



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 identificación de mazorca negra en plantaciones de cacao

Para optar el título profesional de Ingeniero de Sistemas e Informática

Autor:

Cristian Villalobos Culqui

<https://orcid.org/0009-0004-7990-1975>

Asesor:

Ing. Dr. Miguel Angel Valles Coral

<https://orcid.org/0000-0002-8806-2892>

Tarapoto, Perú

2024



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 identificación de mazorca negra en plantaciones de cacao

Para optar el título profesional de Ingeniero de Sistemas e Informática


Autor:

Cristian Villalobos Culqui

Sustentado y aprobado el 19 de diciembre del 2024, por los siguientes jurados



Presidente de Jurado
Ing. Dr. Jorge Damián Valverde
Iparraguirre



Secretario de Jurado
Ing. Dr. Juan Carlos García
Castro



Vocal de Jurado
Ing. Dr. Juan Orlando Riascos
Armas



Asesor
Ing. Dr. Miguel Angel Valles Coral

Tarapoto, Perú

2024



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



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

Resolución N° 38-2024-UNSM/FISI-D (16.12.2024)

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

A las 10:00 horas del día Jueves, 19 de diciembre del año 2024, se inició el acto público de sustentación de la tesis titulada **MODELO DE VISIÓN ARTIFICIAL BASADA EN REDES NEURONALES CONVOLUCIONALES PARA IDENTIFICACIÓN DE MAZORCA NEGRA EN PLANTACIONES DE CACAO**; presentado por **CRISTIAN VILLALOBOS CULQUI**, con el Asesor: Ing. Dr. Miguel Ángel Valles Coral.

Instalado los miembros de jurado calificador conformado por:

Presidente : Ing. Dr. JORGE DAMIAN VALVERDE IPARRAGUIRRE
Secretario : Ing. Dr. JUAN CARLOS GARCÍA CASTRO
Vocal : Ing. Dr. JUAN ORLANDO RIASCOS ARMAS

El presidente del jurado dirigió brevemente unas palabras y a continuación el secretario dio lectura a la Resolución N° 38-2024-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 *diecinueve (19)*.

De acuerdo con el Artículo 40° del RG – CTI, la nota obtenida es *aprobado* y correspondiente a la calificación de *no apto*; 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 11.32 horas, el mismo día 19 de diciembre del 2024.

Ing. Dr. JORGE DAMIAN VALVERDE
IPARRAGUIRRE
Presidente

Ing. Dr. JUAN CARLOS GARCÍA
CASTRO
Secretario

Ing. Dr. MIGUEL ÁNGEL VALLES
CORAL
Asesor

Ing. Dr. JUAN ORLANDO RIASCOS
ARMAS
Vocal

CRISTIAN VILLALOBOS CULQUI
Autor

Declaratoria de autenticidad

Yo, **Cristian Villalobos Culqui**, identificado con DNI N° **75501303**, egresado de la Escuela Profesional de Ingeniería de Sistemas e Informática, de la Universidad Nacional de San Martín, con la tesis titulada: **Modelo de visión artificial basada en redes neuronales convolucionales para identificación de mazorca negra en plantaciones de cacao.**

Declaro bajo juramento que:

- 1) La tesis presentada es de mi autoría.
- 2) He respetado las normas internacionales de citas y referencias para las fuentes consultadas. Por tanto, la tesis no ha sido plagiada ni total ni parcialmente.
- 3) La tesis no ha sido auto plagiado; es decir, no ha sido publicada ni presentada anteriormente para obtener algún grado académico previo o título profesional.
- 4) Los datos presentados en los resultados son reales, no han sido falseados, ni duplicados, ni copiados y por tanto los resultados que se presenten en la tesis se constituirán en aportes a la realidad investigada.

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

Tarapoto, 19 de diciembre de 2024



Cristian Villalobos Culqui
DNI N° 75501303

Ficha de identificación

<p>Título del proyecto Modelo de visión artificial basada en redes neuronales convolucionales para identificación de mazorca negra en plantaciones de cacao</p>	<p>Área de investigación: Ciencias naturales Línea de investigación: Ciencias de la computación Sublínea de investigación: Inteligencia artificial y recuperación de la Información Grupo de investigación (indicar resolución): Tipo de investigación: GIA- Resolución N° 166–2023–UNSM/FISI/CFT Básica <input type="checkbox"/>, Aplicada <input checked="" type="checkbox"/>, Desarrollo experimental <input type="checkbox"/></p>
<p>Autor: Cristian Villalobos Culqui</p>	<p>Facultad de Ingeniería de Sistemas e Informática Escuela Profesional de Ingeniería de Sistemas e Informática https://orcid.org/0009-0004-7990-1975</p>
<p>Asesor: Ing. Dr. Miguel Angel Valles Coral</p>	<p>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/0000-0002-8806-2892</p>

Dedicatoria

A mis queridos padres, cuyos valores, apoyo incondicional y amor han sido la fuente de mi inspiración y determinación en este camino académico. A mis amados hermanos, quienes han sido mi fuente de fortaleza y alegría a lo largo de esta travesía.

El autor

Agradecimientos

A mis padres, agradezco su apoyo inquebrantable, tanto emocional como financiero, que hizo posible este proyecto. A mis hermanos, por su constante ánimo. Y a mi asesor de tesis, Dr. Miguel Angel Valles Coral, por su guía experta. Cada uno de ustedes ha sido esencial en el éxito de este proyecto de tesis. Gracias por ser mi pilar fundamental.

El autor

Índice general

Ficha de identificación.....	6
Dedicatoria	7
Agradecimientos	8
Índice general.....	9
Índice de tablas	11
Índice de figuras.....	12
RESUMEN	13
ABSTRACT	14
CAPÍTULO I INTRODUCCIÓN A LA INVESTIGACIÓN	15
CAPÍTULO II MARCO TEÓRICO	18
2.1. Antecedentes de la investigación.....	18
2.2. Fundamentos teóricos.....	20
CAPÍTULO III MATERIALES Y MÉTODOS	28
3.1. Ámbito y condiciones de la investigación	28
3.1.1. Contexto de la investigación.....	28
3.1.2. Periodo de ejecución	28
3.1.3. Autorizaciones y permisos.....	28
3.1.4. Control ambiental y protocolos de bioseguridad.....	28
3.1.5. Aplicación de principios éticos internacionales.....	29
3.1. Sistema de variables	29
3.3 Procedimientos de la investigación.....	29
3.3.1 Objetivo específico 1	31
3.3.2 Objetivo específico 2	33
3.3.3 Objetivo específico 3	35
CAPÍTULO IV RESULTADOS Y DISCUSIÓN	36
4.1 Resultado específico 1	36
4.2 Resultado específico 2	38
4.3 Resultado específico 3	43

CONCLUSIONES	53
RECOMENDACIONES	54
REFERENCIAS BIBLIOGRÁFICAS	55
ANEXOS.....	62

Índice de tablas

Tabla 1 <i>Descripción de variable por objetivo general</i>	29
Tabla 2 <i>Descripcion de parcelas para la recolección de imágenes</i>	31
Tabla 3 <i>Etiquetado de imágenes</i>	32
Tabla 4 <i>Métricas según grupo de evaluación</i>	49
Tabla 5 <i>Resultados de la prueba ANOVA</i>	49
Tabla 6 <i>Estadísticos descriptivos</i>	50
Tabla 7 <i>Aplicacion de la prueba post-hoc TUKEY</i>	50

Índice de figuras

Figura 1	<i>Arquitectura típica de una red neuronal YOLOv8.</i>	22
Figura 2	<i>Representación esquemática de VGG19.</i>	23
Figura 3	<i>Representación esquemática de Inception V3. Fuente</i>	23
Figura 4	<i>Representación física de frutos infectados por mazorca negra.</i>	25
Figura 5	<i>Imágenes que conforman el Dataset</i>	30
Figura 6	<i>Representación esquemática de la captura de imagen en un fruto de cacao</i>	32
Figura 7	<i>contraste entre el aprendizaje tradicional vs el de transferencia.</i>	33
Figura 8	<i>Imágenes preprocesadas</i>	38
Figura 9	<i>Métricas del entrenamiento (InceptionV3)</i>	42
Figura 10	<i>Métricas del entrenamiento (VGG19).</i>	43
Figura 11	<i>Matriz de confusión (YOLOv8)</i>	46
Figura 12	<i>Matriz de confusión (InceptionV3).</i>	46
Figura 13	<i>Matriz de confusión (VGG19).</i>	47
Figura 14	<i>Curva ROC para clasificación multiclase (YOLOv8).</i>	47
Figura 15	<i>Curva ROC para clasificación multiclase (InceptionV3).</i>	48
Figura 16	<i>Curva ROC para clasificación multiclase (VGG19)</i>	48
Figura 17	<i>Proceso de recolección de imágenes de frutos de cacao infectados</i>	62
Figura 18	<i>Identificación frutos de cacao con las diversas etapas de la enfermedad</i>	62
Figura 19	<i>Capturando imágenes de cacao infectados por la enfermedad (Etapa 1).</i>	63
Figura 20	<i>Capturando imágenes de cacao infectados por la enfermedad (Etapa 4).</i>	63
Figura 21	<i>Capturando imágenes de cacao saludable.</i>	64

RESUMEN

Modelo de visión artificial basada en redes neuronales convolucionales para identificación de mazorca negra en plantaciones de cacao

La identificación y diagnóstico de la enfermedad de la mazorca negra en las plantaciones de cacao es uno de los principales problemas que enfrenta el sector agrícola, esta afección causa pérdidas en el rendimiento y calidad del grano, y se suma a la falta de métodos sofisticados para detectarla en etapas tempranas. El presente trabajo de investigación tiene como objetivo mejorar la detección de esta enfermedad mediante el desarrollo de modelos de visión artificial basados en redes neuronales convolucionales (CNN). Para ello, se recopilaron y etiquetaron un total de 1982 imágenes de mazorcas afectadas, obtenidas de cinco parcelas ubicadas en el sector Shitarillo, distrito de Alto Saposa, provincia de Huallaga, San Martín. El periodo de ejecución del proyecto comprendió la recolección de datos y el desarrollo de los modelos durante un lapso de 9 meses. Se construyeron tres modelos principales utilizando las arquitecturas YOLOv8, InceptionV3 y VGG19, aplicando técnicas de transferencia de aprendizaje para mejorar la precisión en la clasificación. Los modelos fueron entrenados y evaluados con un diseño experimental factorial, empleando un 70% de las imágenes para entrenamiento, 20% para validación y 10% para pruebas. Los resultados indicaron que los modelos YOLOv8 e InceptionV3 lograron una precisión promedio del 79% en la detección de la mazorca negra, superando significativamente al modelo VGG19. Las métricas de evaluación como precisión, exactitud, F1, recall, Kappa de Cohen y área bajo la curva ROC confirmaron la eficacia de YOLOv8 e InceptionV3. La prueba ANOVA y la prueba de Tukey revelaron que VGG19 tuvo un rendimiento significativamente inferior, mientras que no se encontraron diferencias significativas entre YOLOv8 e InceptionV3. Esto demuestra que ambos modelos son adecuados para la implementación en sistemas de detección temprana de enfermedades en plantaciones de cacao, con YOLOv8 siendo ligeramente superior en cuanto a robustez y exactitud.

Keywords: Early detection, Deep learning models, Image analysis, Automatic classification, Precision agriculture

ABSTRACT

Computer vision model based on convolutional neural networks for black pod disease identification in cocoa plantations.

The identification and diagnosis of black pod disease in cocoa plantations is one of the main problems faced by the agricultural sector, this condition causes losses in the yield and quality of the bean, and adds to the lack of sophisticated methods to detect it in early stages. The present research work aims to improve the detection of this disease by developing computer vision models based on convolutional neural networks (CNN). For this purpose, a total of 1982 images of affected pods, obtained from five plots located in the Shitarillo sector, Alto Saposoa district, Huallaga province, San Martín, were collected and labeled. The project period included data collection and model development over a period of 9 months. Three main models were built using YOLOv8, InceptionV3 and VGG19 architectures, applying transfer learning techniques to improve classification accuracy. The models were trained and evaluated with a factorial experimental design, using 70% of the images for training, 20% for validation and 10% for testing. The results indicated that the YOLOv8 and InceptionV3 models achieved an average accuracy of 79% in black cob detection, significantly outperforming the VGG19 model. Evaluation metrics such as precision, accuracy, F1, recall, Cohen's Kappa and area under the ROC curve confirmed the efficacy of YOLOv8 and InceptionV3. ANOVA and Tukey's test revealed that VGG19 significantly underperformed, while no significant differences were found between YOLOv8 and InceptionV3. This demonstrates that both models are suitable for implementation in early disease detection systems in cocoa plantations, with YOLOv8 being slightly superior in terms of robustness and accuracy.

Keywords: Early detection, Deep learning models, Image analysis, Automatic classification, Precision agriculture



CAPÍTULO I

INTRODUCCIÓN A LA INVESTIGACIÓN

El *Theobroma cacao* L, comúnmente conocido como cacao, es un cultivo de enorme relevancia en países subdesarrollados (Palacios Bejarano et al., 2021), sus granos son utilizados para la elaboración de chocolates, bebidas, refrescos, helados, dulces y otros alimentos (Kumi et al., 2022). Una de sus enfermedades más comunes, llamada, pudrición negra de la vaina, ocasiona pérdidas anuales de producción de hasta el 80%. (Franco et al., 2019) y es de vital importancia detectarla a tiempo y tratarla de manera efectiva (Gyamfi et al., 2020).

En Perú (MIDAGRI, 2022) el 87.3% de la producción de cacao proviene de Ucayali (9.8%), Junín (19.9%), San Martín (39.1%), Cusco y Amazonas (18.5%). Sin embargo, se observo fluctuaciones significativas debido a variaciones ocasionadas por enfermedades (Sociedad et al., 2020). San Martín, región líder con 28 984 hectáreas (Fachin et al., 2019) ha experimentado su crecimiento sostenido en los últimos años, superando al arroz, café y palma aceitera (INEI, 2022). Sin embargo, su sostenibilidad enfrenta desafíos importantes, como la presencia de la "pudrición parda" causada por el hongo *Phytophthora palmivora*, preocupación constante para los agricultores quienes deben desarrollar su habilidad visual para reconocer la enfermedad en etapas iniciales (Fachin et al., 2019). Esto muestra los desafíos que enfrenta su producción.

El principal problema que esta investigación abordo es la ineficacia de los procesos de inspección visual y morfológica en la identificación de la mazorca negra del cacao. Uno de los elementos que influyen en esta situación problemática es la complejidad para entender sus síntomas visibles patológicos (Picon et al., 2019), ya que la precisión de esta evaluación puede verse comprometida debido a sesgos en su calificación visual, especialmente cuando es realizada por agricultores jóvenes (Mashood Nasir et al., 2021; Mohammad Yazdi Pusadan et al., 2022). A pesar de que algunos expertos podrían ofrecer una evaluación más precisa, el proceso de contacto con ellos suele ser prolongado. (Pandian et al., 2022; Singh et al., 2020) además que se trata de un método crítico y costoso (Almadhor et al., 2021; Khattak et al., 2021).

Otro causante primordial es la diversidad en sus síntomas, lo que puede provocar su propagación diversa (Ahmad et al., 2023) y disminución en producción y calidad (Barburiceanu et al., 2021). La identificación visual resulta compleja debido a la amplia variabilidad en su expresión morfológica (Baculio & Barbosa, 2022; H. Li et al., 2022),

que esta influenciada por factores como, tipo de cacao, condiciones ambientales e interacciones biológicas (Mzoughi & Yahiaoui, 2023). Estos factores sumados a la falta de dispositivos tecnológicos precisos y efectivos para identificar la aparición temprana de la enfermedad (Basri et al., 2020; Samuel, 2022) Suponen un riesgo preocupante para su producción.

Las causas mencionadas anteriormente pueden conducir a una identificación inexacta de la enfermedad, ya que el reconocimiento convencional se basa en inspecciones visuales fenotípicas llevada a cabo por agricultores o expertos en el área. (Roy et al., 2021). Esto genera una disminución significativa en la calidad y producción del cacao (Che'Ya et al., 2022), lo que, a su vez, puede afectar negativamente la reputación de los productores y el valor comercial de su producto, reduciendo así su competitividad en el mercado global.

Una consecuencia adicional es la aplicación indiscriminada de fungicidas (L. Li et al., 2021), lo cual puede llevar al desarrollo de resistencia por parte de la planta a estos productos químicos, esto a su vez disminuye significativamente la eficacia de los tratamientos para combatirlos (Jackulin & Murugavalli, 2022) sin embargo, además de dañar la calidad de las plantas también genera pérdida de recursos (Khalid et al., 2023). Estas consecuencias pueden tener implicaciones adversas para la salud de las poblaciones locales, los ecosistemas circundantes y la economía de la población (Boateng et al., 2023).

La principal barrera para encontrar una solución viable a la problemática se encuentra en la limitación financiera de los agricultores, dado que una gran mayoría no cuenta con medios suficientes para adquirir tecnologías avanzadas (Mushi et al., 2022). Esta condición empeora aún más en países en desarrollo, donde la carencia de apoyo económico por parte de los gobiernos hacia el sector agrícola es deficiente, y su baja productividad limita aún más el poder adquisitivo de los agricultores.

Entonces, nos planteamos la pregunta: ¿Existen diferencias significativas en la precisión de los modelos de redes neuronales convolucionales para la detección de la mazorca negra en plantaciones de cacao en la región San Martín?

Con la finalidad de responder a la pregunta nos planteamos el objetivo general y sus respectivos objetivos específicos:

OG: Mejorar la detección temprana de la mazorca negra en plantaciones de cacao en la región San Martín.

OE1: Diseñar un protocolo para la obtención y etiquetado de un conjunto de datos de imágenes de mazorca negra en plantaciones de cacao.

OE2: Construir y entrenar modelos de visión artificial basada en redes neuronales convolucionales para la clasificación de la mazorca negra en plantaciones de cacao.

OE3: Evaluar y comparar el rendimiento de los modelos de visión artificial basados en redes neuronales convolucionales propuestos durante la clasificación de imágenes de mazorca negra en plantaciones de cacao.

El presente proyecto de investigación se encuentra organizado en tres secciones principales: En el primer capítulo, se exponen los antecedentes de la investigación, las bases teóricas y se definen los conceptos esenciales. El segundo capítulo abarca la descripción del tipo de investigación, su nivel y diseño, la población y muestra involucradas, así como las técnicas y la validación de los instrumentos de recolección de datos, además de los métodos utilizados para procesar y analizar la información. Finalmente, el tercer capítulo se dedica a la presentación de los resultados y la discusión de estos en relación con los objetivos planteados. Finalmente, se incluyen las conclusiones, las recomendaciones, las referencias bibliográficas y los anexos respectivos.

CAPÍTULO II

MARCO TEÓRICO

2.1. Antecedentes de la investigación

Internacional. Lomotey et al. (2024) en su artículo titulado “Detección y diagnóstico automático de enfermedades del cacao mediante tecnología móvil y aprendizaje profundo,” abordaron la problemática de las enfermedades en el cultivo de cacao en Ghana. Su investigación se centró en el desarrollo de una aplicación móvil que emplea técnicas de aprendizaje automático para la detección temprana y diagnóstico de las principales enfermedades del cacao, como el brote hinchado y la mazorca negra, responsables de hasta un 11% de pérdida en la cosecha. Utilizaron redes neuronales convolucionales (CNN) para el análisis y clasificación de 2,828 imágenes de cacao distribuidas en tres etiquetas de clase, desarrollaron y entrenaron cuatro modelos CNN: CentreNet ResNet50 V2, EfficientDet D0, SSD MobileNet V2, y SSD ResNet50 V1 FPN. Sus resultados indicaron que el modelo SSD MobileNet V2 fue el más eficiente, logrando un índice de confianza del 88% en la detección de enfermedades. La aplicación, además, sugiere tratamientos basados en una guía informativa incorporada, demostrando la eficacia de la tecnología móvil y el aprendizaje profundo en la gestión de enfermedades en cultivos de cacao.

En Estados Unidos, Kumi et al. (2022) en su artículo titulado “Cocoa Companion: Aplicación para teléfonos inteligentes basada en aprendizaje profundo para la detección de enfermedades del cacao” propusieron el uso de métodos de aprendizaje automático para identificar la aparición temprana y el diagnóstico de las dos enfermedades principales que afectan la producción de cacao, que son: brote hinchado y vaina negra. En este sentido, diseñaron una aplicación móvil con un servicio de back-end en la nube para otorgar la capacidad a los agricultores de tomar una fotografía de la mazorca de cacao y cargarla para su diagnóstico respectivo. Para el análisis y clasificación de imágenes construyeron y entrenaron cuatro modelos de redes neuronales convolucionales (CNN): CenterNet, ResNet50 V2, EfficientDet D0, SSD MobileNet V2 y SSD ResNet50. Obteniendo como resultado que el modelo con mejor rendimiento fue SSD MobileNet V2 con una puntuación de detección de confianza superior al 80 %.

En Turquía, un estudio de Atila et al. (2021) titulado “Clasificación de enfermedades de las hojas de las plantas utilizando el modelo de aprendizaje profundo EfficientNet” muestran la utilización de la arquitectura de aprendizaje profundo EfficientNet en la

clasificación de enfermedades en hojas de plantas. El rendimiento de este modelo se comparó con otros modelos de aprendizaje profundo de vanguardia como son AlexNet, ResNet50, VGG16 e Inception V3, utilizando la dataset PlantVillage se entrenaron tanto modelos originales como aumentados, que consistieron en conjuntos de imágenes con 55,448 y 61,486 muestras, respectivamente. Los resultados que obtuvieron en los datos de prueba revelaron que los modelos B5 y B4 de EfficientNet alcanzaron los valores más altos en comparación con otros modelos de aprendizaje profundo. Se lograron tasas de precisión de 99.91% y 99.97% para los modelos B5 y B4, respectivamente, en el conjunto de datos original, y del 98.42% y 99.39%, respectivamente, en el conjunto de datos aumentado. Los resultados encontrados destacan el excelente rendimiento de EfficientNet en la clasificación de enfermedades en hojas de plantas.

Otra investigación titulada “Clasificación de la vaina de cacao si está sana o atacada por plaga o enfermedad de la vaina negra mediante un algoritmo de aprendizaje profundo” desarrollada por Godmalin et al. (2022) propusieron la utilización de un algoritmo de aprendizaje profundo específicamente EfficientNetB0, para la clasificación automatizada de las condiciones de las mazorcas de cacao en tres categorías: salud, ataque de enfermedad de la vaina negra y ataque de plagas. Utilizaron un método de diseño de investigación experimental y una red neuronal convolucional para el entrenamiento. Los resultados mostraron que el modelo puede clasificar tres condiciones de una imagen de vaina de cacao determinada: sana, ataque de enfermedad de la vaina negra y ataque de plagas. En condiciones controladas, el modelo clasifica correctamente la condición de la mazorca de cacao con una precisión del 94%. Los autores destacaron la eficacia de EfficientNetB0 en esta tarea.

Nacional. En un estudio titulado “Un estudio comparativo sobre clasificación de plantas utilizando arquitecturas de redes neuronales convolucionales” realizado por Bermejo & Alzamora (2022) evaluaron y compararon varios modelos de aprendizaje por transferencia, como Alexnet, VGG-16, ResNet-18, ResNet-50, DenseNet e Inception V3, para la clasificación de especies de plantas. Utilizaron dos conjuntos de datos, el conjunto de datos de la Amazonía forestal peruana y PlantVillage, y evaluaron los modelos utilizando métricas multiclase como exactitud, sensibilidad, precisión y F-score. Los resultados mostraron que el modelo VGG-16 obtuvo una precisión del 97,79%, sensibilidad del 98,00%, precisión del 98,00% y F-score del 98,00% para el conjunto de datos de la Amazonía Forestal Peruana. Por lo tanto, su modelo se destaca como el más efectivo en la clasificación de especies de plantas.

Iparraquirre-Villanueva et al. (2023), en su estudio llamado "Identificación de enfermedades en plantas de cultivo basada en redes neuronales convolucionales" Utilizaron las CNN con transferencia de aprendizaje para identificar y clasificar enfermedades en plantas de cultivos. Para el procesamiento utilizaron el dataset compuesto por más de 87 mil imágenes obtenidas de Plant Village, divididas en 38 clases y 26 tipos de enfermedades. Para la identificación y clasificación de imágenes emplearon tres modelos de CNN (DenseNet-201, ResNet-50 e Inception-v3). Sus resultados mostraron que los modelos DenseNet-201 e Inception-v3 lograron una precisión del 98 % ligeramente superior al modelo ResNet-50, que logró una precisión del 97 %. Para los autores este enfoque demostrado es eficaz y prometedor ya que se obtiene una precisión de más del 96 % con grandes conjuntos de datos.

2.2. Fundamentos teóricos

2.2.1. Visión Artificial

Se define como el campo de la informática que engloba métodos y técnicas para la construcción y aplicación de sistemas de visión artificial en aplicaciones prácticas. Esto incluye el uso de software, hardware y técnicas de imagen necesarios para estos sistemas (Patricio & Rieder, 2018). Esta disciplina busca replicar la capacidad del sistema visual humano utilizando técnicas y algoritmos computacionales. Analiza imágenes digitales para extraer información y realizar tareas de reconocimiento, detección y clasificación de objetos.

2.2.2. Redes neuronales convolucionales (CNN)

Son una arquitectura de aprendizaje profundo que se inspira en el mecanismo de percepción visual natural (Gu et al., 2018). Estas redes destacan por su capacidad para analizar patrones y objetos complejos en datos de gran magnitud. Su estructura se basa en capas convolucionales que aprenden y optimizan características directamente de los datos de entrada (Kiranyaz et al., 2021).

De manera similar, Ayon et al. (2021) manifiesta que las CNN están compuestas por múltiples capas, donde la salida de una capa se utiliza como entrada para la siguiente. Estas capas procesan imágenes al convertirlas en vectores y luego se utilizan en una red neuronal de alimentación hacia adelante. Durante el entrenamiento, se utiliza la propagación hacia atrás para analizar y corregir errores, ajustando los pesos en las capas ocultas para minimizar el error. Este proceso se repite en cada iteración hasta que se alcanza la salida deseada.

Al recibir imágenes como entrada, las CNN descubren una serie de características dentro de cada imagen y, basándose en estas características, pueden distinguir una imagen de otra. Esta capacidad las convierte en una herramienta poderosa en el procesamiento de datos visuales, como la identificación de la mazorca negra del cacao.

2.2.3. Modelos de redes neuronales convolucionales

2.2.3.1. YOLOv8 (You Only Look Once) v8

YOLOv8 es la versión más reciente de la serie YOLO, diseñada para la detección de objetos en tiempo real, destacándose por su precisión y velocidad. Incorpora mejoras como arquitecturas avanzadas de espina dorsal y cuello, que optimizan la extracción de características, y un cabezal dividido sin anclajes Ultralytics, que incrementa la precisión y eficiencia en la detección. Además, YOLOv8 logra un equilibrio entre precisión y rapidez, siendo ideal para diversas aplicaciones. También ofrece una variedad de modelos preentrenados que se adaptan a diferentes necesidades y requisitos de rendimiento. (ultralytics, 2024)

Este modelo avanzado para la detección de objetos que podría ser muy eficaz para identificar la enfermedad de la mazorca negra en plantaciones de cacao. Su capacidad de procesamiento en tiempo real lo hace adecuado para su uso directamente en el campo, y a diferencia de modelos como VGG16, YOLOv8 combina la detección y clasificación en un único proceso. No obstante, este modelo necesita un conjunto de datos más amplio para su entrenamiento y puede exigir más recursos computacionales en dispositivos móviles. Las pruebas muestran que YOLOv8 puede alcanzar una precisión superior al 90% en la detección de ciertas enfermedades, pero es esencial ajustar el modelo a los datos específicos del cacao. YOLOv8 podría proporcionar un enfoque más eficiente y preciso para identificar la mazorca negra, aunque con mayores demandas de recursos. (V. & Kumar, 2024)

Es un algoritmo de detección de objetos que identifica y localiza objetos en imágenes en tiempo real. Utilizando técnicas como Entropía Cruzada Binaria (BCE) para clasificación, Pérdida Profunda de Características (DFL) para la regresión de cuadros delimitadores, y Intersección sobre Unión Completa (CIoU) para evaluar el ajuste de los cuadros. Su rendimiento se optimiza ajustando parámetros como el optimizador, la tasa de aprendizaje, el número de épocas, el tamaño de imagen, el tamaño del lote y la función de pérdida, combinando estas pérdidas ponderadas durante el entrenamiento (Chitranningrum et al., 2024).

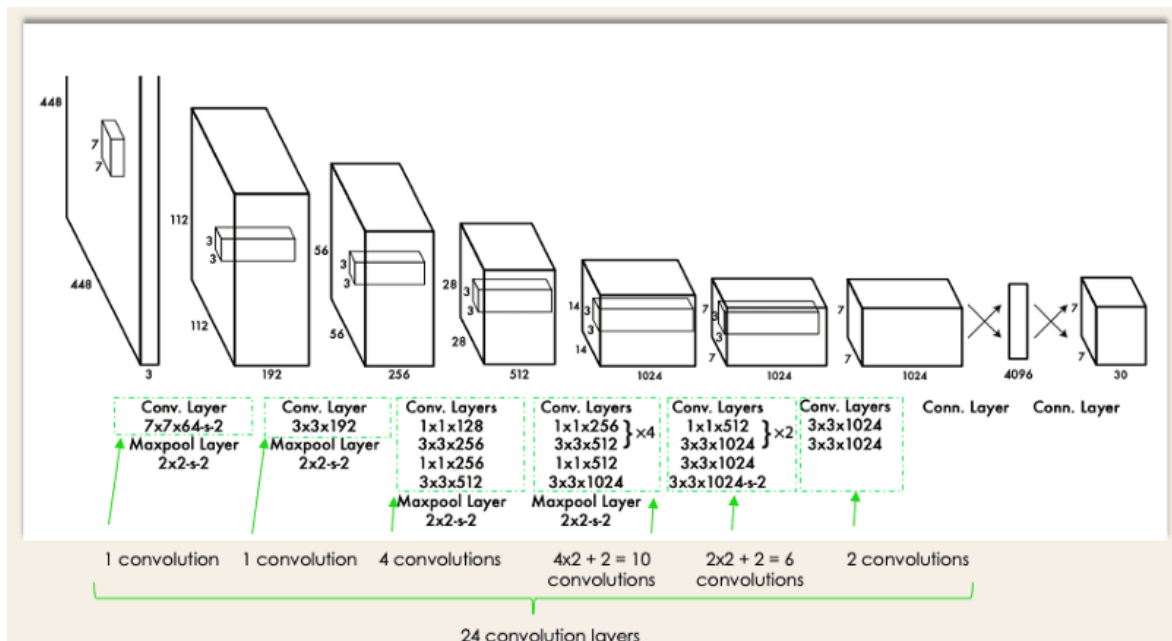


Figura 1

Arquitectura típica de una red neuronal YOLOv8.

Fuente: Tomado de (V. & Kumar, 2024)

2.2.3.2. VGG 19 (Visual Geometry Group 19)

VGG19 es una arquitectura de aprendizaje profundo que forma parte de la serie VGG (Visual Geometry Group) desarrollado en la universidad de Oxford. Se caracteriza por su profundidad y precisión en tareas de clasificación de imágenes.

El modelo VGG-19 comprende 19 capas, basado en la arquitectura VGG que utiliza cinco conjuntos de capas de convolución con núcleos de tamaño 3x3. Después de cada capa de convolución, se aplica la función de activación ReLU, seguida de una capa de agrupación máxima con núcleos de tamaño 2x2 para reducir la dimensión espacial. En la parte final del modelo, se encuentran tres capas completamente conectadas, las dos primeras con 4096 unidades y la última con 1000 unidades y función de activación softmax (Roopashree & Anitha, 2021).

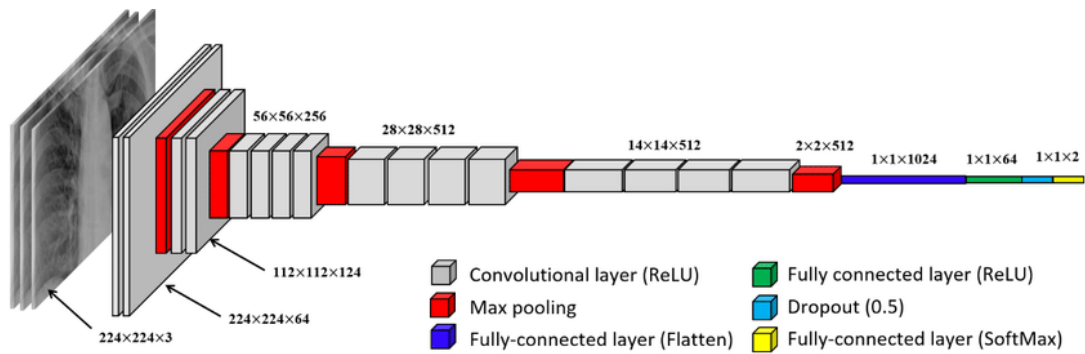


Figura 2
Representación esquemática de VGG19
Fuente: Google Cloud

2.2.3.3. Inception V3

Inception v3, desarrollado por Google, es la tercera versión de la serie de arquitecturas evolutivas de Deep Learning. En el transcurso de su desarrollo como modelo de aprendizaje profundo se introdujeron mejoras en cada versión empezando con Inception V1, seguida de Inception V2, que implementó la normalización por lotes. Luego, en Inception V3, abarcó la idea de factorización para menorar la cantidad de conexiones y parámetros sin comprometer la eficiencia de la red. La arquitectura de Inception v3 consta de un total de 42 capas. La capa de entrada acepta imágenes de 299x299 píxeles. Además, la última capa utiliza la función Softmax para la clasificación (Atila et al., 2021).




Figura 3
Representación esquemática de Inception V3. Fuente
Fuente: Google Cloud

2.2.4. Aumento de datos

El aumento de datos es una técnica que consiste en generar nuevos ejemplos de entrenamiento a partir de los datos existentes mediante la aplicación de transformaciones o perturbaciones a las imágenes originales. Esto implica rotaciones, cambios de escala, traslaciones, cambios de iluminación y otras variaciones. Esta técnica permite al modelo aprender características más robustas y generalizables al exponerlo a una mayor variabilidad en los datos de entrenamiento. De esta manera el modelo se vuelve más eficiente en reconocer y clasificar correctamente nuevas instancias que no forman parte del conjunto de datos original (Jaiswal, 2021).

2.2.5. Aprendizaje por transferencia

Es un enfoque efectivo que aplica el conocimiento previamente adquirido en un área específica para mejorar el aprendizaje en otra. Este enfoque permite reducir los costos de anotación manual y el tiempo de computación en el conjunto de datos del dominio de destino (Yang et al., 2021). El aprendizaje por transferencia puede aplicarse en diferentes cultivos, logrando reducir el tiempo de capacitación hasta en un 80% (Bosilj et al., 2020). Además, se ha utilizado con éxito en la identificación de enfermedades en plantas, obteniendo altos niveles de precisión y recuperación. En general, el aprendizaje por transferencia tiene un gran potencial en el fenotipado de plantas, al reducir el costo de anotación de datos y acelerar el proceso de entrenamiento en nuevas tareas.

2.2.6. Cacao

El cacao (*Theobroma cacao*) constituye una de las plantaciones más significativas a nivel global. Sus árboles producen vainas de forma ovalada o alargada, dentro de las cuales se encuentran las semillas o granos de cacao. Este producto se cultiva en regiones tropicales y subtropicales, principalmente en América Latina, África occidental y Asia. Su producción mundial se estima en millones de toneladas cada año (Zuidema et al., 2005).

2.2.7. Mazorca negra en plantaciones de cacao

Es también conocida como pudrición negra de la vaina del cacao, Constituye una enfermedad causada por hongos del género *Phytophthora* spp. afecta principalmente a las vainas de cacao, aunque también puede observarse en otras partes del árbol. Es notable por la manifestación de lesiones pequeñas, duras y oscuras en la superficie de las vainas. Y su propagación es rápida ya que en 11 días desde la infección puede dañar completamente los tejidos de la vaina. Esta enfermedad es altamente devastadora y puede causar pérdidas significativas en su producción. Se estima que representa hasta

el 90% de las pérdidas en la producción a gran escala, generando impactos económicos muy significativos (Tan et al., 2018).



Figura 4
Representación física de frutos infectados por mazorca negra.
Fuente: Google Cloud

2.2.8. Identificación de la mazorca negra en plantaciones de cacao.

Este proceso se realiza mediante inspección visual de las vainas de cacao. Es decir, se buscan signos y síntomas característicos de la enfermedad, como lesiones pequeñas, duras y oscuras en la superficie de las vainas. Estas lesiones suelen ser evidentes y pueden extenderse rápidamente si la infección está presente. Sin embargo, la identificación visual puede ser subjetiva y propensa a errores humanos. Por lo tanto, Una estrategia eficaz para este proceso es utilizar métodos de procesamiento de imágenes y modelos de aprendizaje profundo para identificar los síntomas iniciales y los niveles de infección de los frutos del cacao (Tan et al., 2016). De esta manera obtener una mayor precisión y menor proporción de error. Esto proporciona una herramienta más efectiva para los agricultores contribuyendo así a una mejor producción de cacao.

2.2.9. Métricas de rendimiento.

Son medidas empleadas para examinar y cuantificar el comportamiento de un modelo o algoritmo en tareas de clasificación, regresión u otras aplicaciones de aprendizaje automático. Proporcionan información objetiva sobre el desempeño de las predicciones llevadas a cabo por el modelo. (Ayikpa et al., 2023; Maeda-Gutiérrez et al., 2020) muestran la importancia de evaluar las siguientes métricas:

- **Precisión:** Constituye la relación entre los casos correctos positivos y el total de casos clasificados como positivos y negativos.
- **Coeficiente F1:** Es una métrica que fusiona la precisión y la sensibilidad en un único valor, especialmente útil cuando existe un desequilibrio entre las clases de datos.

- Exactitud: Es la proporción de número de casos correctamente clasificados con relación al total de casos.
- Kappa de Cohen: Es una medida de la concordancia entre las clasificaciones observadas y las clasificaciones esperadas por azar.
- Recall: Mide la proporción de casos positivos reales que han sido correctamente identificados por el modelo, reflejando su capacidad para detectar todos los casos positivos.
- Área bajo la curva ROC: Representa la habilidad del modelo para distinguir entre clases positivas y negativas, donde un valor más alto indica un mejor rendimiento en la clasificación.
- Matriz de confusión: Es una tabla que muestra el número de casos clasificados correcta e incorrectamente para cada clase, permitiendo evaluar el desempeño del modelo en términos de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos.

2.2.10. Conjunto de Datos

El término "conjunto de datos" se refiere a la colección de imágenes de frutos de cacao utilizadas para el reconocimiento de características y la identificación de enfermedades, como la mazorca negra de cacao. Este conjunto incluye tanto datos de entrenamiento como datos de prueba, y se divide en conjuntos específicos de frutos de cacao normales y afectados por enfermedades. Las imágenes en el conjunto de datos están organizadas por categoría según el nivel de infección. Por lo general, los conjuntos de datos son extensos, lo que mejora el entrenamiento de los modelos de visión artificial y, a su vez, genera resultados de clasificación de enfermedades más precisos (Basri et al., 2018).

2.2.11. Procesamiento de imágenes.

Abarca la aplicación de un conjunto de técnicas y algoritmos con el fin de mejorar, analizar y extraer información de las imágenes digitales. Consiste en la manipulación y análisis de estas imágenes para obtener resultados deseados, como la optimización de la nitidez de la imagen, la extracción de características relevantes y la realización de tareas específicas. En el contexto del procesamiento de imágenes de frutos de cacao, se emplean enfoques basados en redes neuronales convolucionales (CNN) para la realización de tareas, tales como la segmentación de los frutos en una imagen, la clasificación según su estado de salud, la medición de distancias y otros análisis relevantes (Naranjo-Torres et al., 2020).

Otro aspecto fundamental en este proceso es la eliminación del ruido de la imagen, que se manifiesta como variaciones aleatorias en los valores de los píxeles, lo que provoca una degradación visual, reducción de la claridad y distorsión de los detalles. En ese sentido para (Liu et al., 2018) el objetivo del procesamiento de imágenes en relación con el ruido es eliminar o reducir al mínimo estas perturbaciones aplicando técnicas y algoritmos específicos como filtrado, suavizado, eliminación de artefactos y restauración de detalles, con el fin de mejorar la legibilidad, el contraste y la precisión de la información visual contenida en la imagen.

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1. Ámbito y condiciones de la investigación

3.1.1. Contexto de la investigación

La investigación se llevo a cabo en el sector shitarillo perteneciente al distrito de alto Saposoa, provincia de Huallaga departamento de San Martin, Perú. Caracterizada por su ubicación en la selva alta de los Andes peruanos, con una altitud promedio de 420 metros sobre el nivel del mar. Fundado el 13 de septiembre de 1963 durante el gobierno del presidente Fernando Belaúnde Terry. Alto Saposoa con su capital Pasarraya opera como un distrito del Perú, regido por las leyes y regulaciones nacionales y regionales, con su propia estructura de gobierno local encabezada por un alcalde y un concejo municipal, donde la economía local está estrechamente relacionada con la agricultura.

3.1.2. Periodo de ejecución

El proyecto se desarrolló en el período comprendido entre octubre de 2023 y Julio de 2024.

3.1.3. Autorizaciones y permisos

En esta investigación, no existen limitaciones en cuanto al acceso y manipulación de los materiales utilizados como parte del estudio, ya que no están sujetos a ninguna regulación a nivel nacional, regional o local. A pesar de ello se han obtenido los permisos pertinentes de los dueños de las parcelas de cacao, asegurando la disponibilidad de acceso a los terrenos y la captura de imágenes de los frutos en las plantaciones de cacao que serán empleadas como muestras en esta investigación, lo que permite una total libertad en la recopilación y manipulación de los datos y muestras necesarios para el desarrollo de la investigación.

3.1.4. Control ambiental y protocolos de bioseguridad

El proyecto no genera impactos ambientales negativos ni implica una interacción física significativa entre las personas involucradas. Dado que la captura de las imágenes de los frutos en las plantaciones de cacao se realizó al aire libre en un espacio abierto, solamente se siguieron protocolos básicos de bioseguridad para garantizar que la salud y el bienestar de los involucrados no corra peligro, por lo tanto, no se requiere implementar controles ambientales ni normas de bioseguridad adicionales, ya que no se compromete la salud de quienes participan en el desarrollo de la investigación.

3.1.5. Aplicación de principios éticos internacionales

Los resultados de esta investigación no causan daño a ninguna persona o grupo en particular. Respetándose aspectos fundamentales tales como credibilidad, autenticidad y legitimidad destacándose el respeto a la propiedad intelectual al citar adecuadamente las contribuciones de teorías y definiciones tomadas de diferentes autores, siguiendo las normas establecidas por APA. Además, se espera que este estudio sea útil para otros investigadores, ya que busca ofrecer una solución a un problema común en el campo de la agricultura con la aplicación de la ciencia y tecnología.

3.1. Sistema de variables

La operacionalización de la variable se muestra en la siguiente tabla:

Tabla 1

Descripción de variable por objetivo general

Objetivo General: Mejorar la detección temprana de la mazorca negra en plantaciones de cacao en la región San Martín.

Variable	Indicadores	Medio de registro	Unidad de medida
Clasificación de la mazorca negra en plantaciones de cacao	Exactitud	Informe	Numérico
	Coeficiente F1	Informe	Numérico
	Precisión	Informe	Numérico
	Recall	Informe	Numérico
	Kapa de Cohen	Informe	Numérico
	Area bajo la curva ROC	Informe	Numérico
	Matriz de confusión	Informe	Numérico

3.3 Procedimientos de la investigación

a. Tipo y nivel de la investigación.

La investigación es de tipo aplicada ya que está dirigida hacia la solución de problemas prácticos y específicos en áreas delineadas (Maurice Eyssautier de la Mora, 2006) para términos de este estudio se aplico conocimientos teóricos y prácticos de procesamiento de imágenes utilizando técnicas de visión artificial y métodos de reconocimiento de patrones con el fin de dar solución a un problema específico, la detección de la mazorca negra en plantaciones de cacao, mediante la construcción y evaluación de modelos de reconocimiento de patrones visuales empleando CNN existentes previamente entrenadas que contribuyeron en el proceso de reconocimiento temprano y preciso de esta enfermedad.

El alcance de este estudio es de nivel descriptivo, ya que su objetivo principal es describir el comportamiento de los modelos propuestos en la detección de la mazorca negra en plantaciones de cacao empleando un conjunto de datos equilibrado.

El enfoque metodológico utilizado en esta investigación se basó en un diseño experimental factorial ya que se manipularon las variables independientes (indicadores de desempeño) para examinar los efectos en la clasificación de la mazorca negra en plantaciones de cacao. Buscando analizar tanto los efectos individuales de cada indicador de desempeño como las posibles interacciones entre ellos.

b. Población y muestra

La población está integrada por imágenes provenientes de una única fuente: Dataset constituido con fotografías tomadas por un teléfono móvil. Las imágenes recolectadas son tanto de frutos sanos como infectados por la mazorca negra en sus cuatro estadios u etapas (etapa uno, dos, tres y cuatro). A su vez cuentan con etiquetas correspondientes para su correcta identificación.

Para lograr la precisión del modelo, se tomó como muestra la totalidad de las imágenes seleccionadas. Esta se dividió en tres partes: el 70% se empleó para entrenar los modelos propuestos, el 20% para la validación y el 10% para su diagnóstico posterior. En la asignación de la muestra, se aplicó un método de muestreo no probabilístico que se basó en las características del estudio en lugar de la probabilidad (Tutz, 2023). En ese sentido el conjunto de datos utilizó clasificar las imágenes en cinco categorías diferentes según las etapas de la vaina negra: Etapa 1, Etapa 2, Etapa 3, Etapa 4, y también incluye imágenes de frutos de cacao saludables.



Figura 5
Imágenes que conforman el Dataset

c. Diseño analítico, muestral y experimental

Con el objetivo de llevar a cabo este estudio, se empleó un conjunto de datos equilibrado compuesto por imágenes de frutos, tanto infectados por la mazorca negra del cacao como saludables. En total, se utilizaron 1982 imágenes distribuidas en bloques de 400

en cada una de las etapas de la enfermedad y 382 de cacao saludable. Todas las imágenes fueron capturadas mediante un teléfono móvil Huawei Y9s 2019. Estas fotografías fueron tomadas en frutos de cacao con una edad comprendida entre 4 y 6 meses desde el inicio del proceso de floración, entre las 10:00 a. m. y las 3:00 p. m.

En el proyecto, se utilizaron tres modelos existentes de redes neuronales convolucionales (CNN) previamente entrenados: YOLOV8, VGG19 e InceptionV3. Estos modelos fueron empleados en la detección de la mazorca negra del cacao, aprovechando el aprendizaje por transferencia.

Se midieron los resultados de los modelos propuestos empleando métricas de evaluación con el fin de ayudar a determinar la efectividad y validez de cada uno de ellos.

3.3.1 Objetivo específico 1

Obtención y Etiquetado de un Conjunto de Datos de Imágenes de Mazorca Negra en Plantaciones de Cacao

Selección de plantaciones de cacao: La recolección de imágenes de frutos de cacao para la investigación la llevamos a cabo mediante una selección cuidadosa de cinco parcelas ubicadas en el sector Shitarillo, perteneciente al distrito de Alto Saposo, provincia de Huallaga, región San Martín, donde se cultivan las tres principales variedades de cacao que estamos considerando en la investigación: Criollo, Forastero y Trinitario.

Tabla 2

Descripción de parcelas para la recolección de imágenes

Nombre parcela	Distancia aproximada	Ubicación geográfica (Coordenadas)
Parcela cacao 1	4.5 km desde la ciudad de Pasarraya	-6.767472, -76.844028 6°46'05"S 76°50'38"W
Parcela cacao 2	4 km desde la ciudad de Pasarraya	-6.771944, -76.840833. 6°46'19"S 76°50'27"W
Parcela cacao 3	3.5 km desde la ciudad de Pasarraya	-6.767472, -76.844028. 6°45'51"S 76°50'01"W
Parcela cacao 4	3.9 km desde la ciudad de Pasarraya	6°45'37"S 76°50'09"W
Parcela cacao 5	3.2 km desde la ciudad de Pasarraya	6°46'12"S 76°49'49"W

Adquisición de imágenes: La obtención de imágenes fue llevada a cabo con precisión y cuidado, utilizando un teléfono móvil Huawei Y9s 2019 configurado con una resolución de [4:3] 12 MP, la opción "cuadrícula de cámara" activada para facilitar la alineación óptima de los frutos de cacao. Manteniendo una distancia constante de aproximadamente 30 cm entre la cámara y los frutos, se procuró una perspectiva uniforme en todas las imágenes. Además, se implementaron medidas para evitar condiciones desfavorables de iluminación, evitando la toma de fotografías en contra luz y asegurándose de que los frutos no estuvieran expuestos directamente al sol. Cabe resaltar que este proceso fue asesorado por un ingeniero agrónomo.




Figura 6

Representación esquemática de la captura de imagen en un fruto de cacao

Etiquetado de las imágenes: Tras la adquisición de imágenes, llevamos a cabo un meticuloso proceso de etiquetado, categorizando cada imagen en una de las cinco etapas de desarrollo de la enfermedad de la mazorca negra del cacao (etapas 1, 2, 3, 4) o como "Cacao Saludable". Para asignar el nombre correspondiente a cada imagen se implementó un algoritmo sencillo en Python.

Tabla 3

Etiquetado de imágenes

Nombre carpeta	Nombre referencial de las imaganes
BlackPod_Fase1	BlackPod_Fase1_0001.jpg (<i>Imagen N°1</i>)
BlackPod_Fase2	BlackPod_Fase2_0040.jpg (<i>Imagen N°40</i>)
BlackPod_Fase3	BlackPod_Fase3_0400.jpg (<i>Imagen N°400</i>)
BlackPod_Fase4	BlackPod_Fase4_0200.jpg (<i>Imagen N°200</i>)
Healthy	Healthy_0006.jpg (<i>Imagen N°6</i>)

Validación y verificación de las etiquetas: Cada imagen, etiquetada con las categorías de desarrollo de la enfermedad (Etapa 1, Etapa 2, Etapa 3, Etapa 4, Cacao Saludable), fue revisada minuciosamente, asegurando su correspondencia con el

contenido visual. Este proceso contó con la participación de un ingeniero agrónomo especializado en fitopatología, quien aportó su experiencia para evaluar las distintas etapas de la enfermedad. además, implementamos verificaciones cruzadas internas para garantizar coherencia y, cualquier etiqueta cuestionada, fue sometida a una nueva evaluación.

División del conjunto de datos: Se dividió en tres carpetas esenciales: entrenamiento (70%), validación (20%) y pruebas (10%). Esta estrategia asegura que el modelo se entrene con la mayoría de las imágenes, se ajuste y valide con un conjunto independiente, y se evalúe de manera objetiva en un conjunto completamente no visto.

Almacenamiento seguro del conjunto de datos: Implementamos un protocolo de almacenamiento seguro para preservar la integridad y accesibilidad de la información. El conjunto de datos, ahora estructurado en carpetas de entrenamiento, validación y pruebas, se almacenó de manera local en un ordenador personal además se creó una copia adicional en Google Drive.

3.3.2 Objetivo específico 2

Construcción y Entrenamiento de Modelos de Visión Artificial para la Clasificación de la Mazorca Negra en Plantaciones de Cacao

Recopilación de teoría sobre aprendizaje por transferencia: Se llevó a cabo una exhaustiva revisión de artículos que trataron el tema del aprendizaje por transferencia. En dichos estudios se presentaron modelos entrenados previamente, los cuales, gracias al conocimiento adquirido, demostraron la capacidad de clasificar imágenes con precisión en categorías específicas de forma autónoma.

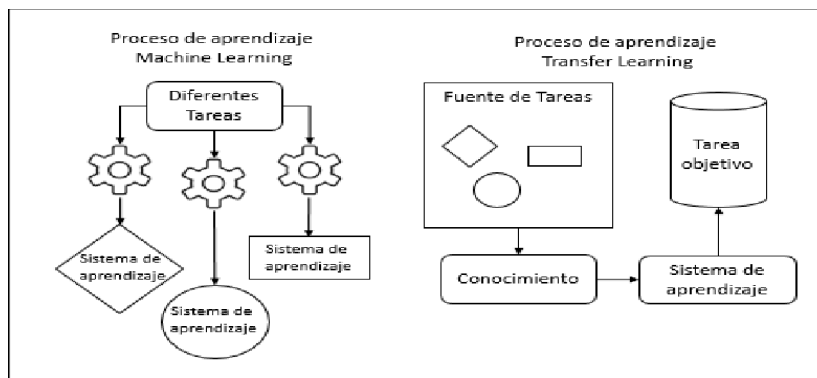


Figura 7

contraste entre el aprendizaje tradicional vs el de transferencia

Recopilación de teoría sobre las arquitecturas YOLOV8, VGG19 e Inception v3: Se exploraron aspectos CNN de diversos artículos y se analizaron para la construcción de

cada uno de los modelos. YOLOv8 se destaca por su eficiencia en la detección de objetos a través de una arquitectura mejorada que utiliza bloques de capas convolucionales con filtros de distintos tamaños. A diferencia de modelos como VGG19, YOLOv8 evita módulos complejos y se enfoca en una estructura profunda con un diseño modular que optimiza tanto la extracción de características como la regresión de cuadros delimitadores. La mejora en su rendimiento se logra mediante el uso de técnicas avanzadas de pérdida, incluyendo Entropía Cruzada Binaria (BCE), Pérdida Profunda de Características (DFL) y Intersección sobre Unión Completa (CIoU), las cuales se ponderan para ajustar y optimizar el modelo durante el entrenamiento. VGG19, es una extensión de VGG16, mantiene la disposición de filtros de 3x3 en capas convolucionales secuenciales. Su mayor profundidad refuerza la capacidad para aprender representaciones jerárquicas complejas mientras sigue la filosofía de VGG16 con una estructura más extensa. InceptionV3 introduce módulos Inception que aplican diversos filtros simultáneamente mediante capas convolucionales y de agrupación. Esta configuración permite la extracción eficiente de patrones al aprovechar diferentes tamaños de filtros, contribuyendo a una representación más completa y variada de las características presentes en la Mazorca Negra.

Construcción y entrenamiento de los modelos basados en YOLOv8, VGG19 e Inception v3.

Inspección y selección de las métricas de evaluación: Se seleccionaron las siguientes métricas para la evaluación de cada uno de los modelos:

- **Precisión:** Constituye la relación entre los casos correctos positivos y el total de casos clasificados como positivos y negativos.
- **Coefficiente F1:** Es una métrica que fusiona la precisión y la sensibilidad en un único valor, especialmente útil cuando existe un desequilibrio entre las clases de datos.
- **Exactitud:** Es la proporción de número de casos correctamente clasificados con relación al total de casos.
- **Kappa de Cohen:** Es una medida de la concordancia entre las clasificaciones observadas y las clasificaciones esperadas por azar.
- **Recall:** Mide la proporción de casos positivos reales que han sido correctamente identificados por el modelo, reflejando su capacidad para detectar todos los casos positivos.
- **Área bajo la curva ROC:** Representa la habilidad del modelo para distinguir entre clases positivas y negativas, donde un valor más alto indica un mejor rendimiento en la clasificación.

- Matriz de confusión: Es una tabla que muestra el número de casos clasificados correcta e incorrectamente para cada clase, permitiendo evaluar el desempeño del modelo en términos de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos.

3.3.3 Objetivo específico 3

Evaluar y comparar el rendimiento de los modelos de visión artificial basados en redes neuronales convolucionales propuestos durante la clasificación de imágenes de mazorca negra en plantaciones de cacao.

- Obtención de parámetros.
- Aplicación de las métricas de evaluación
- Comparación de modelos YOLOV8, VGG19, INCEPTIONV3
- Aplicación de la prueba ANOVA a los indicadores de rendimiento de cada modelo para determinar la existencia de diferencias significativas entre el cada uno de ellos.
- Visualización y análisis de resultados

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1 Resultado específico 1

Obtención y Etiquetado de un Conjunto de Datos de Imágenes de Mazorca Negra en Plantaciones de Cacao

Durante el proceso de obtención de imágenes, se recopilaron un total de 1982 elementos repartidos en cinco categorías mediante el método planteado en el capítulo anterior. Tras seleccionar cuidadosamente cada una de las imágenes, se etiquetaron mediante el asesoramiento de un ingeniero agrónomo, obteniéndose como resultado la siguiente distribución:

Clase	Cantidad
BlackPod_Fase1	400
BlackPod_Fase2	400
BlackPod_Fase3	400
BlackPod_Fase4	400
Healthy	382

Para facilitar el manejo de las imágenes y la identificación de patrones por parte del modelo, es fundamental comenzar con el preprocesamiento de los datos que se utilizarán en las diversas etapas del proyecto.

Importamos los recursos y bibliotecas que se emplearán en el acondicionamiento del dataset.

```
import tensorflow as tf
import numpy as np
import pandas as pd
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.utils import to_categorical
```

En este caso, al estar empleando Google Colaboratory para la manipulación de los datos, es necesario importarlos desde la unidad virtual de almacenamiento de Google, por lo que procedemos a montar dicha unidad:

```
from google.colab import drive
drive.mount('/gdrive')
```

```
%cd /gdrive/MyDrive/Proyectos\ IA/CacaoVillalobos/Datased_BlackPod
```

Indicamos la ubicación de cada conjunto de datos requeridos: el de entrenamiento, validación y el de prueba. Además, definimos las dimensiones que se emplearán durante el preprocesamiento.

```
train_data_dir = 'train'
validation_data_dir = 'val'
test_data_dir = 'test'
img_width, img_height = 299, 299
input_shape = (img_width, img_height, 3)
```

Utilizamos la clase **ImageDataGenerator** para instanciar generadores de datos, que se encargarán de aplicar diversas técnicas de transformación y preprocesamiento. Estas técnicas incluyen escalado, rotación, traslación, aumento de zoom y variaciones en el brillo con el objetivo de incrementar la cantidad de datos de entrenamiento y mejorar la capacidad del modelo para generalizar, así como para prevenir el sobreajuste (Overfitting).

```
train_datagen = ImageDataGenerator(rescale=1./255,
                                   shear_range=0.2,
                                   zoom_range=0.2,
                                   brightness_range=[0.8, 1.2],
                                   horizontal_flip=True)
validation_datagen = ImageDataGenerator(rescale=1./255)
test_datagen = ImageDataGenerator(rescale=1./255)
```

Dichos generadores, nos permitieron obtener los conjuntos de datos preparados y estructurados adecuadamente para el entrenamiento, la validación y, finalmente, la prueba.

```
train_dataset = train_datagen.flow_from_directory(train_data_dir,
                                                  target_size=(img_width, img_height),
                                                  batch_size=32,
                                                  class_mode='categorical')

validation_dataset = validation_datagen.flow_from_directory(validation_data_dir,
                                                            target_size=(img_width, img_height),
                                                            batch_size=32,
                                                            class_mode='categorical',
                                                            shuffle=False)

test_dataset = test_datagen.flow_from_directory(test_data_dir,
```

```
target_size=(img_width, img_height),
batch_size=32,
class_mode='categorical',
shuffle=False)
```

Para efectos de visualizar los resultados y la manera en la que trabaja esta clase, imprimimos una muestra de 10 elementos de forma aleatoria:

```
batch = train_dataset.next()
muestra = batch[0][:10]
labels = list(train_dataset.class_indices.keys())
etiquetas = np.argmax(batch[1], axis=1)

plt.figure(figsize=(14, 6))
for i in range(len(muestra)):
    plt.subplot(2, 5, i+1)
    plt.imshow(muestra[i])
    plt.xlabel(labels[etiquetas[i]])
plt.show()
```



Figura 8
Imágenes preprocesadas

Las imágenes obtenidas tras el preprocesamiento están organizadas e identificadas de acuerdo con su categoría, y están listas para ser utilizadas en el entrenamiento y la validación. Este enfoque es coherente con investigaciones similares, como la de (Atila et al., 2021) y (Wang et al., 2024), quienes implementaron métodos y técnicas de redimensionamiento y aumento de datos antes de llevar a cabo el procesamiento.

4.2 Resultado específico 2

Construcción y Entrenamiento de Modelos de Visión Artificial para la Clasificación de la Mazorca Negra en Plantaciones de Cacao

La construcción del modelo de clasificación se compararon tres arquitecturas de redes neuronales convolucionales: YOLOv8, InceptionV3 y VGG19. Para el primer caso de prueba, se empleó la arquitectura YOLOv8 en su versión yolov8x-cls. Dicha arquitectura se entrenó por completo con el dataset generado anteriormente.

```
model = YOLO("yolov8x-cls.pt")
dir = "/gdrive/MyDrive/Proyectos
IA/CacaoVillalobos/Datased_BlackPod"
results = model.train(data=dir, epochs=20, imgsz=299)
```

Para el caso de los 2 prototipos restantes, se emplearon técnicas de transferencia de aprendizaje, el cual se basa en utilizar un modelo previamente entrenado con un set de datos más grande y simplemente conectarlo a un clasificador adaptado a nuestro caso.

Creamos instancias de los modelos InceptionV3 y VGG19 a los que asignamos a la variable "pretrained_model" con el fin de poder ajustar sus arquitecturas.

```
pretrained_model = InceptionV3(weights='imagenet',
include_top=False, input_shape=input_shape)
```

```
pretrained_model = VGG16(weights='imagenet', include_top=False,
input_shape=input_shape)
```

Examinamos las capas del modelo para asegurarnos de no sobrescribir los pesos del modelo que fue previamente entrenado con el conjunto de datos visual ImageNet.

```
for layer in pretrained_model.layers:
    layer.trainable = False
```

Utilizamos la función output para obtener el tensor resultante de las capas convolucionales de cada modelo instanciado, y lo almacenamos en una variable para integrarlo posteriormente en un nuevo modelo.

```
res = pretrained_model.output
```

El nuevo modelo se crea a partir del tensor previamente obtenido. A este modelo le añadimos una capa de aplanamiento (Flatten) que se conecta a una capa densa (Dense) de 1024 unidades con la función de activación "ReLU" y una función de regularización

que añade la penalización de regularización a la pérdida con respecto a los pesos de la última capa. Esta, a su vez, se conecta a una capa densa final (Dense) de 5 unidades con activación "Softmax", que se encargará de realizar la clasificación.

```
res = Flatten()(res)
res = Dense(1024, activation = 'relu',
kernel_regularizer=l2(0.01))(res)
res = Dropout(0.2)(res)
predictions = Dense(5, activation = 'softmax')(res)
```

Establecemos el modelo como la capa de entrada y utilizamos el modelo almacenado en la variable "predictions" como la capa de salida o decisión. El resultado se guarda en la variable "model".

```
model = Model(inputs = pretrained_model.input, outputs =
predictions)
```

Utilizamos la función *compile* para compilar el modelo, empleando el algoritmo de optimización Adam y la entropía cruzada categórica como criterio de error durante el entrenamiento. También configuramos el monitoreo de la precisión del modelo en cada iteración o época de entrenamiento mediante el parámetro *metrics*.

```
model.compile(optimizer = Adam(), loss='categorical_crossentropy',
metrics = ['accuracy'])
```

Antes de comenzar el entrenamiento, configuramos la callback *checkpoint*, la cual es una función que se activará en momentos específicos durante el proceso de entrenamiento, en el caso de esta callback, guardará el modelo entrenado cada vez que se alcanza un máximo en la precisión con el conjunto de validación durante el proceso de entrenamiento.

```
checkpoint = ModelCheckpoint('Cacao_InceptionV3_Best.keras',
monitor='val_accuracy',
save_best_only=True,
mode='max',
verbose=1)
```

```
checkpoint = ModelCheckpoint('Cacao_VGG19_Best.keras',
monitor='val_accuracy',
save_best_only=True,
mode='max',
verbose=1)
```

En cuanto al entrenamiento, proporcionamos el conjunto de entrenamiento, la cantidad de lotes que se generarán para cada época (`steps_per_epoch`), el número de épocas (`epochs`), el conjunto de validación, la cantidad de lotes que se evaluarán (`validation_steps`) y, por último, los callbacks mencionados anteriormente.

Realizamos el entrenamiento mediante el método `fit()`. Esta función, además de poner en marcha el entrenamiento, nos devuelve el registro histórico del entrenamiento con las métricas de monitoreo en cada época especificadas en los argumentos del método `compile()`. Almacenamos este registro en la variable "history".

```
history = model.fit(train_dataset, steps_per_epoch =
train_dataset.n//train_dataset.batch_size*30,
                    epochs = 30, validation_data =
validation_dataset,
                    validation_steps =
validation_dataset.n//validation_dataset.batch_size*30,
                    callbacks=[checkpoint])
```

Luego de completar el entrenamiento, evaluamos la exactitud del modelo con el conjunto de datos de prueba, el cual ha sido reservado y no ha tenido ninguna interacción con el modelo durante el proceso de entrenamiento.

```
score = trained_model.evaluate(test_dataset)
print("Pérdida: ", score[0])
print("Exactitud: ", score[1])
Pérdida: 1.186540126800537
Exactitud: 0.6899999976158142
```

Luego de correr la evaluación, con el modelo basado en la arquitectura InceptionV3, se alcanzó un 74.5% de exactitud con el set de prueba, mientras que con el modelo VGG19, sólo se pudo alcanzar el 20%

```
7/7 ----- 36s 3s/step - accuracy: 0.7416 - loss:
0.8808
Pérdida: 0.9343509674072266
Exactitud: 0.7450000047683716
```

```
7/7 ----- 32s 3s/step - accuracy: 0.4016 - loss:
442.0095
Pérdida: 875.97900390625
Exactitud: 0.20000000298023224
```

Utilizando la librería `matplotlib.pyplot`, recorreremos la variable "history" para visualizar la evolución de la precisión del modelo a lo largo de las épocas de entrenamiento.

```
import matplotlib.pyplot as plt
plt.plot(history.history['accuracy'])
plt.plot(history.history['val_accuracy'])
plt.title('Exactitud del modelo')
plt.ylabel('Exactitud')
plt.xlabel('Épocas')
plt.legend(['Entrenamiento', 'Validación'], loc='upper left')
plt.show()
```

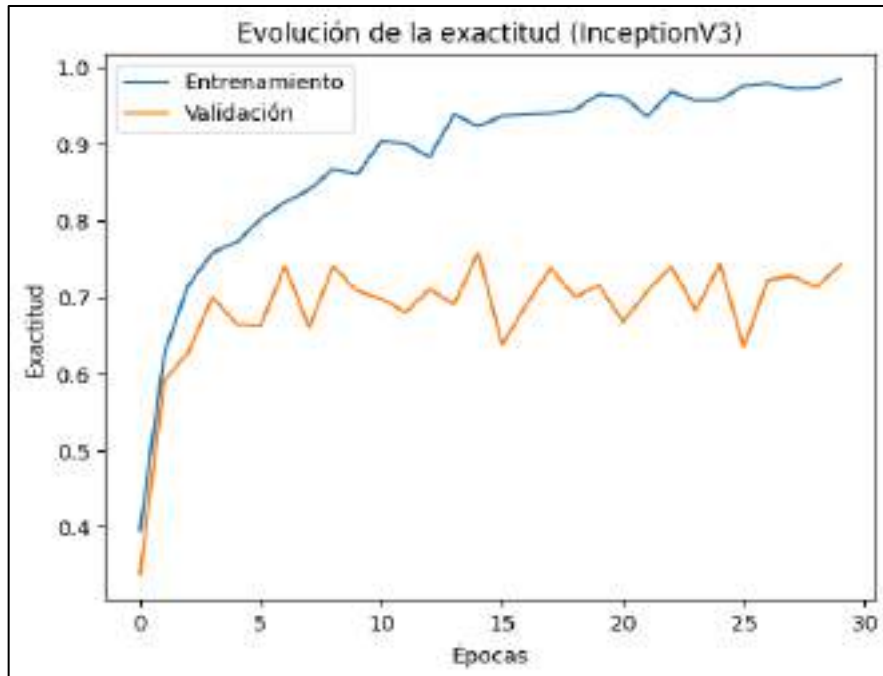


Figura 9
Métricas del entrenamiento (InceptionV3)

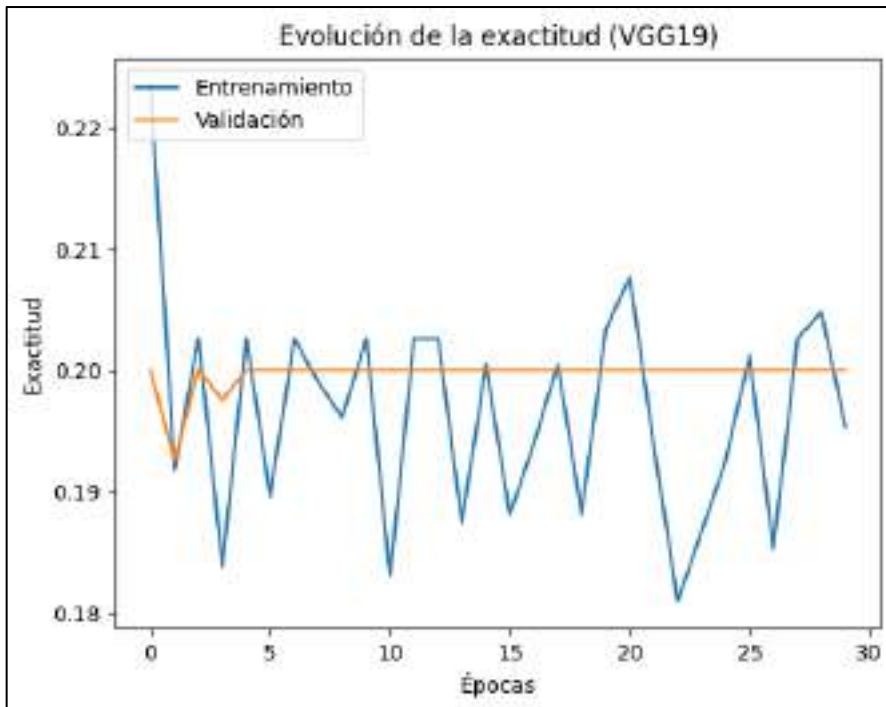


Figura 10
Métricas del entrenamiento (VGG19)

Como se puede apreciar en el gráfico del proceso de entrenamiento (Figura 1), los valores finales de la métrica de precisión, tanto en el conjunto de entrenamiento como en el de validación, no presentan una variación significativa, lo que indica que no hay sobreajuste en el modelo.

En el trabajo (Lomotey et al., 2024), se desarrollaron varios modelos para la detección y el diagnóstico automáticos de enfermedades del cacao. Ellos proponen una red neuronal convolucional basada en el modelo SSD MobilNet v2 con la que obtienen una precisión del 88% en el conjunto de validación. En comparación con los resultados obtenidos por el modelo YOLOv8, propuesto en esta investigación, podemos evidenciar un menor rendimiento, alcanzando un valor máximo del 79.5% con el set de validación. Esto puede deberse a la diferencia en la calidad y/o cantidad de las imágenes de entrenamiento utilizados en ambas investigaciones.

4.3 Resultado específico 3

Evaluar y comparar el rendimiento de los modelos de visión artificial basados en redes neuronales convolucionales propuestos durante la clasificación de imágenes de mazorca negra en plantaciones de cacao

Comenzando con el modelo basado en YOLOv8. Para este caso, instanciamos la clase YOLO y especificamos la ubicación en la que se encuentra la instancia del modelo que previamente entrenamos directamente en su argumento:

```
model = YOLO("./runs/classify/train10/weights/best.pt")
```

En cuanto a los modelos lceptionV3 y VGG19, los cargamos mediante el método `load_model()` de la clase `models` de `keras`, especificando en su argumento la ubicación de cada modelo guardado mediante la callback **ModelCheckpoint**.

```
trained_model =
keras.models.load_model('Cacao_InceptionV3_Best.keras')
```

```
trained_model = keras.models.load_model('Cacao_VGG19_Best.keras')
```

Realizamos las predicciones sobre el set de datos de prueba y las anexamos en el array "pred". Debido a que los resultados almacenados en "pred" son arrays de probabilidades, aplicamos la función `argmax()` de `numpy` para obtener las predicciones en un formato mas comprensible y de fácil manipulación.

```
pred = trained_model.predict(test_dataset)
pred = np.argmax(pred, axis=1)
```

Desde nuestro set de datos de prueba, extraemos mediante su atributo `classes_indices` las etiquetas correspondientes a cada predicción hecha en el paso anterior.

```
labels = list(test_dataset.class_indices.keys())
from sklearn import metrics
ref_classes = []
for index in range(len(test_dataset)):
    ref_classes.extend(np.argmax(test_dataset[index][1], axis=1))
```

Tras procesar los valores de la variable "pred" y con los valores reales de referencia almacenados en la variable "ref_classes", sometemos a dichos resultados a las métricas de evaluación de rendimiento respectivas a la tarea de clasificación.

- Exactitud
- Coeficiente F1
- Precisión
- Recall
- Kappa de Cohen
- Area bajo de curva ROC

- Matriz de confusión

```
accuracy = metrics.accuracy_score(ref_classes, predicted_classes)
f1 = metrics.f1_score(ref_classes, predicted_classes,
average='micro')
precision = metrics.precision_score(ref_classes, predicted_classes,
average='micro')
recall = metrics.recall_score(ref_classes, predicted_classes,
average='micro')
cohen_kappa = metrics.cohen_kappa_score(ref_classes,
predicted_classes)
```

```
n_classes = len(np.unique(y_test))
fpr = dict()
tpr = dict()
roc_auc = dict()
for i in range(n_classes):
    fpr[i], tpr[i], _ = roc_curve([e==i for e in y_test], [f==i for f
in pred])
    roc_auc[i] = roc_auc_score([e==i for e in y_test], [f==i for f
in pred])
```

```
cm = confusion_matrix(labels, pred)

# Visualizamos la matriz de confusión
plt.figure(figsize=(10,7))
sns.heatmap(cm, annot=True, fmt='d')
plt.xlabel('Predicción')
plt.ylabel('Referencia')
plt.xticks(np.arange(5) + 0.5, labels=nombre_clases)
plt.yticks(np.arange(5) + 0.5, labels=nombre_clases)
plt.show()
```

Lo que nos da como resultado lo siguiente:

INDICADOR	YOLOv8	INCEPTIONV3	VGG19
Exactitud	0.7902	0.7321	0.1920
Coeficiente F1	0.7902	0.7321	0.1920
Precisión	0.7902	0.7321	0.1920
Recall	0.7902	0.7321	0.1920
Kappa de Cohen	0.7315	0.6535	0.0000
ROC AUC	0.854	0.835	0.50




Figura 11
Matriz de confusión (YOLOv8)

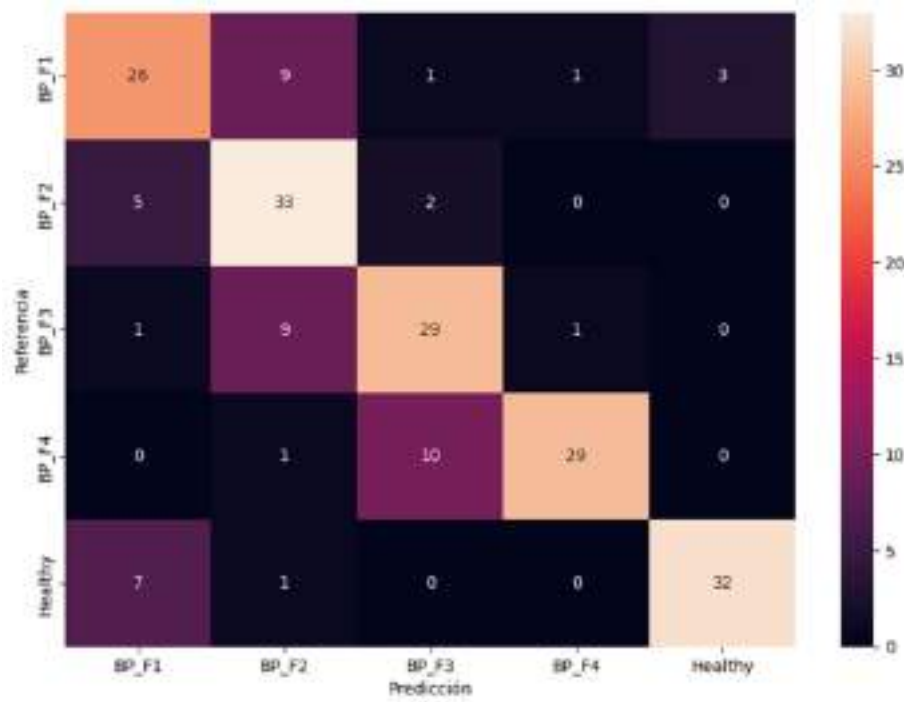


Figura 12
Matriz de confusión (InceptionV3)

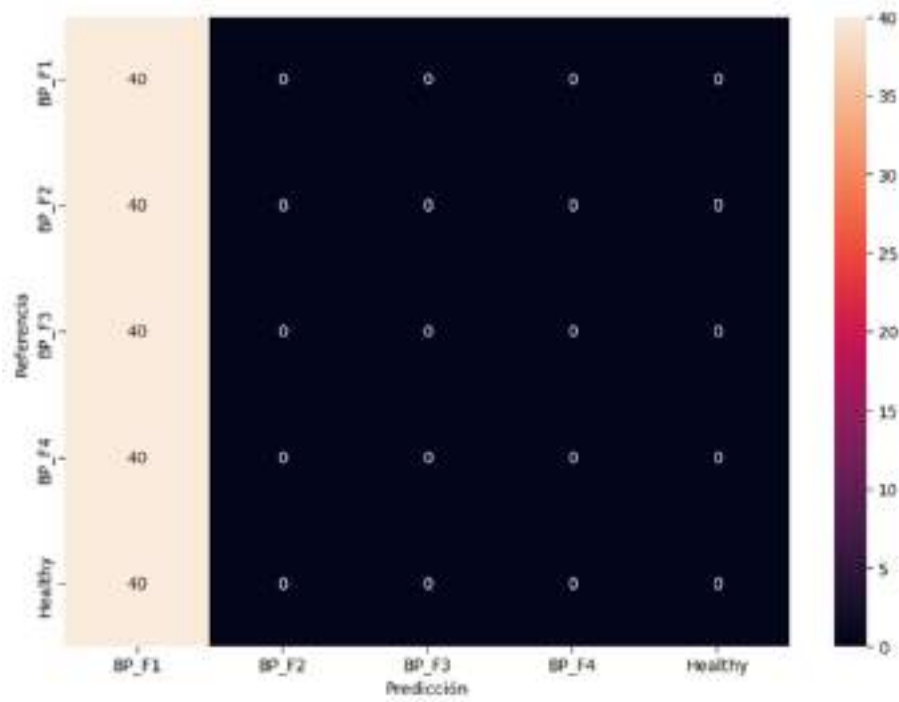


Figura 13
Matriz de confusión (VGG19)

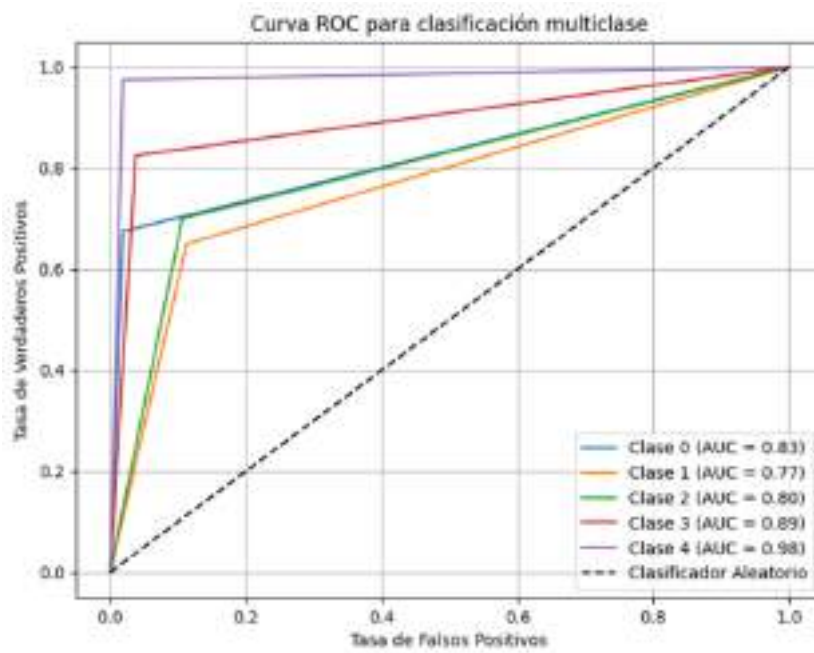


Figura 14
Curva ROC para clasificación multiclase (YOLOv8)

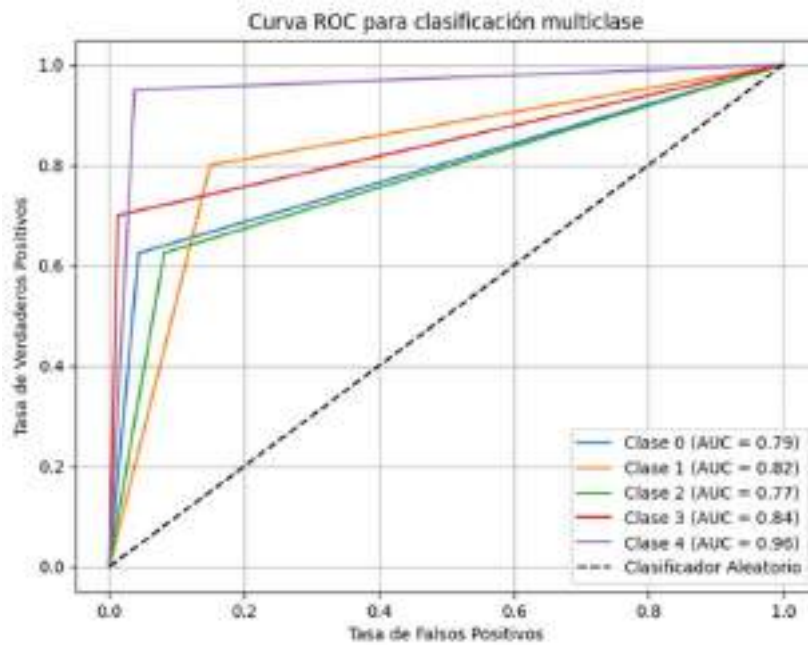


Figura 15
Curva ROC para clasificación multiclase (InceptionV3)

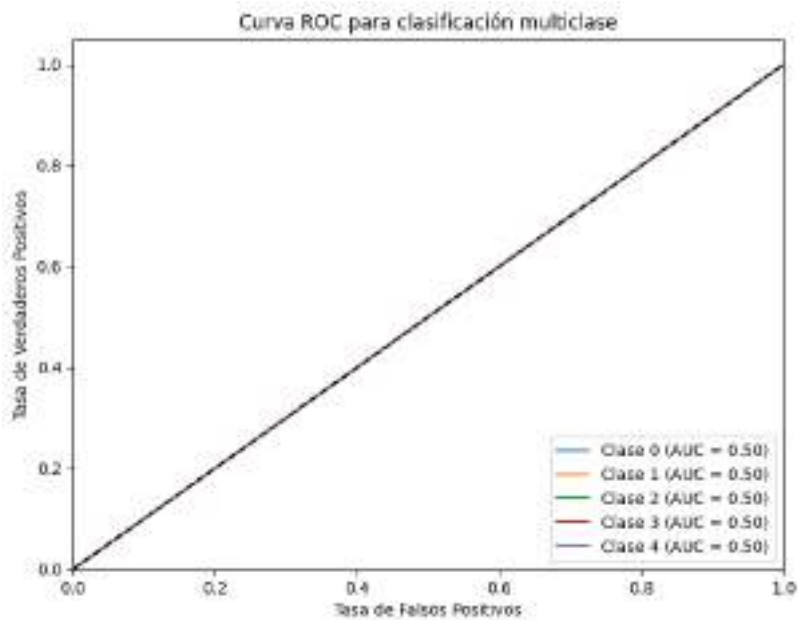


Figura 16
Curva ROC para clasificación multiclase (VGG19)

Con el fin de garantizar la consistencia de las métricas de rendimiento, el conjunto de prueba se dividió en 7 subconjuntos. Luego, cada modelo se ejecutó con cada uno de estos grupos del conjunto de prueba.

Después de realizar las predicciones, se obtuvieron los siguientes resultados (ver Tabla 4).

Tabla 4
Métricas según grupo de evaluación

MODELO	GRUPO	EXACTITUD	F1	PRECISIÓN	RECALL	KAPPA DE COHEN
YOLOV8	1	0.6875	0.6875	0.6875	0.6875	0.60298
	2	0.6875	0.6875	0.6875	0.6875	0.6088
	3	0.84375	0.84375	0.84375	0.84375	0.8037
	4	0.90625	0.90625	0.90625	0.90625	0.8807
	5	0.8125	0.8125	0.8125	0.8125	0.74297
	6	0.71875	0.71875	0.71875	0.71875	0.64488
	7	0.875	0.875	0.875	0.875	0.8367
INCEPTIONV3	1	0.71875	0.71875	0.71875	0.71875	0.634053
	2	0.8125	0.8125	0.8125	0.8125	0.755414
	3	0.71875	0.71875	0.71875	0.71875	0.647491
	4	0.71875	0.71875	0.71875	0.71875	0.646626
	5	0.75	0.75	0.75	0.75	0.684729
	6	0.78125	0.78125	0.78125	0.78125	0.727825
	7	0.625	0.625	0.625	0.625	0.478261
VGG19	1	0.1875	0.1875	0.1875	0.1875	0
	2	0.21875	0.21875	0.21875	0.21875	0
	3	0.25	0.25	0.25	0.25	0
	4	0.21875	0.21875	0.21875	0.21875	0
	5	0.125	0.125	0.125	0.125	0
	6	0.21875	0.21875	0.21875	0.21875	0
	7	0.125	0.125	0.125	0.125	0

Para evaluar si hay diferencias significativas en los resultados proporcionados por los modelos propuestos, utilizamos el método ANOVA (análisis de varianza), que nos permitió obtener los siguientes resultados:

Tabla 5
Resultados de la prueba ANOVA

		Suma de cuadrados	GL	Media cuadrática	F	SIG
Exactitud	Entre grupos	1.524	2	.762	159.575	.000
	Dentro de grupos	.086	18	.005		
	Total	1.610	20			
Coefficiente F1	Entre grupos	1.524	2	.762	159.575	.000
	Dentro de grupos	.086	18	.005		
	Total	1.610	20			
Precisión	Entre grupos	1.524	2	.762	159.575	.000
	Dentro de grupos	.086	18	.005		
	Total	1.610	20			
Recall	Entre grupos	1.524	2	.762	159.575	.000
	Dentro de grupos	.086	18	.005		
	Total	1.610	20			
Kappa de Cohen	Entre grupos	2.259	2	1.130	161.610	.000

Exactitud	HSD	YOLOv8	InceptionV3	.05804	.036	.283	-.0362	.1523
						93		
	Tuke	y	VGG19	.59821 [*]	.036	.000	.5040	.6925
						93		
	Inception	V3	YOLOv8	-.05804	.036	.283	-.1523	.0362
						93		
	VGG19	YOLOv8	VGG19	.54018 [*]	.036	.000	.4459	.6344
						93		
	Inception	V3	YOLOv8	-.59821 [*]	.036	.000	-.6925	-.5040
						93		
VGG19	YOLOv8	InceptionV3	-.54018 [*]	.036	.000	-.6344	-.4459	
					93			
Coeficiente F1	HSD	YOLOv8	InceptionV3	.05804	.036	.283	-.0362	.1523
						93		
	Tuke	y	VGG19	.59821 [*]	.036	.000	.5040	.6925
						93		
	Inception	V3	YOLOv8	-.05804	.036	.283	-.1523	.0362
						93		
	VGG19	YOLOv8	VGG19	.54018 [*]	.036	.000	.4459	.6344
						93		
	Inception	V3	YOLOv8	-.59821 [*]	.036	.000	-.6925	-.5040
						93		
VGG19	YOLOv8	InceptionV3	-.54018 [*]	.036	.000	-.6344	-.4459	
					93			
Precisión	HSD	YOLOv8	InceptionV3	.05804	.036	.283	-.0362	.1523
						93		
	Tuke	y	VGG19	.59821 [*]	.036	.000	.5040	.6925
						93		
	Inception	V3	YOLOv8	-.05804	.036	.283	-.1523	.0362
						93		
	VGG19	YOLOv8	VGG19	.54018 [*]	.036	.000	.4459	.6344
						93		
	Inception	V3	YOLOv8	-.59821 [*]	.036	.000	-.6925	-.5040
						93		
VGG19	YOLOv8	InceptionV3	-.54018 [*]	.036	.000	-.6344	-.4459	
					93			
Recall	HSD	YOLOv8	InceptionV3	.05804	.036	.283	-.0362	.1523
						93		
	Tuke	y	VGG19	.59821 [*]	.036	.000	.5040	.6925
						93		
Inception	V3	YOLOv8	-.05804	.036	.283	-.1523	.0362	
					93			

			VGG19	.54018*	.036	.000	.4459	.6344
					93			
		VGG19	YOLOv8	-.59821*	.036	.000	-.6925	-.5040
					93			
			InceptionV3	-.54018*	.036	.000	-.6344	-.4459
					93			
Kappa de Cohen	HSD Tuke y	YOLOv8	InceptionV3	.07806	.044	.216	-.0360	.1921
					69			
			VGG19	.73154*	.044	.000	.6175	.8456
					69			
		Inception V3	YOLOv8	-.07806	.044	.216	-.1921	.0360
					69			
			VGG19	.65349*	.044	.000	.5394	.7675
					69			
	VGG19	YOLOv8	-.73154*	.044	.000	-.8456	-.6175	
					69			
			InceptionV3	-.65349*	.044	.000	-.7675	-.5394
					69			

Mediante el valor “p” (Sig.), es posible determinar que existen diferencias significativas en todos los indicadores de rendimiento correspondientes al modelo VGG19, puesto que dicho valor “p” no supera el valor Alpha (0.01) planteado según el nivel de confianza propuesto (99%).

Si observamos los estadísticos descriptivos de las métricas de rendimiento de cada modelo (Tabla 6), es posible determinar que dicha diferencia significativa respecto a los demás grupos radica en su peor desempeño. Por lo que es posible afirmar que tanto el modelo YOLOv8 y el modelo basado en InceptionV3, presentan un mejor rendimiento sin contemplar diferencias significativas entre ellos.

Como puede observarse en las distintas gráficas e indicadores, el modelo basado en YOLOv8 logró alcanzar un valor promedio del 79% en su exactitud respecto a set de prueba. Este valor coincide con los valores registrados en otros trabajos como el de (Kumi et al., 2022) quienes alcanzaron valor superior al 80% con el modelo SSD MobileNet. Una diferencia bastante pequeña que podría deberse a la calidad y/o cantidad de los datos utilizados en cada investigación

CONCLUSIONES

1. Logramos mejorar la detección temprana de la mazorca negra en las plantaciones de cacao en la región de San Martín mediante los modelos de visión artificial desarrollados durante la presente investigación, dos de los cuales han demostrado tener un buen rendimiento en la identificación temprana de esta enfermedad.
2. Recopilamos y etiquetamos de manera exitosa y exhaustiva un conjunto de 1982 imágenes de mazorca negra en plantaciones de cacao de cinco parcelas ubicadas en el sector Shitarillo, perteneciente al distrito de Alto Saposa, provincia de Huallaga, región San Martín.
3. Construimos tres modelos de visión artificial utilizando técnicas avanzadas, incluyendo redes neuronales convolucionales para generar el modelo basado en la arquitectura YOLOv8 y transferencia de aprendizaje para los modelos basados en InceptionV3 y VGG19. Dos de estos modelos han demostrado ser efectivos en la clasificación de imágenes de mazorca negra segmentados en 5 categorías, los cuales a su vez se agruparon en grupos de entrenamiento, validación y prueba para llevar a cabo correctamente el proceso de entrenamiento.
4. Luego de construir y entrenar los tres modelos, evaluamos y comparamos sus rendimientos a través de sus indicadores de desempeño en la tarea de clasificación, los cuales se aplicaron sobre siete subconjuntos de datos. Dichos valores se sometieron a la prueba ANOVA en el que se determinó que existía al menos un modelo que presentaba diferencias significativas respecto a los demás. Mediante la prueba de Tukey, se determinó que el modelo basado en VGG19 presentaba un rendimiento significativamente inferior a los otros dos modelos. Estos dos modelos, sin embargo, no presentan diferencias significativas entre sí.

RECOMENDACIONES

1. Recomendamos para futuros trabajos, recopilar una mayor cantidad de imágenes por clase, esto con el fin de obtener una muestra más representativa de los distintos escenarios que presentan las distintas estadias de la enfermedad y de esta manera disminuir el sobreajuste de los modelos, permitiéndoles alcanzar mayores valores en los índices de rendimiento.
2. Recomendamos explorar nuevas técnicas y/o arquitecturas de aprendizaje automático con el fin de encontrar aquella solución que se desempeñe de manera óptima frente al problema planteado, teniendo en cuenta las mismas métricas o similares a las que se utilizaron durante este trabajo.
3. Investigar técnicas de optimización específicas para los modelos de visión artificial utilizados, incluyendo el ajuste de hiperparámetros, otras técnicas de aumento de datos y la selección de otras funciones de optimización u otros valores de tasas de entrenamiento.
4. Para garantizar los resultados obtenidos, se recomienda realizar pruebas en campo que garanticen que los resultados obtenidos en el laboratorio se traduzcan en mejoras reales en la detección temprana de las enfermedades del cacao, permitiendo ampliar o modificar las muestras en el set de datos.

REFERENCIAS BIBLIOGRÁFICAS

- Ahmad, A., Saraswat, D., & El Gamal, A. (2023). A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools. *Smart Agricultural Technology*, 3, 100083. <https://doi.org/10.1016/j.atech.2022.100083>
- Almadhor, A., Rauf, H. T., Lali, M. I. U., Damaševičius, R., Alouffi, B., & Alharbi, A. (2021). AI-Driven Framework for Recognition of Guava Plant Diseases through Machine Learning from DSLR Camera Sensor Based High Resolution Imagery. *Sensors*, 21(11), 3830. <https://doi.org/10.3390/s21113830>
- Atila, Ü., Uçar, M., Akyol, K., & Uçar, E. (2021). Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*, 61. <https://doi.org/10.1016/j.ecoinf.2020.101182>
- Ayikpa, K. J., Mamadou, D., Gouton, P., & Adou, K. J. (2023). Classification of Cocoa Pod Maturity Using Similarity Tools on an Image Database: Comparison of Feature Extractors and Color Spaces. *Data*, 8(6), 99. <https://doi.org/10.3390/data8060099>
- Ayon, S. A., Mashrafi, C. Z., Yousuf, A. Bin, Hossain, F., & Hossain, M. I. (2021). FoodieCal: A Convolutional Neural Network Based Food Detection and Calorie Estimation System. *2021 National Computing Colleges Conference (NCCC)*, 1–6. <https://doi.org/10.1109/NCCC49330.2021.9428820>
- Baculio, N. G., & Barbosa, J. B. (2022). An Objective Classification Approach of Cacao Pods using Local Binary Pattern Features and Artificial Neural Network Architecture (ANN). *Indian Journal of Science and Technology*, 15(11), 495–504. <https://doi.org/10.17485/IJST/v15i11.60>
- Barburiceanu, S., Meza, S., Orza, B., Malutan, R., & Terebes, R. (2021). Convolutional Neural Networks for Texture Feature Extraction. Applications to Leaf Disease Classification in Precision Agriculture. *IEEE Access*, 9, 160085–160103. <https://doi.org/10.1109/ACCESS.2021.3131002>
- Basri, Tamin, R., Harli, Indrabayu, & Areni, I. S. (2018). Gabor filter evaluation for Binary threshold image processing in early detection application. *Journal of Advanced Research in Dynamical and Control Systems*, 10(10).
- Basri, Tamin, R., Karim, H. A., Indrabayu, & Areni, I. S. (2020). Mobile image processing application for cacao's fruits pest and disease attack using deep

learning algorithm. *ICIC Express Letters*, 14(10).
<https://doi.org/10.24507/icicel.14.10.1025>

Bermejo, D., & Alzamora, G. S. (2022). A comparative study on plant classification using convolutional neural networks architectures. *2022 XLVIII Latin American Computer Conference (CLEI)*, 1–8.
<https://doi.org/10.1109/CLEI56649.2022.9959905>

Boateng, K. O., Dankyi, E., Amponsah, I. K., Awudzi, G. K., Amponsah, E., & Darko, G. (2023). Knowledge, perception, and pesticide application practices among smallholder cocoa farmers in four Ghanaian cocoa-growing regions. *Toxicology Reports*, 10, 46–55. <https://doi.org/10.1016/j.toxrep.2022.12.008>

Bosilj, P., Aptoula, E., Duckett, T., & Cielniak, G. (2020). Transfer learning between crop types for semantic segmentation of crops versus weeds in precision agriculture. *Journal of Field Robotics*, 37(1), 7–19.
<https://doi.org/10.1002/rob.21869>

Che'Ya, N. N., Mohidem, N. A., Roslin, N. A., Saberioon, M., Tarmidi, M. Z., Arif Shah, J., Fazlil Ilahi, W. F., & Man, N. (2022). Mobile Computing for Pest and Disease Management Using Spectral Signature Analysis: A Review. *Agronomy*, 12(4), 967. <https://doi.org/10.3390/agronomy12040967>

Fachin, G., Pinedo, K., Vásquez, J., Flores, E., Doria, M., Alvarado, J., Koch, C., & Bellido, J. J. (2019). Environmental factors and incidence of carmenta foraseminis (Busck) eichlin (Lepidoptera: Sesiidae) in theobroma cacao "cocoa tree" fruits in san martin, Peru. *Boletín Científico Del Centro de Museos*, 23(2). <https://doi.org/10.17151/bccm.2019.23.2.6>

Franco, A. J. D., Merca, F. E., Rodriguez, M. S., Balidion, J. F., Migo, V. P., Amalin, D. M., Alocilja, E. C., & Fernando, L. M. (2019). DNA-based electrochemical nanobiosensor for the detection of *Phytophthora palmivora* (Butler) Butler, causing black pod rot in cacao (*Theobroma cacao* L.) pods. *Physiological and Molecular Plant Pathology*, 107. <https://doi.org/10.1016/j.pmpp.2019.04.004>

Godmalin, R. A., Aliac, C. J., & Feliscuzo, L. (2022). Classification of Cacao Pod if Healthy or Attack by Pest or Black Pod Disease Using Deep Learning Algorithm. *2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAJET)*, 1–5.
<https://doi.org/10.1109/IICAJET55139.2022.9936817>

- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, *77*, 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- Gyamfi, A., Iddrisu, S. A. J., & Adegbola, O. (2020). Machine learning-based cocoa e-health system. *13th CMI Conference on Cybersecurity and Privacy - Digital Transformation - Potentials and Challenges, CMI 2020*. <https://doi.org/10.1109/CMI51275.2020.9322689>
- INEI. (2022). *Informe Técnico N° 01 - Marzo 2022 Indicador de la Actividad Productiva Departamental*. <https://www.inei.gob.pe/media/MenuRecursivo/boletines/01-informe-tecnico-indicador-de-la-act-productiva-dptal-iv-trim-2021.pdf>
- Iparraguirre-Villanueva, O., Guevara-Ponce, V., Torres-Ceclén, C., Ruiz-Alvarado, J., Castro-Leon, G., Roque-Paredes, O., Zapata-Paulini, J., & Cabanillas-Carbonell, M. (2023). Disease Identification in Crop Plants based on Convolutional Neural Networks. *International Journal of Advanced Computer Science and Applications*, *14*(3). <https://doi.org/10.14569/IJACSA.2023.0140360>
- Jackulin, C., & Murugavalli, S. (2022). A comprehensive review on detection of plant disease using machine learning and deep learning approaches. *Measurement: Sensors*, *24*, 100441. <https://doi.org/10.1016/j.measen.2022.100441>
- Jaiswal, G. (2021). Performance Analysis of Incremental Learning Strategy in Image Classification. *2021 11th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, 427–432. <https://doi.org/10.1109/Confluence51648.2021.9377034>
- Khalid, M., Sarfraz, M. S., Iqbal, U., Aftab, M. U., Niedbala, G., & Rauf, H. T. (2023). Real-Time Plant Health Detection Using Deep Convolutional Neural Networks. *Agriculture*, *13*(2), 510. <https://doi.org/10.3390/agriculture13020510>
- Khattak, A., Asghar, M. U., Batool, U., Asghar, M. Z., Ullah, H., Al-Rakhami, M., & Gumaei, A. (2021). Automatic Detection of Citrus Fruit and Leaves Diseases Using Deep Neural Network Model. *IEEE Access*, *9*, 112942–112954. <https://doi.org/10.1109/ACCESS.2021.3096895>

- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, 151, 107398. <https://doi.org/10.1016/j.ymssp.2020.107398>
- Kumi, S., Kelly, D., Woodstuff, J., Lomotey, R. K., Orji, R., & Deters, R. (2022). Cocoa Companion: Deep Learning-Based Smartphone Application for Cocoa Disease Detection. *Procedia Computer Science*, 203. <https://doi.org/10.1016/j.procs.2022.07.013>
- Li, H., Shi, H., Du, A., Mao, Y., Fan, K., Wang, Y., Shen, Y., Wang, S., Xu, X., Tian, L., Wang, H., & Ding, Z. (2022). Symptom recognition of disease and insect damage based on Mask R-CNN, wavelet transform, and F-RNet. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.922797>
- Li, L., Zhang, S., & Wang, B. (2021). Plant Disease Detection and Classification by Deep Learning—A Review. *IEEE Access*, 9, 56683–56698. <https://doi.org/10.1109/ACCESS.2021.3069646>
- Liu, Z., Yan, W. Q., & Yang, M. L. (2018). Image denoising based on a CNN model. *2018 4th International Conference on Control, Automation and Robotics (ICCAR)*, 389–393. <https://doi.org/10.1109/ICCAR.2018.8384706>
- Lomotey, R. K., Kumi, S., Orji, R., & Deters, R. (2024). Automatic detection and diagnosis of cocoa diseases using mobile tech and deep learning. *International Journal of Sustainable Agricultural Management and Informatics*, 10(1), 92–119. <https://doi.org/10.1504/IJSAMI.2024.135403>
- Maeda-Gutiérrez, V., Galván-Tejada, C. E., Zanella-Calzada, L. A., Celaya-Padilla, J. M., Galván-Tejada, J. I., Gamboa-Rosales, H., Luna-García, H., Magallanes-Quintanar, R., Guerrero Méndez, C. A., & Olvera-Olvera, C. A. (2020). Comparison of Convolutional Neural Network Architectures for Classification of Tomato Plant Diseases. *Applied Sciences*, 10(4), 1245. <https://doi.org/10.3390/app10041245>
- Mashood Nasir, I., Bibi, A., Hussain Shah, J., Attique Khan, M., Sharif, M., Iqbal, K., Nam, Y., & Kadry, S. (2021). Deep Learning-based Classification of Fruit Diseases: An Application for Precision Agriculture. *Computers, Materials & Continua*, 66(2), 1949–1962. <https://doi.org/10.32604/cmc.2020.012945>

- Maurice Eyssautier de la Mora. (2006). *METODOLOGIA DE LA INVESTIGACION* (Cengage Learning, Ed.; 5th ed.). <https://www.etp.com.py/libro/metodologia-de-la-investigacion-65079.html>
- MIDAGRI. (2022). *Commodities Cacao_ abr-jun 2022*. https://repositorio.midagri.gob.pe/bitstream/20.500.13036/1363/1/Commodities%20Cacao_%20abr-jun%202022.pdf
- Mohammad Yazdi Pusadan, Syahrullah, Merry, & Ahmad Imam Abdullah. (2022). k-Nearest Neighbor and Feature Extraction on Detection of Pest and Diseases of Cocoa. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 6(3), 471–480. <https://doi.org/10.29207/resti.v6i3.4064>
- Mushi, G. E., Di Marzo Serugendo, G., & Burgi, P.-Y. (2022). Digital Technology and Services for Sustainable Agriculture in Tanzania: A Literature Review. *Sustainability*, 14(4), 2415. <https://doi.org/10.3390/su14042415>
- Mzoughi, O., & Yahiaoui, I. (2023). Deep learning-based segmentation for disease identification. *Ecological Informatics*, 75, 102000. <https://doi.org/10.1016/j.ecoinf.2023.102000>
- Naranjo-Torres, J., Mora, M., Hernández-García, R., Barrientos, R. J., Fredes, C., & Valenzuela, A. (2020). A Review of Convolutional Neural Network Applied to Fruit Image Processing. *Applied Sciences*, 10(10), 3443. <https://doi.org/10.3390/app10103443>
- Palacios Bejarano, C. A., Afanador Kafuri, L., & Pardo García, J. M. (2021). Identificación de aislados de Phytophthora spp. obtenidos de cultivos de cacao en Antioquia, Colombia. *Acta Agronómica*, 70(1). <https://doi.org/10.15446/acag.v70n1.70619>
- Pandian, J. A., Kumar, V. D., Geman, O., Hnatiuc, M., Arif, M., & Kanchanadevi, K. (2022). Plant Disease Detection Using Deep Convolutional Neural Network. *Applied Sciences*, 12(14), 6982. <https://doi.org/10.3390/app12146982>
- Patrício, D. I., & Rieder, R. (2018). Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and Electronics in Agriculture*, 153, 69–81. <https://doi.org/10.1016/j.compag.2018.08.001>
- Picon, A., Seitz, M., Alvarez-Gila, A., Mohnke, P., Ortiz-Barredo, A., & Echazarra, J. (2019). Crop conditional Convolutional Neural Networks for massive multi-

crop plant disease classification over cell phone acquired images taken on real field conditions. *Computers and Electronics in Agriculture*, 167. <https://doi.org/10.1016/j.compag.2019.105093>

Roopashree, S., & Anitha, J. (2021). DeepHerb: A Vision Based System for Medicinal Plants Using Xception Features. *IEEE Access*, 9, 135927–135941. <https://doi.org/10.1109/ACCESS.2021.3116207>

Roy, S., Ray, R., Dash, S. R., & Giri, M. K. (2021). Plant Disease Detection Using Machine Learning Tools With an Overview on Dimensionality Reduction. In *Data Analytics in Bioinformatics* (pp. 109–144). Wiley. <https://doi.org/10.1002/9781119785620.ch5>

Samuel, O. S. (2022). Early Cocoa Blackpod Pathogen Prediction with Machine Learning Ensemble Algorithm based on Climatic Parameters. *Journal of Information and Organizational Sciences*, 46(1), 1–14. <https://doi.org/10.31341/jios.46.1.1>

Singh, V., Sharma, N., & Singh, S. (2020). Artificial Intelligence in Agriculture A review of imaging techniques for plant disease detection. *Artificial Intelligence in Agriculture*, 4.

Sociedad, U. Y., Martina López Cuadra, Y., Yannyna Cunias Rodríguez, M., Lizeth Carrasco Vega, Y., & Nacional Intercultural Fabiola Salazar Perú, U. (2020). *El cacao peruano y su impacto en la economía nacional*. <https://orcid.org/0000-0002-3522-0658>

Tan, D. S., Leong, R. N., Laguna, A. F., Ngo, C. A., Lao, A., Amalin, D., & Alvindia, D. (2016). A framework for measuring infection level on cacao pods. *2016 IEEE Region 10 Symposium (TENSYMP)*, 384–389. <https://doi.org/10.1109/TENCONSpring.2016.7519437>

Tan, D. S., Leong, R. N., Laguna, A. F., Ngo, C. A., Lao, A., Amalin, D. M., & Alvindia, D. G. (2018). AuToDiDAC: Automated Tool for Disease Detection and Assessment for Cacao Black Pod Rot. *Crop Protection*, 103, 98–102. <https://doi.org/10.1016/j.cropro.2017.09.017>

ultralytics. (2024). YOLOv8. <https://docs.ultralytics.com/es/models/yolov8/#can-i-benchmark-yolov8-models-for-performance>

- V., V., & Kumar, N. S. (2024). Deep Learning based Mango Leaf Disease Detection for Classifying and Evaluating Mango Leaf Diseases. *Fusion: Practice and Applications*, 15(2), 261–277. <https://doi.org/10.54216/FPA.150222>
- Wang, Y., Rajkumar Dhamodharan, U. S., Sarwar, N., Almalki, F. A., Naith, Q. H., R, S., & D, M. (2024). A hybrid approach for rice crop disease detection in agricultural IoT system. *Discover Sustainability*, 5(1), 99. <https://doi.org/10.1007/s43621-024-00285-4>
- Yang, S., Zheng, L., He, P., Wu, T., Sun, S., & Wang, M. (2021). High-throughput soybean seeds phenotyping with convolutional neural networks and transfer learning. *Plant Methods*, 17(1), 50. <https://doi.org/10.1186/s13007-021-00749-y>
- Zuidema, P. A., Leffelaar, P. A., Gerritsma, W., Mommer, L., & Anten, N. P. R. (2005). A physiological production model for cocoa (*Theobroma cacao*): model presentation, validation and application. *Agricultural Systems*, 84(2), 195–225. <https://doi.org/10.1016/j.agsy.2004.06.015>

ANEXOS

Anexo 1: Proceso de recolección de imágenes de frutos de cacao infectados por la enfermedad de la mazorca negra, para la conformación del Dataset.



Figura 17
Proceso de recolección de imágenes de frutos de cacao infectados



Figura 18
Identificación frutos de cacao con las diversas etapas de la enfermedad



Figura 19
Capturando imágenes de cacao infectados por la enfermedad (Etapa 1)



Figura 20
Capturando imágenes de cacao infectados por la enfermedad (Etapa 4)



Figura 21
Capturando imágenes de cacao saludable

Modelo de visión artificial basada en redes neuronales convolucionales para identificación de mazorca negra en plantaciones de cacao

por CRISTIAN VILLALOBOS CULQUI

Fecha de entrega: 26-jun-2025 09:46a.m. (UTC-0500)

Identificador de la entrega: 2706381290

Nombre del archivo: TESIS_Cristian_villalobos_culqui_26.06.2025.docx (6.28M)

Total de palabras: 12724

Total de caracteres: 75706

Modelo de visión artificial basada en redes neuronales convolucionales para identificación de mazorca negra en plantaciones de cacao

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	tesis.unsm.edu.pe Fuente de Internet	12%
2	repositorio.unsm.edu.pe Fuente de Internet	3%
3	Submitted to Centro Europeo de Postgrado - CEUPE Trabajo del estudiante	1%
4	revistas.unsm.edu.pe Fuente de Internet	1%
5	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	1%
6	repository.unad.edu.co Fuente de Internet	1%
7	hdl.handle.net Fuente de Internet	1%