity status classification of papaya fruits based on machine learning and transfer learning approach” se desarrolla un enfoque que combina aprendizaje automático y aprendizaje por transferencia para la clasificación de papaya. El proceso de desarrollo consta de varias etapas: la recolección de muestras, que incluye 300 imágenes; el desarrollo del enfoque de aprendizaje automático; el desarrollo del enfoque de aprendizaje por transferencia; y la comparación de resultados. En los enfoques de aprendizaje automático, se emplearon diversas características y clasificadores, entre los cuales destacan el patrón binario local (LBP), el histograma de gradientes orientados (HOG), la matriz de coocurrencia de nivel de gris (GLCM), el clasificador de vecino más cercano (KNN), la máquina de vectores de soporte (SVM) y Naïve Bayes. Por otro lado, el enfoque de aprendizaje por transferencia incluye siete modelos previamente entrenados: ResNet101, ResNet50, ResNet18, VGG19, VGG16, GoogleNet y AlexNet. El clasificador KNN, que utiliza la función HOG, demostró un rendimiento notable al alcanzar una precisión del 100% con un tiempo de entrenamiento de 0.0995 segundos, superando a otros modelos de clasificación basados en aprendizaje automático. En el ámbito del aprendizaje por transferencia, el modelo VGG19 también se destacó, logrando una precisión del 100% con un tiempo de entrenamiento de 1 minuto y

52 segundos, teniendo en cuenta la técnica de parada temprana. En conclusión, tanto en el enfoque de aprendizaje automático como en el de aprendizaje por transferencia, el modelo VGG19 se destaca como el más eficiente en todos los aspectos evaluados.

En el artículo de Tamayo-Monsalve et al. (2022), titulado “Coffee Maturity Classification Using Convolutional Neural Networks and Transfer Learning” proponen un sistema de clasificación de la madurez del café basado en redes neuronales convolucionales (CNN) y tecnología de imágenes hiperespectrales. En el estudio, clasificaron un total de 640 frutas de café de cereza de la variedad Arábica tipo Caturra por expertos y adquirieron un sistema multispectral para capturar imágenes en diferentes etapas de maduración. Para el análisis, probaron varios modelos basados en CNN y seleccionaron los mejores modelos entrenados con y sin Transfer Learning (TL), utilizando una validación cruzada para determinar las métricas. Los modelos Inception-ResNet v2 y DenseNet 201 demostraron una precisión del 100% y una desviación estándar del 0% durante la validación cruzada de 10 veces, incluyendo cuatro experimentos que comparaban diferentes arquitecturas de redes neuronales convolucionales y la aplicación de TL. Los hallazgos del estudio pueden ser de gran relevancia para la comunidad científica, ya que demuestran el potencial de las CNN junto con los sistemas multispectrales para la agricultura de precisión y para mejorar la calidad en la clasificación automática de las frutas del café.

En su artículo, Sabzi et al. (2022) titulado “Non-Destructive Estimation of Physicochemical Properties and Detection of Ripeness Level of Apples Using Machine Vision” presentan un enfoque no destructivo para estimar las propiedades fisicoquímicas y niveles de madurez de las manzanas en entornos de huerto utilizando inteligencia artificial y procesamiento de video. El desarrollo del enfoque constó de varias fases, incluyendo la extracción de características de color y textura, análisis experimental para identificar las propiedades fisicoquímicas de referencia y niveles de madurez de las manzanas, selección de características óptimas, desarrollo de modelos de predicción y clasificación. Tras examinar niveles de madurez de 1356 manzanas en huertos naturales, se alcanzó una tasa de clasificación correcta del 97,86%. En conclusión, el enfoque desarrollado resultó satisfactorio al permitir estimar propiedades fisicoquímicas y niveles de madurez de manera precisa y no invasiva utilizando técnicas de inteligencia artificial y procesamiento de video.

En el artículo Azadnia et al. (2023), titulado “Intelligent detection and waste control of hawthorn fruit based on ripening level using machine vision system and deep learning techniques” se propone una técnica práctica basada en una red neuronal convolucional modificada para un sistema automatizado de clasificación de espino. Para su desarrollo,

se siguieron distintas fases, entre ellas la recolección de 600 frutos de espino en tres niveles de maduración, la construcción de una caja de captura de imágenes en un teléfono inteligente, la implementación de un algoritmo automatizado en Python para aplicar operaciones de procesamiento previo, el aumento de datos, el desarrollo de la red neuronal convolucional modificada y la evaluación con otros modelos. El estudio arrojó precisiones de prueba del 100%, 99,63% y 99,63% utilizando Inception-V3, ResNet-50 y la CNN propuesta, respectivamente. En conclusión, las redes profundas empleadas pueden ser utilizadas para la clasificación automatizada de frutas en las industrias alimentarias modernas.

En el artículo Ratha et al. (2023), titulado “Papaya Fruit Maturity Estimation Using Wavelet and ConvNET” se desarrolló un nuevo sistema de clasificación no destructivo para categorizar las papayas según su nivel de madurez. El sistema consta de varias etapas, que incluyen la recolección de 300 muestras, con 100 muestras en cada grupo. Se probaron tres modelos de clasificación y se examinaron las características profundas de VGG16 con SVM, así como la extracción de características basada en DWT a gran escala con SVM, dentro del enfoque de aprendizaje profundo. La técnica de aprendizaje profundo, que combina las características profundas de VGG16 con SVM, arrojó resultados de precisión y AUC del 96,7% y 100%, respectivamente. En conclusión, el método híbrido de clasificación automática puede ser utilizado para clasificar las papayas según su nivel de madurez y resulta útil para la industria frutícola.

2.2. Fundamentos teóricos

Visión Artificial

La visión artificial es una disciplina que tiene como objetivo permitir a las máquinas adquirir, procesar y comprender información visual de manera similar a como lo hacen los seres humanos (Santa María Pinedo et al., 2021). Entre las tareas más comunes de la visión artificial se encuentra la clasificación de objetos, incluidos los frutos. La aplicación de técnicas de visión artificial basadas en redes neuronales convolucionales ha demostrado ser efectiva en la clasificación precisa de frutas (Chakraborty et al., 2023).

Red neuronal convolucional (CNN)

De acuerdo con (Rizwan Iqbal & Hakim, 2022) una CNN es una técnica de aprendizaje profundo que imita el funcionamiento del cerebro humano para crear patrones y procesar datos para la toma de decisiones. Según (Shinoda et al., 2023) la arquitectura CNN permite la convolución usando capas de varios tamaños, lo que permite capturar una amplia gama

de características, desde características generales de la imagen hasta pequeños detalles (ver Figura 1). Esto hace posible la clasificación de cultivos y la identificación de enfermedades en cultivos agrícolas al capturar la imagen completa. Además, según (Benmouna et al., 2022), desde su introducción en 1990 por Hubel y Wiesel (Hubel & Wiesel, 1962), se han propuesto muchos modelos de CNN, como AlexNet, VGG Net, ZF Net, GoogLeNet y redes totalmente convolucionales (FCN). Estos modelos han demostrado su papel crucial en varios campos y han mostrado un desempeño sobresaliente en la identificación de enfermedades en cultivos agrícolas.




Figura 1
Estructura típica de una CNN

Nota. La figura ilustra la arquitectura de una CNN, compuesta por una secuencia de capas que procesan una imagen de entrada. Se observan capas de convolución que extraen características mediante filtros, capas de agrupación que reducen la dimensionalidad, capas totalmente conectadas que realizan la clasificación final, y la capa de salida que produce la predicción del modelo.

Capas convolucionales

Según (Rizwan Iqbal & Hakim, 2022), la convolución es la operación central en el procesamiento de imágenes para detectar características únicas con la relación entre los píxeles intacta en la primera capa de CNN. Esta operación implica aplicar núcleos de convolución especialmente diseñados a la imagen original para realizar tareas específicas como desenfoque, nitidez o detección de características. Durante la operación de convolución, el núcleo se aplica horizontalmente (en filas) y verticalmente (en columnas) a la matriz de entrada. Las dimensiones de los núcleos de convolución son menores que las de la imagen de entrada, y sus parámetros permanecen constantes durante todo el proceso de reconocimiento. Este proceso de convolución es una transformación integral esencial en el procesamiento de imágenes en CNN.

Agrupación de capas

Las CNN tienen varias capas, incluyendo una capa de entrada, una capa convolucional, una capa de activación, una capa de agrupación y una capa totalmente conectada, según (Liu & Zhang, 2023). La capa de agrupación, también conocida como capa de submuestreo o pooling, se utiliza para reducir gradualmente el tamaño espacial de los datos, controlar el sobreajuste y utilizar menos recursos computacionales.

La capa de agrupación se inserta periódicamente entre capas convolucionales sucesivas y puede utilizar el Max pooling o la agrupación promedio como métodos comunes. La agrupación promedio en particular, según (Abd El-Wahab et al., 2023), reduce el tamaño del mapa de características después de la capa de convolución al tomar los mapas de características de mayor tamaño y reducir su ancho y altura sin perder información importante.

Capas totalmente conectadas

La capa totalmente conectada es esencial para el aprendizaje de la red neuronal convolucional al permitir el mapeo no lineal de entradas a salidas, según (Abd El-Wahab et al., 2023) y (Rizwan Iqbal & Hakim, 2022). Esta capa se utiliza para clasificar imágenes en categorías y requiere datos en forma de vector unidimensional, por lo que se lleva a cabo un aplanamiento previo.

Preprocesamiento de imágenes

El preprocesamiento de imágenes es una etapa esencial en la clasificación de frutos de aguaymanto. Durante esta fase, se aplican diversas técnicas que optimizan la eficiencia del procesamiento y mejoran la calidad de las imágenes. Entre las técnicas de optimización, destacan el recorte y el redimensionamiento, que permiten adaptar las imágenes a los requerimientos del sistema de clasificación. Por otro lado, las técnicas de mejora de calidad, como el ajuste de contraste, la eliminación de ruido y la normalización de la iluminación, aseguran que las características relevantes de los frutos sean claramente distinguibles. Estas técnicas han sido empleadas con éxito en investigaciones recientes, como las realizadas por (Mukhiddinov et al., 2022) y (Azadnia et al., 2023).

Aumento de datos

El aumento de datos es una técnica crucial en el reconocimiento de imágenes de cultivos agrícolas, como señalan (Shinoda et al., 2023) y (Sabanci, 2023). Recopilar conjuntos de datos puede ser laborioso y prolongado, por lo que es fundamental aplicar técnicas eficientes para aumentar la cantidad de datos disponibles y mejorar la precisión de la

clasificación en aprendizaje profundo. Las técnicas de aumento de datos, como desenfoque, ruido gaussiano y control gamma, consisten en manipulaciones artificiales de imágenes sin procesar para ampliar el número de registros en el conjunto, lo que mejora la capacidad de generalización de los modelos. Según (Rizwan Iqbal & Hakim, 2022), el aumento de datos también soluciona el problema de sobreajuste y permite generar modelos generalizados a partir de conjuntos de datos existentes, lo que contribuye a mejorar la calidad de los análisis y resultados obtenidos. Es decir, el aumento de datos es una herramienta valiosa cuyo uso debe ser considerado en la construcción de modelos de aprendizaje profundo.

Función de activación

Una función de activación es un componente crucial en las redes neuronales que determina si una neurona debe activarse o no, es decir, si debe transmitir su señal a la siguiente capa (Barhate et al., 2023). Estas funciones introducen no linealidades en el modelo, permitiendo que la red aprenda patrones complejos y evitar problemas de sobreajuste como se menciona en (Pipitsunthonsan et al., 2023). Se emplean a menudo para cada capa convolucional según (Azadnia et al., 2023). Existen muchas funciones de activación, cada una tiene características específicas que afectan el rendimiento del modelo en diferentes contextos como lo demostrado en (Mukhiddinov et al., 2022).

Máquinas de vectores de soporte (SVM)

Las Máquinas de Vectores de Soporte (SVM) son un conjunto de métodos de aprendizaje supervisado utilizados para clasificación y regresión. Según (Taner et al., 2023) el objetivo principal de un SVM es encontrar el hiperplano que mejor separa los datos en diferentes clases como lo mostrado en la Figura 2. SVM se destacan por su capacidad de manejar datos de alta dimensionalidad y por su buen desempeño en problemas de clasificación binaria (Hassan et al., 2023).

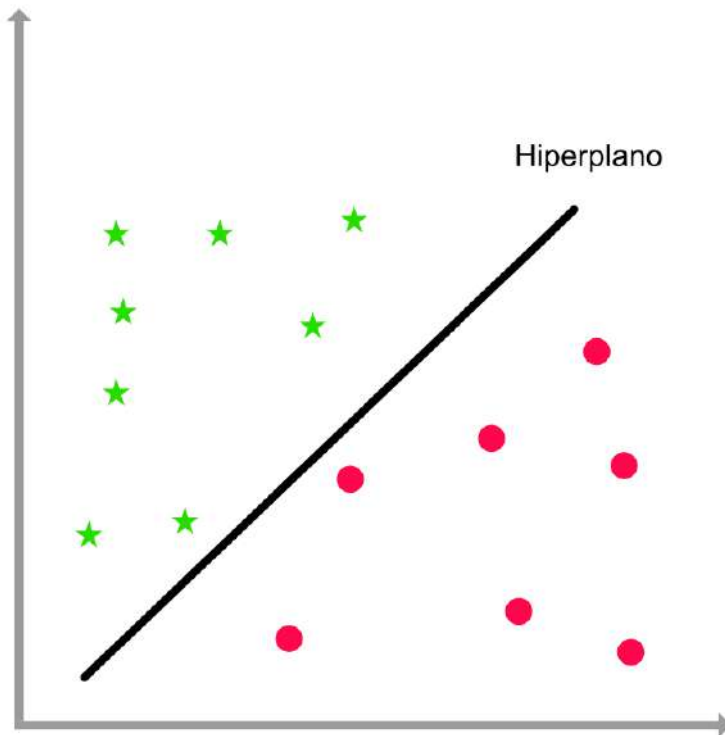


Figura 2
Hiperplano de separación en SVM

K-Vecinos Más Cercanos (KNN)

El algoritmo K-Vecinos Más Cercanos (KNN) es un método de aprendizaje supervisado que se utiliza principalmente para problemas de clasificación, aunque también puede aplicarse a la regresión. Este algoritmo funciona identificando los 'k' ejemplos más cercanos a un punto de consulta y asignando la clase más frecuente entre esos vecinos (ver Figura 3). La distancia entre los puntos se calcula comúnmente utilizando la distancia euclidiana. KNN es conocido por su simplicidad y efectividad, aunque su rendimiento puede verse afectado por la elección del valor de 'k' y la escala de las características (Hassan et al., 2023).




Figura 3
Representación básica del algoritmo KNN

Clasificador de bosque aleatorio (RFC)

Un clasificador de bosque aleatorio (RFC) es un algoritmo de aprendizaje supervisado que pertenece a la familia de los métodos de ensamble. Un RFC consiste en un conjunto de árboles de decisión (ver Figura 4), donde cada árbol se construye utilizando un subconjunto aleatorio de las características y un subconjunto aleatorio de las muestras de entrenamiento, según se menciona en (Taner et al., 2023). La clasificación final se realiza mediante un voto mayoritario entre todos los árboles del bosque (Hassan et al., 2023).

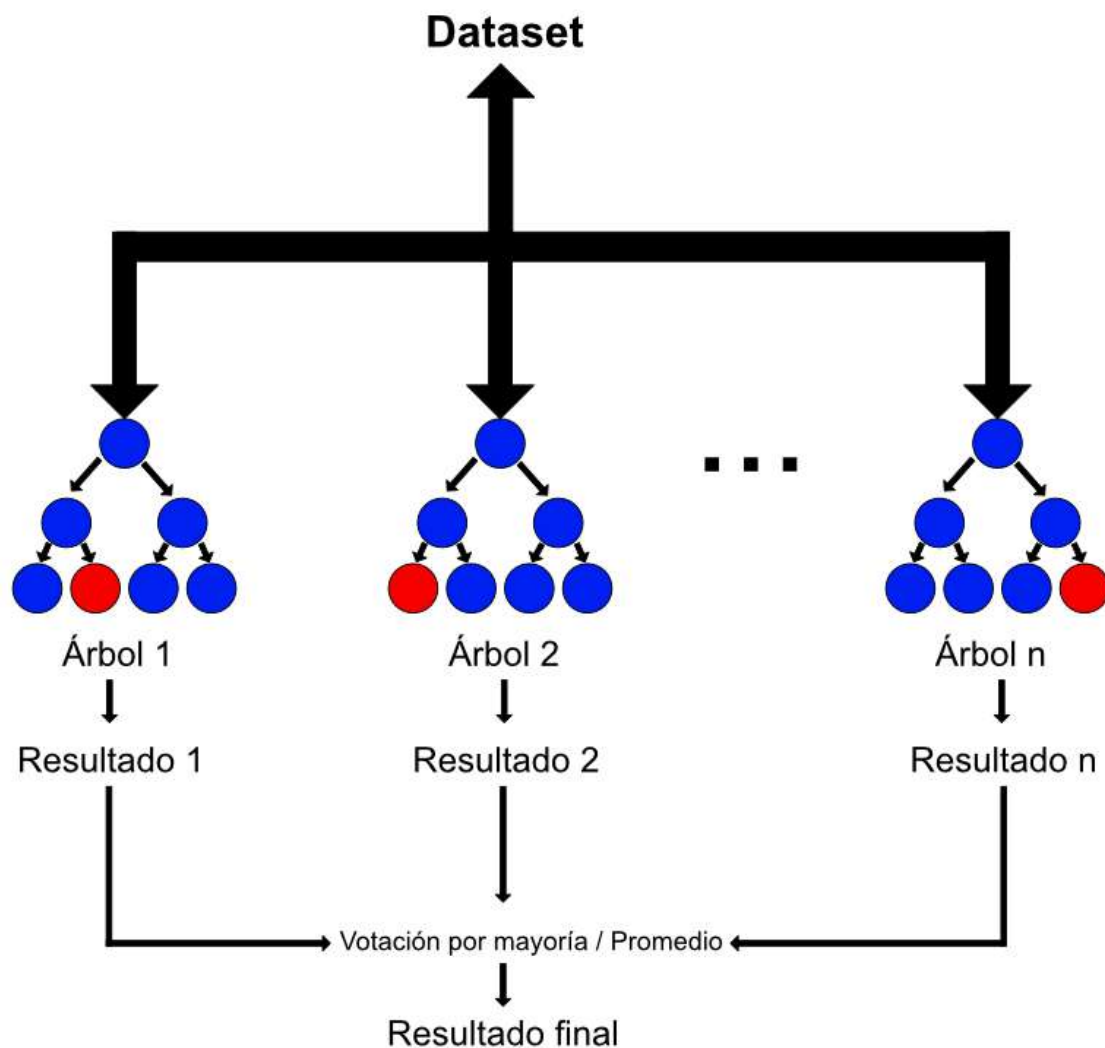


Figura 4
Árbol de decisión en Random Forest

Calidad de frutos

En los últimos años, se ha observado una disminución en el rendimiento y calidad de los cultivos de uchuva, lo que ha ocasionado que una buena parte de la producción no cumpla con los estándares de tamaño y calidad necesarios para su exportación, según (Rosero Erazo et al., 2022). Por esta razón, el seguimiento y control automatizado de la calidad es fundamental para la viabilidad de los productos agrícolas básicos.

(Tamayo-Monsalve et al., 2022) destaca la relevancia de invertir en esfuerzos de investigación para el seguimiento y control automatizado de la calidad en la producción agrícola con el fin de mantener la viabilidad de la industria. En este contexto, (Rizwan Iqbal & Hakim, 2022) describe un enfoque basado en el aprendizaje profundo para la

clasificación y control de calidad automatizado, utilizando características de calidad como el color, tamaño, forma y textura.

(Sholehah et al., 2022) realizó un estudio para determinar la calidad del aguaymanto basándose en criterios para la medición de propiedades físicas como el tamaño, firmeza y color de la fruta, y propiedades químicas como los flavonoides, la vitamina C, la actividad antioxidante, el ácido total titulado (TTA) y los sólidos solubles totales (TSS)

Metodología SEMMA

El proceso metodológico empleado en los artículos analizados se asemeja en gran medida a la metodología SEMMA (ver Figura 5). Este acrónimo representa las cinco fases que la componen: Muestreo, Exploración, Modificación, Modelado y Evaluación (Barrios et al., 2019).

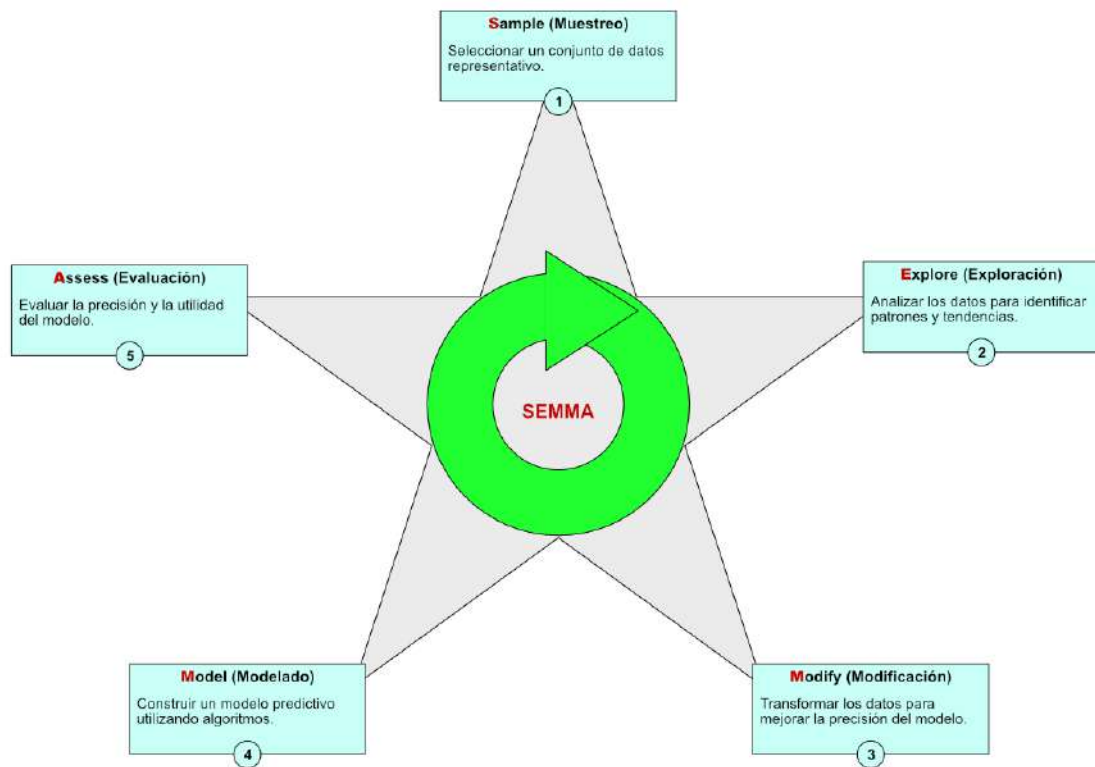


Figura 5
Fases de la metodología SEMMA

A continuación, se explican las fases:

Muestreo: permite seleccionar y preparar los datos adecuados para el entrenamiento y la validación, garantizando que se representen todas las categorías de interés.

Exploración: facilita la identificación de patrones y características clave en los datos, lo que puede influir en el diseño del modelo.

Modificación: mejora la calidad de los datos y optimiza las configuraciones del modelo, aumentando su rendimiento.

Modelado: se centra en la construcción y ajuste del modelo, permitiendo una implementación eficiente de las técnicas de aprendizaje profundo.

Evaluación: proporciona métricas claras y objetivas que permiten medir el rendimiento del modelo, asegurando que se cumplan los objetivos establecidos (Barrios et al., 2019).

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. Ámbito y condiciones de la investigación

3.1.1. Contexto de la investigación

La investigación se desarrolló en la ciudad de Bambamarca, región de Cajamarca, ubicada en el norte del Perú, reconocida por su rica biodiversidad y su contribución significativa a la agricultura. La ciudad de Bambamarca, en particular, fue seleccionada por ser un importante centro de producción de aguaymanto. Políticamente, Cajamarca está subdividida en provincias y distritos, y su economía depende principalmente de la agricultura y la minería. En cuanto al contexto jurídico, la actividad agrícola en la región se rige por la Ley General del Ambiente (Ley N° 28611) y las normas que promueven el desarrollo sostenible del sector agrario.

3.1.2. Periodo de ejecución

El periodo de ejecución de la investigación abarcó desde el 1 de agosto de 2023 hasta el 1 de mayo de 2024. Durante estos nueve meses, se desarrollaron todas las actividades programadas, desde la adquisición de los frutos de aguaymanto, el diseño y entrenamiento del modelo de visión artificial, hasta la evaluación de su rendimiento. Este periodo incluyó fases de recolección de datos, procesamiento de imágenes, implementación del modelo y análisis de resultados.

3.1.3. Autorizaciones y permisos

Nos centramos en el desarrollo y aplicación de técnicas de visión artificial y redes neuronales convolucionales para mejorar la clasificación de los frutos de aguaymanto, sin involucrar la utilización de materiales sujetos a regulaciones específicas.

En este sentido, no se aplican requisitos de autorización, permisos u otras disposiciones equivalentes, ya que la investigación se llevó a cabo utilizando métodos y herramientas estándar, y no se utilizaron reactivos o sustancias de uso regulado.

3.1.4. Control ambiental y protocolos de bioseguridad

Se consideró la importancia de abordar el control ambiental y la seguridad, especialmente cuando se trabajan con niveles de riesgo ambiental o biológico. Sin embargo, dado que el enfoque principal del proyecto se centra en desarrollo de un modelo de clasificación de

frutos de aguaymanto, no se requieren medidas de manejo ambiental o de bioseguridad específicas.

3.1.5. Aplicación de principios éticos internacionales

Totalidad/Integridad: Se ha asegurado que el proyecto sea diseñado y ejecutado de manera coherente y exhaustiva, considerando todos los aspectos relevantes para la mejora de la clasificación de los frutos de aguaymanto mediante el modelo de visión artificial. Esto implica abordar de manera integral los diferentes aspectos técnicos, metodológicos y éticos del proyecto, garantizando la calidad y fiabilidad de los resultados obtenidos.

Respeto al ecosistema: Se han adoptado medidas para minimizar cualquier impacto negativo en el entorno ambiental durante la ejecución del proyecto. Esto implica seguir las disposiciones establecidas por la legislación ambiental peruana, como la Ley N° 28611, Ley General del Ambiente, y sus normas reglamentarias. Se ha procurado utilizar de manera responsable los recursos naturales y se ha evitado cualquier actividad que pueda generar daños al ecosistema.

3.2. Sistema de variables

La tabla de operacionalización de variables tiene la siguiente descomposición:

Tabla 1
Operacionalización de la variable dependiente

Variable Dependiente	Indicadores	Medio de Registro	Unidad de Medida
Clasificación de frutos de aguaymanto	Precisión en la clasificación.	Comparación entre clasificaciones durante evaluación.	Porcentaje (%)
	Exactitud en la predicción de la madurez de los frutos.	Matriz de confusión generada en el sistema de clasificación	Porcentaje (%)
	Medida de balance entre precisión y sensibilidad.	Cálculo estadístico del modelo de clasificación.	Índice (0-1)
	Exactitud (accuracy) en la clasificación de estados de madurez.	Matriz de confusión generada en el sistema de clasificación.	Porcentaje (%)

Tabla 2
Operacionalización de la variable independiente

Variable independiente	Indicadores	Medio de registro	Unidad de medida
Modelo de visión artificial	Parámetros de precisión y ajuste del modelo.	Configuración y validación del modelo.	Parámetro ajustado
	Eficiencia en el procesamiento y clasificación.	Evaluación de tiempos de procesamiento.	Segundos (s)
	Accuracy, F1-Score, Precision y Recall como evaluadores de rendimiento.	Análisis de matriz de confusión en conjunto de prueba.	Porcentaje (%)
	Estructura de la CNN (cantidad de capas, tamaño de filtros).	Arquitectura del modelo durante el entrenamiento.	Parámetros ajustados

3.3 Procedimientos de la investigación

3.3.1. Objetivo específico 1

Analizar las características distintivas de los frutos de aguaymanto

Para alcanzar el objetivo específico, llevamos a cabo las siguientes actividades:

Adquisición de los frutos

Adquirimos los frutos de aguaymanto de la ciudad de Cajamarca, considerando su relevancia en la producción de este cultivo. Establecimos contacto con un productor local y se adquirió una muestra representativa de frutos de aguaymanto en términos de variedad, tamaño y madurez (ver Figura 6). Fueron 900 los frutos que fueron seleccionados y utilizados para desarrollar el modelo.



Figura 6
Frutos de aguaymanto almacenados en caja

Entorno de captura de imágenes

Para obtener imágenes de alta calidad de los frutos de aguaymanto, creamos un entorno controlado en un espacio donde la iluminación y el fondo fueran uniformes y adecuados (ver Figura 7 y Anexo A). Para evitar reflejos que pudieran afectar la apariencia de los frutos, colocamos hojas blancas alrededor de ellos, las cuales funcionaron como difusores de luz. De esta manera, la luz del foco se dispersó y se suavizó, reduciendo la cantidad de luz que se reflejaba en la superficie de los frutos. Esto nos permitió evitar los reflejos no deseados y obtener imágenes más equilibradas y atractivas, como lo realizado en (Cruz-Domínguez et al., 2021). Utilizamos la cámara de un Samsung Galaxy A53 de 64MP, la cual tiene una alta resolución y una buena capacidad de enfoque, asegurando una representación fiel de las características visuales de los frutos, tales como el color, la forma y la textura.



Figura 7
Captura de las imágenes de aguaymanto

Durante este proceso, se capturaron varias imágenes de cada fruto, variando levemente el ángulo y la iluminación. Posteriormente, las imágenes fueron filtradas para seleccionar aquellas de mayor calidad y adecuadas para el análisis.

Clasificación visual por color

El criterio utilizado para clasificar los frutos de aguaymanto según su grado de madurez fue los cambios en la coloración de la epidermis del fruto, el cual refleja el nivel de desarrollo de las semillas. Para establecer un marco de referencia, nos basamos en la norma NTC 4580 (Normativa Técnica Colombiana) para la uchuva (ICONTEC, 1999). Esta norma define siete etapas de madurez, basadas en el color de la superficie, que van desde el verde oscuro hasta el anaranjado intenso. No obstante, en nuestra investigación simplificamos esta clasificación y agrupamos algunas etapas para su simplificación. La Figura 8 muestra el resumen del procedimiento.



Figura 8
Secuencia de procesamiento de frutos de aguaymanto

3.3.2. Objetivo específico 2

Diseñar un modelo de visión artificial basado en redes neuronales convolucionales que considere las características clave de los frutos de aguaymanto y las limitaciones técnicas.

El diseño del modelo de visión artificial basado en CNN para la clasificación de frutos de aguaymanto se llevó a cabo mediante diversas actividades enfocadas en la creación de un sistema de clasificación preciso y eficiente para los frutos de aguaymanto.

Definición del entorno de desarrollo y preprocesamiento de datos

Se empleó el entorno Google Colab para implementar y entrenar el modelo. Este entorno proporciona la capacidad de utilizar potentes recursos computacionales, como GPU, lo cual fue crucial para acelerar el entrenamiento del modelo.

Se utilizaron un conjunto de datos compuesto por 900 imágenes de frutos de aguaymanto, distribuidas en tres categorías de madurez y organizadas en carpetas que representaban las diferentes clases de madurez. Las imágenes se redimensionaron a 224x224 píxeles para asegurar uniformidad en el procesamiento.

Para realizar el aumento de datos, se utilizaron dos generadores de imágenes proporcionados por ImageDataGenerator de TensorFlow/Keras:

Generador de datos de entrenamiento: Se configuró para aplicar aumentos de datos que incluyeron rotación, zoom y volteo horizontal como lo realizado en (Rizwan Iqbal & Hakim, 2022). Estos aumentos tienen como objetivo mejorar la generalización del modelo al exponerlo a una mayor variedad de variaciones en las imágenes durante el entrenamiento. Generador de datos de validación: A diferencia del generador de entrenamiento, el generador de validación no aplica aumentos, garantizando que las imágenes de validación se mantengan inalteradas para una evaluación precisa del rendimiento del modelo.

Carga y mezcla de datos

Las imágenes fueron cargadas desde el directorio de datos utilizando el generador de datos de entrenamiento. Los datos y etiquetas fueron extraídos, concatenados y mezclados para asegurar que el orden de los datos no introdujera sesgos en el entrenamiento o la validación.

Validación cruzada

Se implementó una validación cruzada utilizando K-Fold con 5 pliegues (Tamayo-Monsalve et al., 2022). Este método asegura una evaluación robusta del modelo al dividir el conjunto de datos en pliegues, entrenar el modelo en k-1 pliegues y validar en el pliegue restante. Esta técnica permite evaluar el rendimiento del modelo en diferentes particiones del conjunto de datos, proporcionando una medida más confiable de su capacidad generalizadora.

Diseño del modelo CNN

Para la clasificación de frutos de aguaymanto, se diseñó un modelo compuesto por varias capas (ver Figura 9) que facilitan la extracción efectiva de características y garantizan una clasificación precisa de las imágenes. El código Python de este modelo se encuentra en el Anexo B. A continuación, se describen los componentes clave de este modelo:

Capas convolucionales: Se utilizaron dos capas convolucionales (Conv2D) con 32 y 64 filtros, respectivamente, utilizando la función de activación Mish. La función primordial de estas capas es la detección de patrones y características en las imágenes de entrada. Cada capa convolucional aplica un conjunto de filtros, también conocidos como kernels, que se deslizan sobre la imagen, llevando a cabo operaciones de convolución. Este proceso permite que la red aprenda características locales, tales como bordes, texturas y formas. La función de activación Mish ha demostrado obtener resultados favorables en estudios recientes (A et al., 2024; Seyrek & Uysal, 2023). Su efectividad se basa en su

capacidad para mejorar el flujo de gradientes y promover la activación no lineal, lo cual contribuye de manera significativa a la optimización del aprendizaje del modelo.

Capas de Max Pooling: Se aplicaron capas de MaxPool2D después de cada capa convolucional, siguiendo lo planteado en (Jahanbakhshi et al., 2021). Esta estrategia permite reducir la dimensionalidad del modelo y capturar las características más relevantes, lo que contribuye a disminuir el sobreajuste y a acortar el tiempo de entrenamiento.

Capas densas: Se incorporó una capa densa compuesta por 256 unidades, utilizando la función de activación Mish, seguida por una capa de salida que emplea softmax, adecuada para la clasificación multiclase. La función softmax permite al modelo predecir la probabilidad de cada clase, asegurando que la suma total de estas probabilidades sea igual a uno (Chen et al., 2021).

Optimización y entrenamiento

El optimizador utilizado fue Adam con una tasa de aprendizaje ajustada mediante un planificador de decaimiento exponencial (ExponentialDecay). Este planificador ajusta la tasa de aprendizaje durante el entrenamiento, empezando con un valor inicial de 0,0001 y reduciéndolo de manera exponencial para mejorar la convergencia del modelo, similar a lo realizado en (Ma et al., 2023)

El modelo fue entrenado durante 10 épocas con un tamaño de lote de 16 imágenes aproximadamente, permitiendo un equilibrio entre la velocidad de entrenamiento y la capacidad del modelo para aprender características significativas.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 224, 224, 32)	896
max_pooling2d (MaxPooling2D)	(None, 112, 112, 32)	0
conv2d_1 (Conv2D)	(None, 112, 112, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 56, 56, 64)	0
flatten (Flatten)	(None, 208704)	0
dense (Dense)	(None, 256)	51,380,480
output (Dense)	(None, 3)	771

Figura 9

Resumen detallado de la arquitectura del modelo CNN

Entrenamiento y evaluación

Durante el entrenamiento, se monitorearon métricas como la precisión, recall, F1-Score y accuracy, lo que permitió realizar ajustes en la arquitectura y en los hiperparámetros, tales como el número de filtros en las capas convolucionales, tasa de aprendizaje y el tamaño de los lotes (batch size).

El análisis de los resultados se basó en las métricas mencionadas, calculadas en cada iteración de la validación cruzada. Para el cálculo de las métricas, se procedió de la siguiente manera:

Precision (Precisión): La precisión mide la proporción de verdaderos positivos entre el total de positivos predichos. Se calcula así:

$$\text{Precision} = \frac{TP}{TP+FP}$$

Donde:

TP = Verdaderos positivos

FP = Falsos positivos

Recall (Sensibilidad o Tasa de Verdaderos Positivos): El recall mide la proporción de verdaderos positivos entre el total de positivos reales. Se calcula así:

$$\text{Recall} = \frac{TP}{TP+FN}$$

Donde:

FN = Falsos negativos

F1-Score: El F1-score es la media armónica entre precisión y recall. Es útil cuando las clases están desbalanceadas. Se calcula así:

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Accuracy (Exactitud): La exactitud mide la proporción de todas las predicciones correctas sobre el total de muestras. Se calcula así:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN}$$

Donde:

TN = Verdaderos negativos

Promedios de métricas: Para obtener los promedios de precisión, recall, F1-score, y accuracy a través de los pliegues de validación cruzada, calculamos la media de estas métricas a lo largo de todos los pliegues.

El entrenamiento del modelo se realizó iterativamente para cada pliegue, ajustando los pesos del modelo en función de los datos aumentados y evaluando su desempeño en el conjunto de validación correspondiente. Se registraron las métricas en cada pliegue, y se calcularon los promedios para obtener una visión global del rendimiento del modelo.

Este enfoque permitió diseñar un modelo robusto y capaz de clasificar de manera efectiva los frutos de aguaymanto en distintas categorías de madurez, considerando tanto las características distintivas de las imágenes como las limitaciones técnicas del problema, como la disponibilidad limitada de datos y la necesidad de un modelo que generalice bien en condiciones reales. La Figura 10 muestra el resumen del procedimiento.

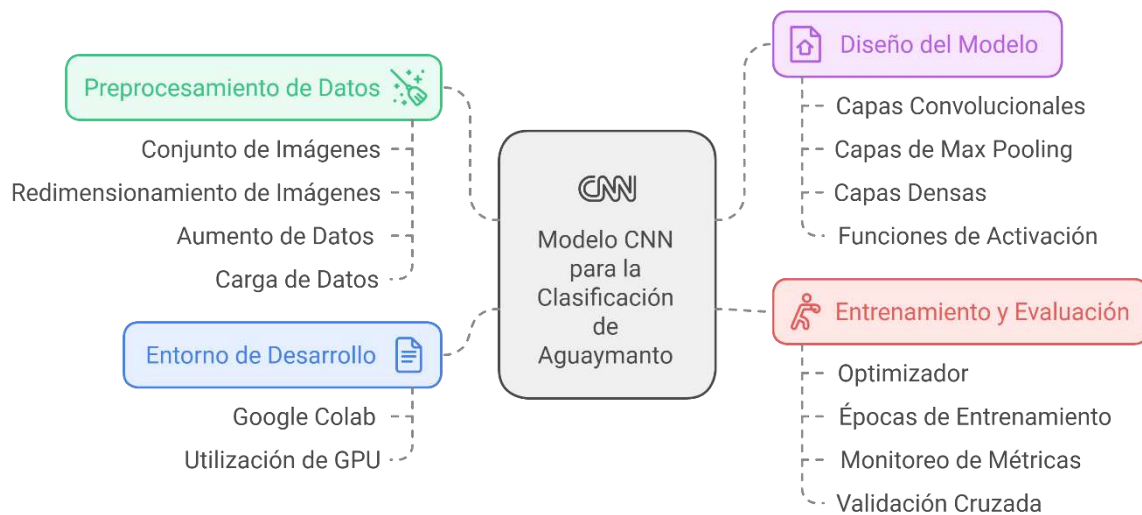


Figura 10
Resumen general del procedimiento del modelo CNN

3.3.3. Objetivo específico 3

Evaluar el rendimiento del modelo propuesto con otros enfoques tradicionales de clasificación de frutos de aguaymanto, utilizando métricas de precisión, eficiencia y confiabilidad.

Para evaluar el rendimiento del modelo de visión artificial basado en redes neuronales convolucionales (CNN) propuesto, se realizó una comparación con algoritmos de clasificación supervisada de clasificación, como **K-Nearest Neighbors (KNN)**, **Support Vector Machines (SVM)** y **Random Forest Classifier (RFC)**. La evaluación se basó en el conjunto de datos de 900 imágenes de frutos de aguaymanto, distribuidas en tres categorías de madurez.

El proceso incluyó los siguientes pasos:

1. **Extracción de características:** Se utilizó la técnica de momentos de color para obtener características de las imágenes, como la media, desviación estándar, asimetría y entropía de los canales de color RGB.
2. **Implementación de modelos tradicionales:** Los enfoques KNN, SVM y RFC se implementaron usando la biblioteca Scikit-learn, ajustando parámetros como el número de vecinos (KNN), el kernel (SVM) y el número de árboles (RFC).
3. **Entrenamiento y validación:** Se empleó validación cruzada K-Fold con 5 pliegues para asegurar una evaluación robusta y confiable. Cada modelo fue entrenado y evaluado con las mismas condiciones y conjunto de datos.
4. **Métricas de rendimiento:** Se calcularon métricas clave como la **precisión**, **recall**, **F1-score** y **exactitud (accuracy)**. Estas métricas permitieron comparar la **eficiencia** (velocidad y recursos utilizados) y la **confiabilidad** (consistencia en los resultados) entre el modelo CNN y los algoritmos de clasificación supervisada.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. Resultado específico 1

Analizar las características distintivas de los frutos de aguaymanto

El análisis de las características de los frutos se centró en la variación del color de la superficie, que fue identificada como el factor más representativo de la madurez, en concordancia con estudios previos (Behera et al., 2021; Taner et al., 2023) que han señalado que la madurez de los frutos generalmente está relacionada con cambios visibles en el color.

Los resultados obtenidos a partir de la clasificación visual de los frutos revelaron que el principal indicador de madurez es la coloración de la epidermis, que cambia gradualmente de un verde intenso (frutos verdes) a un tono anaranjado (frutos maduros), pasando por un estado intermedio de coloración verde-amarillenta (frutos semimaduros). En este proceso, se observó que los frutos inmaduros presentaban una textura más firme y menos rugosa, mientras que los frutos maduros tendían a exhibir una textura más blanda y rugosa.

Dado que nuestro interés es identificar si el fruto está maduro, sin necesidad de distinguir entre los diferentes grados de madurez, se agruparon las muestras utilizando como referencia la norma NTC 4580, tal como se ilustra en la Tabla 3 y la Figura 11. Esta agrupación es fundamental para simplificar el proceso de clasificación. Además, según la investigación realizada por (Barroso et al., 2022), para que el fruto cumpla con los estándares mínimos exigidos para su venta y consumo en estado natural, debe ser recolectado cuando presenta un color completamente amarillo y no presenta visos verdes, a partir de la etapa 4 de la norma NTC 4580. Este criterio es esencial para garantizar la calidad del producto en el mercado.

Tabla 3
Características visuales de los estados de madurez de los frutos de papaya

Estado de maduración	Descripción
Verde	El fruto presenta un color verde.
Parcialmente maduro / Semimaduro	El fruto muestra un color verde en la zona cercana al cáliz, mientras que hacia el centro se observan tonalidades anaranjadas.
Maduro	El fruto exhibe color anaranjado.




Figura 11
Muestras de frutos de aguaymanto en tres estados de madurez

Se logró obtener 300 frutos de cada clase, lo que garantizó un equilibrio adecuado para el entrenamiento y validación del modelo. Cada fruto fue fotografiado en condiciones controladas de iluminación y fondo, de manera que las imágenes capturadas reflejaran de manera precisa las diferencias de color entre las etapas de maduración

Los resultados obtenidos en este análisis confirman que la coloración y textura de los frutos de aguaymanto son indicadores clave del grado de madurez. La clasificación visual, proporciona una base acertada para el desarrollo del modelo de clasificación. Se observa una correlación directa entre los cambios de coloración y la madurez del fruto, lo que respalda el enfoque utilizado para agrupar las etapas de madurez en tres categorías.

Si bien la clasificación en siete etapas podría haber ofrecido mayor detalle, es probable que la inclusión de más categorías hubiera introducido una mayor variabilidad entre clases cercanas, lo que habría complicado el proceso de clasificación sin aportar mejoras significativas al rendimiento del modelo. Además, este enfoque simplificado permitió una reducción en los requerimientos computacionales del modelo CNN, ya que el número de clases a predecir se redujo a tres.

4.2. Resultado específico 2

Diseñar un modelo de visión artificial basado en redes neuronales convolucionales que considere las características clave de los frutos de aguaymanto y las limitaciones técnicas.

Para el diseño del modelo se utilizó la metodología SEMMA (Muestreo, Exploración, Modificación, Modelado y Evaluación). La implementación de SEMMA es fundamental, ya que proporciona un marco estructurado que guía el proceso de desarrollo del modelo, asegurando una adecuada gestión de los datos y la optimización de los parámetros del modelo.

Este enfoque metodológico no solo garantiza una evaluación robusta del modelo, sino que también contribuye a la reproducibilidad de los resultados y a la identificación de áreas de mejora en futuras investigaciones.

1. Muestreo

Se trabajó con un conjunto de datos compuesto por 900 imágenes de frutos de aguaymanto, cuidadosamente capturadas y preparadas para asegurar la calidad del modelo de clasificación. Las imágenes se adquirieron en formato RGB con una resolución de 224x224 píxeles, y se distribuyeron de manera equitativa en tres clases: maduro, semimaduro y verde, con 300 imágenes por categoría.

```
train_datagen = ImageDataGenerator(  
    rotation_range=20,  
    zoom_range=0.2,  
    horizontal_flip=True,  
    preprocessing_function=preprocess_input  
)
```

Esta técnica permitió enriquecer el conjunto de entrenamiento mediante transformaciones geométricas controladas.

2. Exploración

La Tabla 4 muestra los parámetros clave utilizados para optimizar el desempeño del modelo CNN. Estos parámetros fueron fundamentales para explorar diferentes configuraciones durante el proceso de entrenamiento.

Tabla 4
Parámetros críticos para el entrenamiento

Parámetro	Valor	Justificación
Dimensiones	224x224 px	Equilibrio entre detalle y costo computacional
Clases	3	Categorías de madurez identificadas
Épocas	20	Suficiente para convergencia sin sobreajuste
Batch size	16	Optimiza uso de memoria y generalización
K-Folds	5	Validación robusta sin excesivo costo computacional
Learning rate	0.0001	Facilita convergencia estable

Se implementó un scheduler de tasa de aprendizaje con decaimiento exponencial para optimizar el proceso de entrenamiento:

```
lr_schedule = tf.keras.optimizers.schedules.ExponentialDecay(  
    initial_learning_rate=0.0001,  
    decay_steps=300,  
    decay_rate=0.1  
)
```

3. Modificación

Para optimizar el modelo y asegurar su generalización, se implementó una estrategia de validación cruzada con 5-fold. Este método divide el conjunto de datos en 5 pliegues, utilizando cada uno como conjunto de validación en una iteración, mientras que los 4 pliegues restantes se emplean para el entrenamiento. Este proceso se repite 5 veces, garantizando que cada pliegue se utilice como conjunto de validación y permitiendo una evaluación robusta del modelo.

```
kfold = KFold(n_splits=5, shuffle=True, random_state=10)
```

4. Modelado

En cada pliegue de la validación cruzada, se definió una arquitectura CNN usando Sequential con capas convolucionales y de agrupamiento, y una capa densa final con activación softmax para la clasificación en tres categorías. La arquitectura incluye la función de activación Mish en las capas convolucionales y densas intermedias, mientras que la capa de salida emplea softmax. Se usó Adam como optimizador, acompañado de una función de pérdida categorical_crossentropy.

```

model = Sequential([
    Input(shape=(224, 224, 3)),
    Conv2D(32, (3, 3), padding='same', activation=tf.keras.activations.mish),
    MaxPool2D(pool_size=(2, 2)),
    Conv2D(64, (3, 3), padding='same', activation=tf.keras.activations.mish),
    MaxPool2D(pool_size=(2, 2)),
    Flatten(),
    Dense(256, activation=tf.keras.activations.mish),
    Dense(3, activation='softmax', name='output')
])

```

Este modelo se entrenó usando los generadores de datos definidos para el conjunto de entrenamiento y el conjunto de validación en cada pliegue, almacenando las métricas de rendimiento para cada pliegue de forma individual.

5. Evaluación

Tras el entrenamiento en cada pliegue, se realizaron predicciones sobre el conjunto de validación, calculando métricas como precisión, recall, F1-score y se generó una matriz de confusión para evaluar el rendimiento en cada clase. Estas métricas permitieron una visión precisa de las fortalezas y limitaciones del modelo. Finalmente, se promediaron las métricas de todos los pliegues para obtener una evaluación general del modelo CNN.

```

reporte = classification_report(val_true_labels, val_preds_labels, output_dict=True)

```

Se visualizan los resultados de cada pliegue mediante gráficas de precisión y pérdida, generando reportes de clasificación. Finalmente, se calculan las métricas promedio a través de todos los pliegues, proporcionando una evaluación global del rendimiento del modelo.

```

print(f'> Precisión Promedio: {np.mean(precision_por_fold):.4f}')

```

Resultados del modelo CNN

Como se observa en la Tabla 5, se obtuvo una precisión del 99.23%, un accuracy del 99.22%, un recall del 99.22% y un F1-score del 99.22%. Estos resultados indican la capacidad del modelo para clasificar correctamente las imágenes en las tres categorías, con un mínimo de errores.

Tabla 5
Resultados finales del modelo CNN

Métrica	Resultado (%)
Precision	99.23
Recall	99.22
F1-Score	99.22
Accuracy	99.22

La Figura 12 ilustra la matriz de confusión promedio para los tres niveles de madurez evaluados. Esta herramienta visual permite identificar con precisión los errores de clasificación del modelo, así como las clases que presentan mayor dificultad en su discriminación.

Los resultados obtenidos con el modelo CNN propuesto revelan que, en las categorías de frutos "maduros" y "verdes", se observaron clasificaciones erróneas en algunos de los pliegues. Esta confusión puede ser atribuida principalmente a la similitud en la coloración y a ciertas características texturales compartidas entre las clases analizadas.

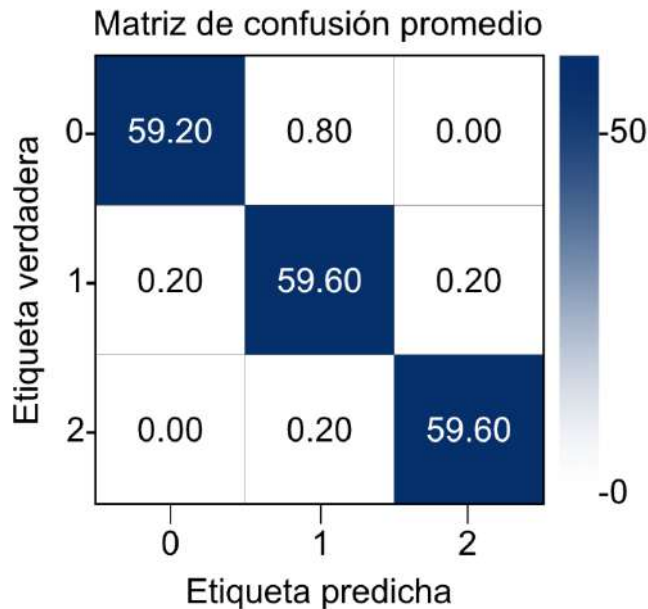


Figura 12
Matriz de confusión promedio del modelo CNN, donde las clases de 0 a 2 representan "Maduro", "Semimaduro" y "Verde", respectivamente

En la Figura 13 se ilustra la evolución de la precisión y la pérdida a lo largo del proceso de entrenamiento en un pliegue, mostrando mejoras significativas en función de las épocas,

tanto en el entrenamiento como en la validación. Esta representación visual permite observar de manera clara las variaciones de estos dos indicadores a medida que avanza el entrenamiento del modelo, facilitando así la evaluación de su desempeño y efectividad.

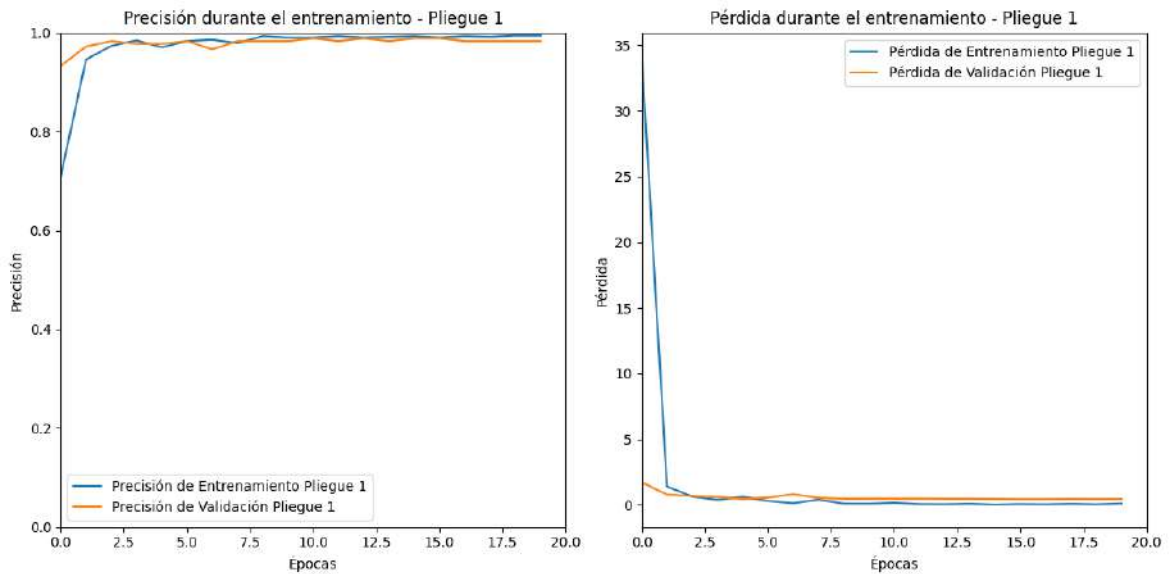


Figura 13

Evolución del entrenamiento y validación de la precisión y pérdida

Se demuestra la eficacia de las CNN para la clasificación de imágenes, resaltando la importancia de la validación cruzada y el aumento de datos en la mejora del rendimiento del modelo. Las métricas obtenidas ofrecen una base sólida para futuras investigaciones y aplicaciones en el campo del aprendizaje profundo.

El diseño y entrenamiento del modelo CNN resultaron en un sistema de clasificación altamente eficiente para los frutos de aguaymanto. Para medir el desempeño del modelo, se emplearon métricas de precisión, recall, F1-Score y accuracy como en (Taner et al., 2023).

Se entrenó utilizando el optimizador Adam con una tasa de aprendizaje adaptativa, ajustada mediante un scheduler basado en decaimiento exponencial. El modelo se entrenó durante 20 épocas, monitoreando el val_loss para evitar el overfitting.

Se calcularon las métricas de precisión, recall, F1-score y accuracy para cada modelo, generándose matrices de confusión para cada pliegue. Además, se calculó el promedio de cada métrica a partir de los 5 pliegues como lo mostrado en la Tabla 2, lo que permitió comparar el rendimiento global del modelo.

Los resultados indican que se obtuvo una precisión del 99.23%, un accuracy del 99.22%, un recall del 99.22% y un F1-score del 99.22%. Este rendimiento superó las expectativas que se tenía, mostrando que el modelo es capaz de identificar con precisión las características visuales clave que distinguen las diferentes etapas de madurez del aguaymanto.

4.3. Resultado específico 3

Evaluar el rendimiento del modelo propuesto con otros enfoques de clasificación de frutos de aguaymanto.

El análisis comparativo del modelo CNN propuesto frente a los algoritmos de clasificación supervisada basados en momentos de color para la extracción de características ha proporcionado resultados concluyentes.

El modelo de CNN ha superado a los enfoques tradicionales en casi todas las métricas evaluadas, si bien la diferencia no ha sido excesivamente amplia. Es decir, los algoritmos de clasificación supervisada basados en momentos de color han mostrado un rendimiento muy competitivo, a pesar de que el modelo de CNN ha logrado un desempeño ligeramente superior.

SVM

La Figura 14 muestra la matriz de confusión promedio obtenida con el modelo SVM. En un conjunto de 180 predicciones, se registró un promedio de 4 clasificaciones incorrectas.

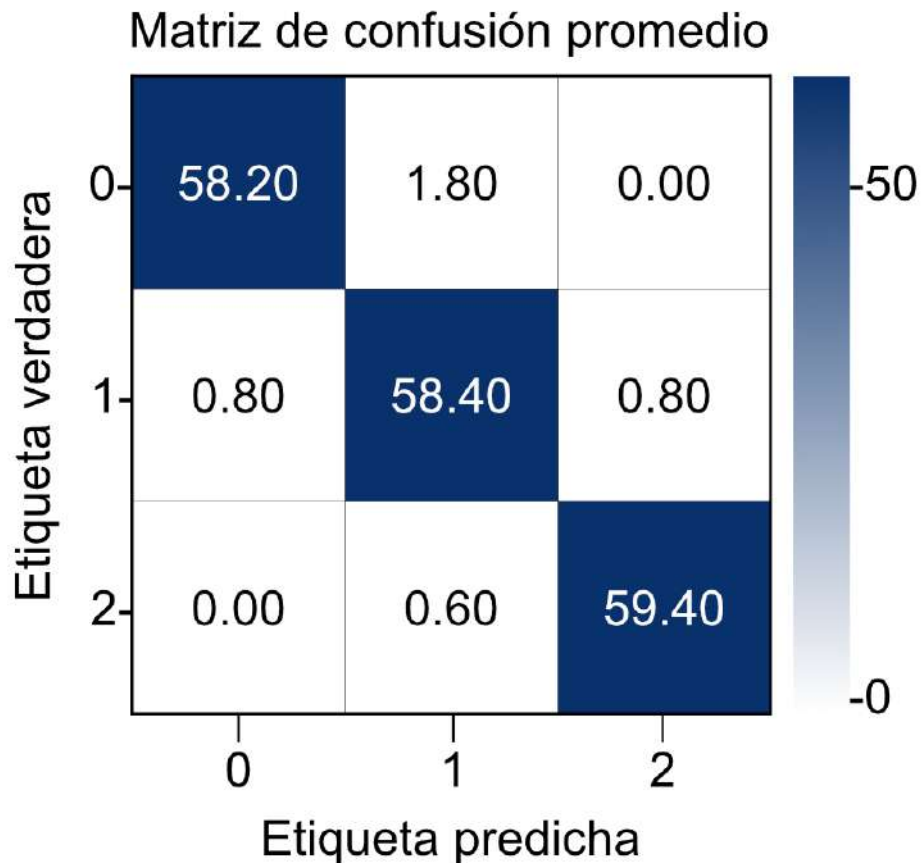


Figura 14
 Matriz de confusión del modelo SVM, donde las clases de 0 a 2 representan “Maduro”, “Semimaduro” y “Verde”, respectivamente

El modelo SVM, utilizando un kernel lineal, alcanzó un accuracy global fue de 97.78% como se muestra en la Tabla 6.

Tabla 6
 Resultados obtenidos con el modelo SVM

Métricas	Resultado (%)
Precision	97.67
Recall	97.76
F1-Score	97.69
Accuracy	97.78

KNN

La Figura 15 muestra la matriz de confusión promedio obtenida con el modelo KNN. En un conjunto de 180 predicciones, se registró un promedio de 3.60 clasificaciones incorrectas.




Figura 15

Matriz de confusión del modelo KNN, donde las clases de 0 a 2 representan "Maduro", "Semimaduro" y "Verde", respectivamente

El modelo KNN, configurado con un valor de $k=5$, logró un accuracy promedio de 98.00% como se muestra en la Tabla 7.

Tabla 7

Resultados obtenidos con el modelo KNN

Métricas	Resultado (%)
Precision	97.97
Recall	98.01
F1-Score	97.97
Accuracy	98.00

RFC

La Figura 16 muestra la matriz de confusión promedio obtenida con el modelo RFC. En un conjunto de 180 predicciones, se registró un promedio de 2.40 clasificaciones incorrectas.




Figura 16
Matriz de confusión del modelo RFC.

Por su parte, el modelo RFC, con 100 árboles, obtuvo una accuracy de 98.67% como se muestra en la Tabla 8.

Tabla 8
Resultados obtenidos con el modelo RFC

Métricas	Resultado (%)
Precision	98.60
Recall	98.66
F1-Score	98.62

Accuracy	98.67
-----------------	-------

Comparación de algoritmos de clasificación supervisada

En la tabla 9 se compara los resultados obtenidos por cada método de clasificación.

Tabla 9
Comparación de métricas entre CNN y enfoques tradicionales

Método	Precision (%)	Recall (%)	F1-Score (%)	Accuracy (%)
CNN	99.23	99.22	99.22	99.22
SVM	97.67	97.76	97.69	97.78
KNN	97.97	98.01	97.97	98.00
RFC	98.60	98.66	98.62	98.67

Comparación de modelos de clasificación para la madurez del fruto de aguaymanto

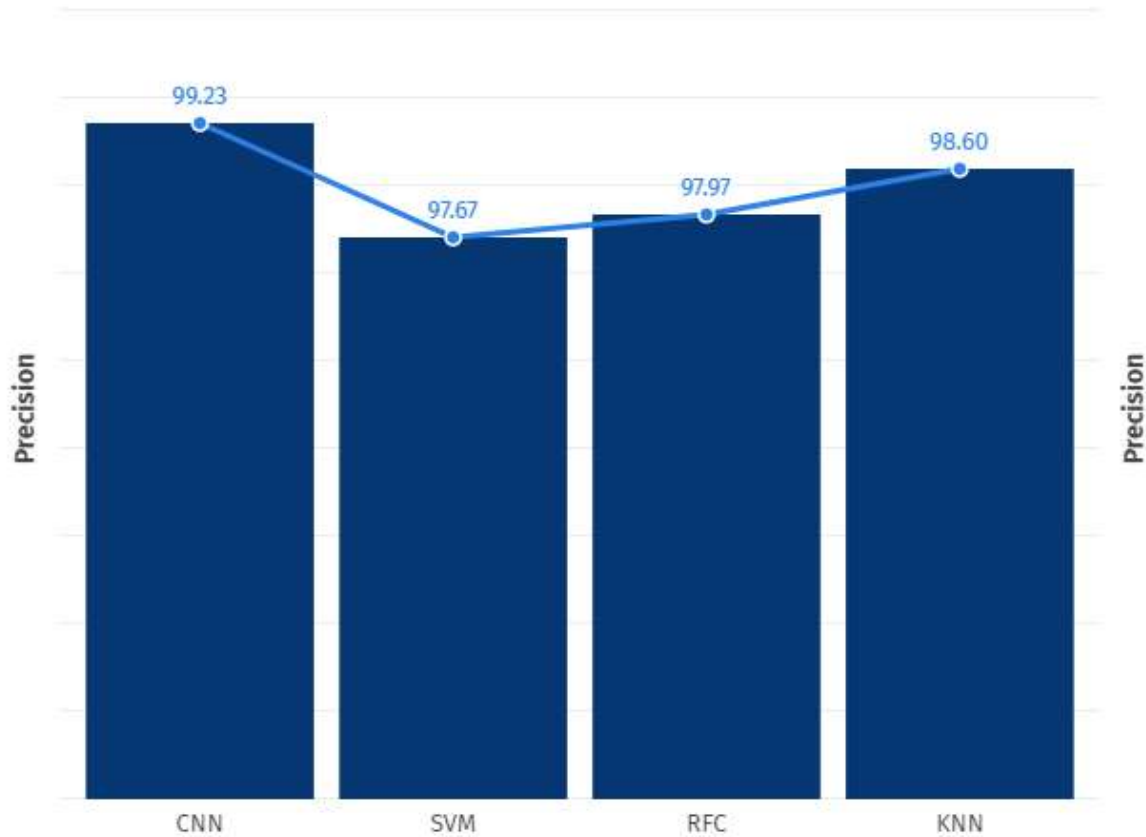


Figura 17
Comparación de precisión de los modelos de clasificación

El modelo CNN logró un accuracy promedio del 99%, mientras que los métodos KNN, SVM y RFC alcanzaron un accuracy del 98%, 98% y 99%, respectivamente. El modelo basado en CNN superó por poco a los enfoques tradicionales en términos de accuracy promedio, precisión y recall. Estos resultados demuestran que la capacidad del CNN para aprender características visuales no lineales permite una clasificación precisa de los frutos de aguaymanto.

En términos de confiabilidad, medida a través del F1-score y el recall, todos los modelos presentaron un buen desempeño. El F1-score del CNN alcanzó 99%, mientras que el de SVM fue 98%, el de RFC 99% y el de KNN 98%. La recall fue igualmente alta en todos los modelos, lo que indica una capacidad para identificar correctamente las instancias positivas en comparación.

4.4. Discusión

Los resultados obtenidos en la investigación destacan la eficacia de las CNN para la clasificación de frutos de aguaymanto en comparación con algoritmos de clasificación supervisada. El modelo CNN mostró un rendimiento superior con una precisión del 99.23%, superando a métodos como K-Nearest Neighbors (KNN) y Support Vector Machines (SVM), cuyos resultados oscilaron entre el 97% y 98% de precisión, de acuerdo con estudios previos como el de (Behera et al., 2021), donde también se observó que las CNN son más efectivas en la clasificación de frutas debido a su capacidad para aprender patrones visuales complejos.

Este hallazgo es consistente con la literatura, en la cual se ha destacado que la madurez de los frutos, que en este caso está determinada principalmente por su coloración, es un factor clave para su clasificación automatizada (Knott et al., 2023; Masuda et al., 2023). Investigaciones similares en otras frutas como las manzanas y las papayas han mostrado resultados comparables cuando se aplican CNN para la clasificación, como se evidencia en el trabajo de (Azadnia et al., 2023), donde se obtuvieron precisiones cercanas al 100%.

No obstante, los algoritmos de clasificación supervisada, como KNN y SVM, aún muestran un rendimiento competitivo. Esto se debe a que, en condiciones controladas como las de este estudio, donde las características visuales de los frutos son homogéneas y se cuenta con un entorno de captura de imágenes optimizado, las diferencias entre los enfoques tradicionales y las CNN son menores. En estudios previos, (Phan et al., 2023) también concluyeron que los algoritmos de clasificación supervisada pueden ser suficientes en contextos donde la variabilidad visual es limitada. Sin embargo, para aplicaciones comerciales a gran escala, donde la variabilidad de las imágenes y las condiciones del entorno son mayores, las CNN ofrecen una ventaja clara debido a su capacidad para generalizar mejor frente a nuevas instancias.

La evaluación de las características distintivas de los frutos de aguaymanto revela que los cambios en la coloración y textura son indicadores precisos de la madurez, lo cual coincide con lo planteado por (Rizwan Iqbal & Hakim, 2022), en su estudio sobre la clasificación de mangos. La precisión del modelo CNN en la identificación de las diferentes etapas de madurez respalda su uso como herramienta de clasificación en la industria agrícola, especialmente en productos con una alta demanda de control de calidad, como lo sugieren (Barhate et al., 2023) en su estudio sobre identificación de especies de plantas.

En términos de implementación, se ha demostrado que la optimización del modelo CNN con técnicas como el ajuste de la tasa de aprendizaje y el uso de funciones de activación avanzadas (e.g., Mish) mejora significativamente su rendimiento, similar a lo encontrado por (A et al., 2024) en el uso de CNN para la clasificación de lesiones cutáneas. Estos ajustes contribuyen no solo a mejorar la precisión del modelo, sino también a reducir el riesgo de sobreajuste, lo cual es crucial en aplicaciones prácticas, como lo ha indicado (Liu & Zhang, 2023) en su trabajo sobre redes neuronales para identificación de servicios en minería.

Los resultados consolidan la eficacia de las CNN en la clasificación de frutos de aguaymanto, especialmente cuando se compara con algoritmos de clasificación supervisada en un entorno controlado. Las investigaciones futuras deberían enfocarse en la evaluación del modelo en condiciones reales de campo y en la mejora de la generalización del modelo mediante la inclusión de conjuntos de datos más diversos, como sugieren (Sabzi et al., 2022) en su trabajo sobre la madurez de manzanas. Esto permitirá validar la aplicabilidad del modelo en escenarios industriales y agrícolas más amplios, optimizando así los procesos de selección y clasificación automatizada en la industria agrícola.

Por otra parte, se muestran una comparación con una investigación similar que utiliza redes neuronales (NN) para la clasificación de aguaymanto empleando el mismo espacio de color (RBG).

Tabla 10
Comparación de accuracy en la clasificación de aguaymanto

Estudio	NN	SVM	KNN
(Nuestro estudio)	99.22	97.78	98.00
(Castro et al., 2019)	85.90	92.47	89.55

Al contrastar los resultados de clasificación de aguaymanto, nuestro estudio alcanzó precisiones superiores (CNN: 99.22%, SVM: 97.78%, KNN: 98.00%) en comparación con Castro et al. (ANN: 85.90%, SVM: 92.47%, KNN: 89.55%). Esta mejora significativa puede atribuirse a la optimización del espacio de color, la implementación de técnicas modernas de aprendizaje profundo, mayor complejidad computacional y un ajuste más preciso de hiperparámetros, aunque factores como la cantidad de muestras y las condiciones de iluminación durante la adquisición de imágenes también podrían haber influido en el rendimiento superior de los clasificadores.

La siguiente tabla compara el accuracy (%) alcanzado en las investigaciones que utilizan CNN para la clasificación de productos agrícolas.

Tabla 11

Comparación de accuracy de diferentes investigaciones que utilizan CNN para clasificación de productos agrícolas

Estudio	Productos agrícolas	Resultado (%)
(Nuestra investigación)	Aguaymanto	99.22
(Tamayo-Monsalve et al., 2022)	Café	100.00
(Sabzi et al., 2022)	Manzanas	97.86
(Azadnia et al., 2023)	Espino	100.00
(Ratha et al., 2023)	Papaya	100.00
(Gulzar, 2023)	Frutas diversas	97.00
(Pipitsunthonsan et al., 2023)	Palma aceitera	90.26
(Cruz-Domínguez et al., 2021)	AjÍ seco	82.13
(Ma et al., 2023)	Mazorcas de maíz	98.56

Es relevante destacar que, a pesar de que las investigaciones previas implementaron modelos pre-entrenados más robustos, nuestros resultados fueron comparables e incluso superiores en algunos casos. Aunque estos estudios difieren en contexto, tamaño muestral y características específicas de las frutas analizadas, proporcionan una perspectiva integral sobre el rendimiento de las CNN en diversos escenarios de clasificación, validando así la eficacia de nuestra metodología.

CONCLUSIONES

Se desarrolló un modelo de visión artificial basado en CNN para la clasificación de frutos de aguaymanto diferenciando entre los estados "maduro", "semimaduro" y "verde", utilizando la variabilidad en la coloración como factor clave.

Se evaluó el rendimiento del modelo mediante técnicas de validación cruzada y aumento de datos, garantizando su robustez, reduciendo el riesgo de sobreajuste y mejorando su capacidad de generalización para clasificar frutos en diferentes condiciones.

El modelo CNN implementado demostró una precisión superior al 99.22% en la clasificación de frutos, superando significativamente enfoques tradicionales como K-NN (98.00%), SVM (97.78%) y RFC (98.67%), validando su efectividad en la clasificación automatizada.

La investigación contribuye al desarrollo de herramientas de visión artificial en agricultura, proporcionando una metodología replicable que puede adaptarse a la clasificación automatizada de diversos tipos de frutos, con potencial de implementación en procesos de selección agrícola.

RECOMENDACIONES

Ampliar el tamaño del dataset utilizado en futuros estudios para mejorar aún más la capacidad de generalización del modelo CNN. Un conjunto de datos más extenso permitiría una mayor variabilidad y diversidad en las imágenes, lo que optimizaría el rendimiento del modelo en escenarios reales.

Implementar técnicas adicionales de aumentación de datos y preprocesamiento de imágenes, como cambios en la iluminación o la rotación de los frutos, para mejorar la robustez del modelo frente a variaciones en las condiciones de captura de las imágenes, como las que pueden encontrarse en ambientes no controlados.

Evaluar el rendimiento del modelo en condiciones de campo o en un entorno industrial real, lo que permitiría validar la aplicabilidad y viabilidad del modelo propuesto en situaciones de uso comercial o productivo.

Realizar estudios comparativos en la clasificación de otros tipos de frutos utilizando el mismo enfoque basado en CNN, con el objetivo de evaluar la aplicabilidad del modelo propuesto en diferentes contextos agrícolas y ampliar su relevancia en la clasificación automatizada de productos agrícolas.

REFERENCIAS BIBLIOGRÁFICAS

- A, R. S., Chamola, V., Hussain, Z., Albalwy, F., & Hussain, A. (2024). A novel end-to-end deep convolutional neural network based skin lesion classification framework. *Expert Systems with Applications*, 246, 123056. <https://doi.org/10.1016/j.eswa.2023.123056>
- Abd El-Wahab, B. S., Nasr, M. E., Khamis, S., & Ashour, A. S. (2023). BTC-fCNN: Fast Convolution Neural Network for Multi-class Brain Tumor Classification. *Health Information Science and Systems*, 11(1), 3. <https://doi.org/10.1007/s13755-022-00203-w>
- Álvarez-Herrera, J. G., Vélez, J. E., & Jaime-Guerrero, M. (2022). Characterization of cape gooseberry (*Physalis peruviana* L.) fruits from plants irrigated with different regimens and calcium doses. *Revista Colombiana de Ciencias Hortícolas*, 16(1). <https://doi.org/10.17584/rcch.2022v16i1.13269>
- Azadnia, R., Fouladi, S., & Jahanbakhshi, A. (2023). Intelligent detection and waste control of hawthorn fruit based on ripening level using machine vision system and deep learning techniques. *Results in Engineering*, 17, 100891. <https://doi.org/10.1016/j.rineng.2023.100891>
- Barhate, D., Pathak, S., & Dubey, A. K. (2023). Hyperparameter-tuned batch-updated stochastic gradient descent: Plant species identification by using hybrid deep learning. *Ecological Informatics*, 75, 102094. <https://doi.org/10.1016/j.ecoinf.2023.102094>
- Barrios, M., Jimeno, M., Villalba, P., & Navarro, E. (2019). Novel Data Mining Methodology for Healthcare Applied to a New Model to Diagnose Metabolic Syndrome without a Blood Test. *Diagnostics*, 9(4), 192. <https://doi.org/10.3390/diagnostics9040192>
- Barroso, N. dos S., Fonseca, J. S. T., Ramos, C. A. da S., Nascimento, M. N. do, Soares, T. L., & Pelacani, C. R. (2022). Impact of the maturity stage on harvest point of fruits and physiological quality of *Physalis peruviana* L. seeds. *Revista Brasileira de Fruticultura*, 44(2). <https://doi.org/10.1590/0100-29452022848>
- Behera, S. K., Rath, A. K., & Sethy, P. K. (2021). Maturity status classification of papaya fruits based on machine learning and transfer learning approach. *Information Processing in Agriculture*, 8(2), 244–250. <https://doi.org/10.1016/j.inpa.2020.05.003>
- Benmouna, B., García-Mateos, G., Sabzi, S., Fernandez-Beltran, R., Parras-Burgos, D., & Molina-Martínez, J. M. (2022). Convolutional Neural Networks for Estimating the Ripening State of Fuji Apples Using Visible and Near-Infrared Spectroscopy. *Food and*

Bioprocess Technology, 15(10), 2226–2236. <https://doi.org/10.1007/s11947-022-02880-7>

Carbajal, Y., Bonilla, H., Siles-Vallejos, M., & López, A. (2021). Citogenética comparativa de *Physalis peruviana* en tres poblaciones cultivadas de Cajamarca, Perú. *Revista Peruana de Biología*, 28(2), e20462. <https://doi.org/10.15381/rpb.v28i2.20462>

Castro, W., Oblitas, J., De-La-Torre, M., Cotrina, C., Bazan, K., & Avila-George, H. (2019). Classification of Cape Gooseberry Fruit According to its Level of Ripeness Using Machine Learning Techniques and Different Color Spaces. *IEEE Access*, 7, 27389–27400. <https://doi.org/10.1109/ACCESS.2019.2898223>

Chakraborty, S. K., A., S., Dubey, K., Jat, D., Chandel, N. S., Potdar, R., Rao, N. R. N. V. G., & Kumar, D. (2023). Development of an optimally designed real-time automatic citrus fruit grading–sorting machine leveraging computer vision-based adaptive deep learning model. *Engineering Applications of Artificial Intelligence*, 120, 105826. <https://doi.org/10.1016/j.engappai.2023.105826>

Chen, Y., Sun, H., Zhou, G., & Peng, B. (2021). Fruit Classification Model Based on Residual Filtering Network for Smart Community Robot. *Wireless Communications and Mobile Computing*, 2021, 1–9. <https://doi.org/10.1155/2021/5541665>

Cruz-Domínguez, O., Carrera-Escobedo, J. L., Guzmán-Valdivia, C. H., Ortiz-Rivera, A., García-Ruiz, M., Durán-Muñoz, H. A., Vidales-Basurto, C. A., & Castaño, V. M. (2021). A novel method for dried chili pepper classification using artificial intelligence. *Journal of Agriculture and Food Research*, 3, 100099. <https://doi.org/10.1016/j.jafr.2021.100099>

Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability*, 15(3), 1906. <https://doi.org/10.3390/su15031906>

Hassan, N. M. H., Ramadan Gamal Elshoky, B., & M. Mabrouk, A. M. (2023). Quality of performance evaluation of ten machine learning algorithms in classifying thirteen types of apple fruits. *Indonesian Journal of Electrical Engineering and Computer Science*, 30(1), 102. <https://doi.org/10.11591/ijeecs.v30.i1.pp102-109>

ICONTEC. (1999). Frutas frescas: uchuva, especificaciones. *ICONTEC*.

Jahanbakhshi, A., Momeny, M., Mahmoudi, M., & Radeva, P. (2021). Waste management using an automatic sorting system for carrot fruit based on image processing technique

and improved deep neural networks. *Energy Reports*, 7, 5248–5256. <https://doi.org/10.1016/j.egyr.2021.08.028>

Knott, M., Perez-Cruz, F., & Defraeye, T. (2023). Facilitated machine learning for image-based fruit quality assessment. *Journal of Food Engineering*, 345, 111401. <https://doi.org/10.1016/j.jfoodeng.2022.111401>

Liu, Y., & Zhang, J. (2023). A lightweight convolutional neural network based on dense connection for open-pit coal mine service identification using the edge-cloud architecture. *Journal of Cloud Computing*, 12(1), 32. <https://doi.org/10.1186/s13677-023-00407-9>

Lu, Z., Zhao, M., Luo, J., Wang, G., & Wang, D. (2021). Design of a winter-jujube grading robot based on machine vision. *Computers and Electronics in Agriculture*, 186, 106170. <https://doi.org/10.1016/j.compag.2021.106170>

Ma, X., Li, Y., Wan, L., Xu, Z., Song, J., & Huang, J. (2023). Classification of seed corn ears based on custom lightweight convolutional neural network and improved training strategies. *Engineering Applications of Artificial Intelligence*, 120, 105936. <https://doi.org/10.1016/j.engappai.2023.105936>

Masuda, K., Uchida, R., Fujita, N., Miyamoto, Y., Yasue, T., Kubo, Y., Ushijima, K., Uchida, S., & Akagi, T. (2023). Application of deep learning diagnosis for multiple traits sorting in peach fruit. *Postharvest Biology and Technology*, 201, 112348. <https://doi.org/10.1016/j.postharvbio.2023.112348>

Mukhiddinov, M., Muminov, A., & Cho, J. (2022). Improved Classification Approach for Fruits and Vegetables Freshness Based on Deep Learning. *Sensors*, 22(21), 8192. <https://doi.org/10.3390/s22218192>

Navarro-Hoyos, M., Arnáez-Serrano, E., Quirós-Fallas, M. I., Vargas-Huertas, F., Wilhelm-Romero, K., Vásquez-Castro, F., Alvarado-Corella, D., & Sánchez-Kopper, A. (2022). QTOF-ESI MS Characterization and Antioxidant Activity of *Physalis peruviana* L. (Cape Gooseberry) Husks and Fruits from Costa Rica. *Molecules*, 27(13), 4238. <https://doi.org/10.3390/molecules27134238>

Phan, Q.-H., Nguyen, V.-T., Lien, C.-H., Duong, T.-P., Hou, M. T.-K., & Le, N.-B. (2023). Classification of Tomato Fruit Using Yolov5 and Convolutional Neural Network Models. *Plants*, 12(4), 790. <https://doi.org/10.3390/plants12040790>

Pipitsunthonsan, P., Pan, L., Peng, S., Khaorapapong, T., Nakasathien, S., Channumsin, S., & Chongcheawchamnan, M. (2023). Palm bunch grading technique using a multi-

- input and multi-label convolutional neural network. *Computers and Electronics in Agriculture*, 210, 107864. <https://doi.org/10.1016/j.compag.2023.107864>
- Qadri, S., Furqan Qadri, S., Razzaq, A., Ul Rehman, M., Ahmad, N., Nawaz, S. A., Saher, N., Akhtar, N., & Khan, D. M. (2021). Classification of canola seed varieties based on multi-feature analysis using computer vision approach. *International Journal of Food Properties*, 24(1), 493–504. <https://doi.org/10.1080/10942912.2021.1900235>
- Ratha, A. K., Barpanda, N. K., Sethy, P. K., & Behera, S. K. (2023). Papaya Fruit Maturity Estimation Using Wavelet and ConvNET. *Ingénierie Des Systèmes d Information*, 28(1), 175–181. <https://doi.org/10.18280/isi.280119>
- Rizwan Iqbal, H. M., & Hakim, A. (2022). Classification and Grading of Harvested Mangoes Using Convolutional Neural Network. *International Journal of Fruit Science*, 22(1), 95–109. <https://doi.org/10.1080/15538362.2021.2023069>
- Rosero Erazo, J. A., Garcia Davila, M. A., Lagos Burbano, T. C., Duarte Alvarado, D. E., & Lagos Santander, L. K. (2022). Aptitud combinatoria del rendimiento en líneas endogámicas de uchuva (*Physalis peruviana* L.). *Acta Agronómica*, 70(4). <https://doi.org/10.15446/acag.v70n4.79049>
- Sabanci, K. (2023). Benchmarking of CNN Models and MobileNet-BiLSTM Approach to Classification of Tomato Seed Cultivars. *Sustainability*, 15(5), 4443. <https://doi.org/10.3390/su15054443>
- Sabzi, S., Nadimi, M., Abbaspour-Gilandeh, Y., & Paliwal, J. (2022). Non-Destructive Estimation of Physicochemical Properties and Detection of Ripeness Level of Apples Using Machine Vision. *International Journal of Fruit Science*, 22(1), 628–645. <https://doi.org/10.1080/15538362.2022.2092580>
- Santa María Pinedo, J. C., Ríos López, C. A., Rodríguez Grández, C., & García Estrella, C. W. (2021). Reconocimiento de patrones de imágenes a través de un sistema de visión artificial en MATLAB. *Revista Científica de Sistemas e Informática*, 1(2), 15–26. <https://doi.org/10.51252/rcsi.v1i2.131>
- Seyrek, E. C., & Uysal, M. (2023). A comparative analysis of various activation functions and optimizers in a convolutional neural network for hyperspectral image classification. *Multimedia Tools and Applications*, 83(18), 53785–53816. <https://doi.org/10.1007/s11042-023-17546-5>

- Shinoda, R., Kataoka, H., Hara, K., & Noguchi, R. (2023). Transformer-based ripeness segmentation for tomatoes. *Smart Agricultural Technology*, 4, 100196. <https://doi.org/10.1016/j.atech.2023.100196>
- Sholehah, D. N., Setiawan, E., Ermavitalini, D., Khasanah, M., Utami, E. S. W., Hariyanto, S., & Purnobasuki, H. (2022). Enhancing fruit quality of three *Physalis* sp. throughout foliar nutrition. *Plant, Soil and Environment*, 68(5), 231–236. <https://doi.org/10.17221/107/2022-PSE>
- Tamayo-Monsalve, M. A., Mercado-Ruiz, E., Villa-Pulgarin, J. P., Bravo-Ortiz, M. A., Arteaga-Arteaga, H. B., Mora-Rubio, A., Alzate-Grisales, J. A., Arias-Garzon, D., Romero-Cano, V., Orozco-Arias, S., Gustavo-Osorio, G., & Tabares-Soto, R. (2022). Coffee Maturity Classification Using Convolutional Neural Networks and Transfer Learning. *IEEE Access*, 10, 42971–42982. <https://doi.org/10.1109/ACCESS.2022.3166515>
- Taner, A., Mengstu, M. T., Selvi, K. Ç., Duran, H., Kabaş, Ö., Gür, İ., Karaköse, T., & Gheorghită, N.-E. (2023). Multiclass Apple Varieties Classification Using Machine Learning with Histogram of Oriented Gradient and Color Moments. *Applied Sciences*, 13(13), 7682. <https://doi.org/10.3390/app13137682>
- Wang, Y., Jin, X., Zheng, J., Zhang, X., Wang, X., He, X., & Polovka, M. (2023). An energy-efficient classification system for peach ripeness using YOLOv4 and flexible piezoelectric sensor. *Computers and Electronics in Agriculture*, 210, 107909. <https://doi.org/10.1016/j.compag.2023.107909>
- Zhang, C., Lu, X., Ma, H., Hu, Y., Zhang, S., Ning, X., Hu, J., & Jiao, J. (2023). High-Throughput Classification and Counting of Vegetable Soybean Pods Based on Deep Learning. *Agronomy*, 13(4), 1154. <https://doi.org/10.3390/agronomy13041154>

ANEXOS

Anexo A. Evaluación de diversos entornos de captura para reducir los reflejos no deseados y obtener imágenes con mayor uniformidad y equilibrio tonal



Anexo B. Código del modelo CNN en Python

```
1 from tensorflow.keras.preprocessing.image import ImageDataGenerator
2 from tensorflow.keras.models import Sequential
3 from tensorflow.keras import Input
4 from tensorflow.keras.layers import Conv2D, MaxPool2D, Flatten, Dense, Activation
5 from tensorflow.keras import optimizers
6 from tensorflow.keras.applications.imagenet_utils import preprocess_input
7 from sklearn.model_selection import KFold
8 from sklearn.utils import shuffle
9 import numpy as np
10 import tensorflow as tf
11 from sklearn.metrics import classification_report, accuracy_score, precision_score, recall_score, f1_score, confusion_matrix, ConfusionMatrixDisplay
12 import matplotlib.pyplot as plt
13 import seaborn as sns
14
15 # Semilla
16 seed = 18
17 tf.random.set_seed(seed)
18
19 # Parámetros
20 ancho = 224
21 alto = 224
22 num_clases = 3
23 epocas = 20
24 tamaño_lote = 16
25 num_folds = 5 # Folds
26 ini_lr = 0.0001
27
28 # Scheduler, para reducir la tasa de aprendizaje exponencialmente
29 lr_schedule = tf.keras.optimizers.schedules.ExponentialDecay(
30     initial_learning_rate=ini_lr,
31     decay_steps=300,
32     decay_rate=0.1
33 )
34
35
36 directorio_dataset = '/content/drive/MyDrive/pruebas'
37
38 # Generador de imágenes con aumento de datos para entrenamiento
39 train_datagen = ImageDataGenerator(
40     rotation_range=20,
41     zoom_range=0.2,
42     horizontal_flip=True,
43     preprocessing_function=preprocess_input
44 )
45
46 # Generador de imágenes para validación (sin aumento)
47 val_datagen = ImageDataGenerator(
48     preprocessing_function=preprocess_input
49 )
50
51 # Se carga y lista imágenes del directorio
52 all_data_generator = train_datagen.flow_from_directory(
53     directorio_dataset,
54     target_size=(ancho, alto),
55     batch_size=tamaño_lote,
56     class_mode='categorical',
57     shuffle=False
58 )
59
60 # Obtener los datos y las etiquetas
61 data, labels = [], []
62 for i in range(len(all_data_generator)):
63     batch_data, batch_labels = all_data_generator[i]
64     data.append(batch_data)
65     labels.append(batch_labels)
66
67 data = np.concatenate(data)
68 labels = np.concatenate(labels)
69
70 # Mezclar datos y etiquetas
71 data, labels = shuffle(data, labels, random_state=seed)
72
73 # Inicializar KFold
74 kfold = KFold(n_splits=num_folds, shuffle=True, random_state=seed)
75
76 acc_por_fold = []
77 loss_por_fold = []
78
```

```

79
80 # Obtener los nombres de las clases desde el generador
81 class_names = list(all_data_generator.class_indices.keys())
82
83 # Almacenar resultados por pliegue
84 historia_por_fold = []
85 precision_por_fold = []
86 recall_por_fold = []
87 f1_score_por_fold = []
88 accuracy_por_fold = []
89 clasificacion_reports = []
90 matrices_confusion = []
91
92
93 for fold_index, (train_index, val_index) in enumerate(kfold.split(data)):
94     print(f'Entrenando en el pliegue {fold_index + 1}/{num_folds}...')
95
96     model = Sequential([
97         Input(shape=(alto, ancho, 3)),
98         Conv2D(32, (3, 3), padding='same', activation=tf.keras.activations.mish),
99         MaxPool2D(pool_size=(2, 2)),
100        Conv2D(64, (3, 3), padding='same', activation=tf.keras.activations.mish),
101        MaxPool2D(pool_size=(2, 2)),
102        Flatten(),
103        Dense(256, activation=tf.keras.activations.mish),
104        Dense(num_clases, activation='softmax', name='output')
105    ])
106
107 # Reinicializar el optimizador
108 optimizer = optimizers.Adam(learning_rate=lr_schedule)
109 model.compile(loss='categorical_crossentropy', optimizer=optimizer, metrics=['accuracy'])
110
111 # Dividir los datos según los índices de KFold
112 train_data, train_labels = data[train_index], labels[train_index]
113 val_data, val_labels = data[val_index], labels[val_index]
114
115 # Crear generadores para entrenamiento y validación con generadores separados
116 train_generator = train_datagen.flow(train_data, train_labels, batch_size=tamano_lote, shuffle=True)
117 val_generator = val_datagen.flow(val_data, val_labels, batch_size=tamano_lote, shuffle=False)
118
119
120 # Entrenar el modelo
121 historia_modelo = model.fit(
122     train_generator,
123     epochs=epocas,
124     validation_data=val_generator
125 )
126
127 # Guardar la historia del entrenamiento
128 historia_por_fold.append(historia_modelo.history)
129
130 # Predecir en el conjunto de validación
131 val_preds = model.predict(val_generator)
132 val_preds_labels = np.argmax(val_preds, axis=1)
133 val_true_labels = np.argmax(val_labels, axis=1)
134
135 # Generar reporte de clasificación
136 reporte = classification_report(val_true_labels, val_preds_labels, output_dict=True)
137 clasificacion_reports.append(reporte)
138

```

```

139 # Calcular y almacenar métricas
140 accuracy_por_fold.append(accuracy_score(val_true_labels, val_preds_labels))
141 precision_por_fold.append(precision_score(val_true_labels, val_preds_labels, average='weighted'))
142 recall_por_fold.append(recall_score(val_true_labels, val_preds_labels, average='weighted'))
143 f1_score_por_fold.append(f1_score(val_true_labels, val_preds_labels, average='weighted'))
144
145 # Calcular y almacenar matriz de confusión
146 matriz_confusion = confusion_matrix(val_true_labels, val_preds_labels)
147 matrices_confusion.append(matriz_confusion)
148
149 # Mostrar la matriz de confusión para el pliegue actual con nombres de clases
150 plt.figure(figsize=(6, 6))
151 sns.heatmap(matriz_confusion, annot=True, fmt="d", cmap="Blues", xticklabels=class_names, yticklabels=class_names)
152 plt.title(f'Matriz de Confusión - Pliegue {fold_index + 1}')
153 plt.ylabel('Etiqueta Verdadera')
154 plt.xlabel('Etiqueta Predicha')
155 plt.show()
156
157 # Mostrar el reporte de clasificación para el pliegue actual
158 print(f'Reporte de Clasificación para el pliegue {fold_index + 1}:')
159 print(reports)
160
161 print(f'Pliegue {fold_index + 1} ⇒ Accuracy: {accuracy_por_fold[-1] * 100}%')
162
163 # Visualización del historial de entrenamiento para todos los pliegues
164 for i, historia in enumerate(historia_por_fold):
165     plt.figure(figsize=(12, 6))
166
167     # Precisión de Entrenamiento y Validación
168     plt.subplot(1, 2, 1)
169     plt.plot(historia['accuracy'], label=f'Precisión de Entrenamiento Pliegue {i+1}')
170     plt.plot(historia['val_accuracy'], label=f'Precisión de Validación Pliegue {i+1}')
171     plt.xlabel('Épocas')
172     plt.ylabel('Precisión')
173     plt.title(f'Precisión durante el entrenamiento - Pliegue {i+1}')
174     plt.ylim([0, 1])
175     plt.xlim([0, epocas])
176     plt.legend()
177
178     # Pérdida de Entrenamiento y Validación
179     plt.subplot(1, 2, 2)
180     plt.plot(historia['loss'], label=f'Pérdida de Entrenamiento Pliegue {i+1}')
181     plt.plot(historia['val_loss'], label=f'Pérdida de Validación Pliegue {i+1}')
182     plt.xlabel('Épocas')
183     plt.ylabel('Pérdida')
184     plt.title(f'Pérdida durante el entrenamiento - Pliegue {i+1}')
185     plt.xlim([0, epocas])
186     plt.legend()
187
188     plt.tight_layout()
189     plt.show()
190
191 # Mostrar promedios finales de precisión, recall, f1-score, y accuracy
192 print('-----')
193 print('Promedios de todos los pliegues:')
194 print(f'> Precisión Promedio: {np.mean(precision_por_fold):.4f}')
195 print(f'> Recall Promedio: {np.mean(recall_por_fold):.4f}')
196 print(f'> F1-Score Promedio: {np.mean(f1_score_por_fold):.4f}')
197 print(f'> Accuracy Promedio: {np.mean(accuracy_por_fold) * 100:.2f}%')
198 print('-----')
199
200 # Matriz de confusión promedio
201 matriz_confusion_promedio = np.mean(matrices_confusion, axis=0)
202
203 plt.figure(figsize=(6, 6))
204 sns.heatmap(matriz_confusion_promedio, annot=True, fmt=".2f", cmap="Blues")
205 plt.title('Matriz de Confusión Promedio')
206 plt.ylabel('Etiqueta Verdadera')
207 plt.xlabel('Etiqueta Predicha')
208 plt.show()

```

Modelo de visión artificial basada en redes neuronales convolucionales para la clasificación de frutos de aguaymanto

por Hector Saavedra Caballero

Fecha de entrega: 21-ago-2025 08:52a. m. (UTC-0500)

Identificador de la entrega: 2732882130

Nombre del archivo: Tesis_-_Héctor_Luis_08.08.2025-Corregido_2_1_.docx (5.29M)

Total de palabras: 12636

Total de caracteres: 73908

Modelo de visión artificial basada en redes neuronales convolucionales para la clasificación de frutos de aguaymanto

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	repositorio.unsm.edu.pe Fuente de Internet	2%
2	tesis.unsm.edu.pe Fuente de Internet	2%
3	repositorio.uss.edu.pe Fuente de Internet	1%
4	Submitted to Universidad Nacional Jorge Basadre Grohmann Trabajo del estudiante	1%
5	dspace.unl.edu.ec Fuente de Internet	1%
6	Submitted to ucol Trabajo del estudiante	<1%
7	repositorio.chapingo.edu.mx Fuente de Internet	<1%
8	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1%