



UNIVERSIDAD
CATÓLICA
DE CUENCA

UNIVERSIDAD CATÓLICA DE CUENCA

Comunidad Educativa al Servicio del Pueblo

**UNIDAD ACADÉMICA DE INFORMÁTICA,
CIENCIAS DE LA COMPUTACIÓN, E
INNOVACION TECNOLOGICA**

CARRERA DE TECNOLOGIA DE LA INFORMACION

**MODELO BASADO EN REDES NEURONALES
CONVOLUCIONALES (CNN) PARA LA DETECCIÓN Y
CLASIFICACIÓN DE LA MONILIASIS EN EL CACAO.**

**PROYECTO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERO EN TECNOLOGIAS DE LA
INFORMACIÓN**

AUTOR: DANIELA LISSBETH LOZANO OCHOA

**DIRECTOR: ING. MANUEL GUILLERMO RODRIGUEZ
LOPEZ**

LA TRONCAL - ECUADOR

2025

DIOS, PATRIA, CULTURA Y DESARROLLO



UNIVERSIDAD CATÓLICA DE CUENCA

Comunidad Educativa al Servicio del Pueblo

**UNIDAD ACADÉMICA DE INFORMÁTICA,
CIENCIAS DE LA COMPUTACIÓN, E
INNOVACION TECNOLOGICA**

CARRERA DE TECNOLOGIA DE LA INFORMACION

MODELO BASADO EN REDES NEURONALES
CONVOLUCIONALES (CNN) PARA LA DETECCIÓN Y
CLASIFICACIÓN DE LA MONILIASIS EN EL CACAO.

**PROYECTO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERO EN TECNOLOGIAS DE LA
INFORMACIÓN**

AUTOR: DANIELA LISSBETH LOZANO OCHOA

DIRECTOR: ING. MANUEL GUILLERMO RODRIGUEZ LOPEZ

LA TRONCAL - ECUADOR

2025

DIOS, PATRIA, CULTURA Y DESARROLLO

UNIDAD ACADÉMICA DE INFORMÁTICA, CIENCIAS DE LA COMPUTACIÓN E INNOVACIÓN TECNOLÓGICA

CARRERA DE INGENIERÍA EN TECNOLOGÍAS DE LA INFORMACIÓN

UNIDAD DE TITULACIÓN

La Troncal, 23 de agosto de 2025

Sección: U.A. de Informática, Ciencias de la Computación e Innovación Tecnológica
Asunto: Certificación y aprobación de presentación del Trabajo de Titulación

Señor Ingeniero
Marcos Orellana Parra. PhD
Responsable de la Unidad de Titulación
Ingeniería en Tecnologías de la Información

De mi consideración.

Reciba un cordial saludo y mis mejores deseos de éxito en sus funciones.

El suscrito, en calidad de tutor del trabajo de titulación, certifica que el trabajo titulado: “MODELO BASADO EN REDES NEURONALES CONVOLUCIONALES (CNN) PARA LA DETECCIÓN Y CLASIFICACIÓN DE LA MONILIASIS EN EL CACAO. “, desarrollado por el estudiante DANIELA LISSBETH LOZANO OCHOA, con numero de cedula 0928933787, ha sido guiado y revisado de manera periódica, cumpliendo con las normativas estatutarias establecidas por la Universidad Católica de Cuenca.

Particular que pongo en su conocimiento para los fines legales consiguientes. Sin otro particular me suscribo de Usted.

Atentamente,



ING. MANUEL GUILLERMO RODRIGUEZ LOPEZ
TUTOR

DECLARATORIA DE AUTORÍA Y RESPONSABILIDAD

DANIELA LISSBETH LOZANO OCHOA portador(a) de la cédula de ciudadanía N.º **0928933787**. Declaro ser el autor de la obra: **“MODELO BASADO EN REDES NEURONALES CONVOLUCIONALES (CNN) PARA LA DETECCIÓN Y CLASIFICACIÓN DE LA MONILIASIS EN EL CACAO”**, sobre la cual me hago responsable sobre las opiniones, versiones e ideas expresadas. Declaro que la misma ha sido elaborada respetando los derechos de propiedad intelectual de terceros y eximo a la Universidad Católica de Cuenca sobre cualquier reclamación que pudiera existir al respecto. Declaro finalmente que mi obra ha sido realizada cumpliendo con todos los requisitos legales, éticos y bioéticos de investigación, que la misma no incumple con la normativa nacional e internacional en el área específica de investigación, sobre la que también me responsabilizo y eximo a la Universidad Católica de Cuenca de toda reclamación al respecto.

La Troncal, **29 de agosto del 2025**

Daniela Lozano

F:

DANIELA LISSBETH LOZANO OCHOA

C.I. 0928933787

AGRADECIMIENTO

Quiero expresar mi más profundo agradecimiento a Dios, por iluminar mi camino, darme fuerza en los momentos difíciles y permitirme cumplir esta meta.

A mis padres, por ser mi apoyo incondicional, por sus enseñanzas, paciencia y amor infinito. Cada sacrificio y palabra de aliento han sido el motor que me impulsó a seguir adelante.

A mis familiares por el acompañamiento, ánimo constante y por celebrar conmigo cada logro, por más pequeño que fuera.

A mis docentes, por compartir generosamente su conocimiento, guiarme con paciencia y motivarme a superar cada obstáculo académico. Gracias por inculcarme la disciplina, la pasión por aprender y la búsqueda de la excelencia.

A mis amigos y compañeros de estudio, por su apoyo, comprensión y palabras de ánimo que hicieron más liviano este camino, en especial al grupito de 4 que siempre estuvieron apoyándome en los momentos más difíciles.

Finalmente, agradezco a todos aquellos que, de alguna manera, hicieron posible la realización de esta tesis. Cada gesto, palabra y acto de apoyo quedó plasmado en cada página de este trabajo.

DEDICATORIA

Este trabajo de tesis va dedicado especialmente a Dios, fuente de luz y fortaleza en mi camino, por regalarme la sabiduría y la paciencia necesarias para alcanzar esta meta.

A mis padres, mis guías y pilares fundamentales, por su amor infinito, por cada palabra de aliento, por su confianza y apoyo incondicional. En especial a mi madre, que nunca me dejó sola en los momentos más oscuros, enseñándome a ver la fe como motor de vida y esperanza, especialmente durante este proceso de tesis.

A mis abuelitas, cuyo ejemplo de trabajo, dedicación y amor me enseñó que los sueños se alcanzan con constancia y corazón.

A mis familiares, tías y primas, por cada gesto de cariño, por sus palabras valientes que me impulsaron a seguir adelante y por celebrar conmigo cada pequeño logro.

A mis docentes, por sembrar en mí el conocimiento, la disciplina y la pasión por aprender, recordándome que cada esfuerzo tiene su recompensa.

Esta tesis es el reflejo de días llenos de dedicación, noches de esfuerzo, momentos de duda y, sobre todo, el amor y la paciencia que me sostuvieron en cada paso. Es un logro compartido con todos aquellos que creyeron en mí y caminaron a mi lado en esta hermosa travesía.

RESUMEN

La moniliasis, causada por el hongo *Moniliophthora roreri*, una de las principales enfermedades que afectan a la producción de cacao en América Latina, provocando pérdidas significativas. La detección temprana de esta enfermedad es crucial para implementar estrategias de control efectivas y minimizar el impacto económico. Este trabajo presenta un modelo basado en redes neuronales convolucionales (CNN) para la detección y clasificación automática de la moniliasis en mazorcas de cacao mediante imágenes digitales.

Se recopilaron un total de 2.000 imágenes de cacao sano y afectado (moniliasis), las cuales fueron preprocesadas utilizando técnicas de aumento de datos, normalización y redimensionamiento. El modelo fue entrenado con una arquitectura secuencial de CNN, incluyendo capas convolucionales, de pooling, aplanamiento y densas, optimizado para clasificación binaria. La evaluación del desempeño del modelo se realizó mediante métricas de precisión, sensibilidad, puntaje F1 y matriz de confusión, logrando así una exactitud máxima de 98,3% en entrenamiento y 99% en validación.

Los resultados proporcionados evidencian que las CNN son herramientas eficaces para la identificación automatizada de la moniliasis, ofreciendo a los agricultores un recurso tecnológico que facilita la detección temprana y mejora la toma de decisión en el manejo de cultivos. Este estudio nos demuestra el gran potencial de la inteligencia artificial en la agricultura de precisión, contribuyendo a la sostenibilidad y productividad del cacao en el Ecuador.

Palabras clave: Moniliasis, Cacao, Redes Neuronales Convolucionales, Inteligencia Artificial, Visión por Computadora, Agricultura de Precisión.

ABSTRACT

Moniliasis, caused by *Moniliophthora roreri* fungus, is one of the main diseases affecting cocoa production in Latin America, leading to significant losses. Early detection of this disease is crucial for implementing effective control strategies and minimizing economic impact. This article presents a model based on convolutional neural networks (CNN) for automatic detection and classification of moniliasis in cocoa pods using digital images.

A total of 2,000 images of healthy and affected (moniliasis) cocoa were collected and preprocessed using data augmentation, data standardization, and resizing techniques. The model was trained with a sequential CNN architecture, including convolutional, pooling, flattening, and dense layers, optimized for binary classification. The model's performance was evaluated using precision, sensitivity, F1 score, and confusion matrix metrics, achieving a maximum accuracy of 98.3% in training and 99% in validation.

The above results show that CNNs are effective tools for the automated identification of moniliasis, providing farmers with a technological resource that facilitates early detection and improves decision-making in crop management. This study demonstrates the great potential of artificial intelligence in precision agriculture, contributing to the sustainability and productivity of cocoa in Ecuador.

Keywords: Moniliasis, Convolutional Neural Networks, Artificial Intelligence, Computer Vision, Precision Agriculture.

INDICE DE CONTENIDO

CERTIFICACION.....	iii
DECLARATORIA DE AUTORÍA Y RESPONSABILIDAD.....	iv
AGRADECIMIENTO	v
DEDICATORIA	vi
RESUMEN.....	vii
ABSTRACT	viii
INDICE DE CONTENIDO	ix
INDICE DE TABLAS	xi
INDICE DE GRAFICOS.....	xi
INTRODUCCIÓN.....	1
CAPÍTULO I:.....	2
1. Marco Referencial	2
1.1. Planteamiento del Problema	2
1.2. Formulación del Problema	2
1.3. Antecedentes de la investigación	2
1.4. Justificación de la investigación	4
1.5. Objetivos	4
1.5.1. Objetivo general.....	4
1.5.2. Objetivos Específicos	4
1.6. Limitaciones.....	4
1.7. Delimitaciones.....	5
CAPITULO II.....	6
MARCO TEÓRICO	6
CAPITULO III.....	14
3. Marco Metodológico	14
3.1. Enfoque de la Investigación.....	14
3.2. Nivel de la Investigación	14
3.3. Población y Muestra.....	14
3.4. Métodos de Investigación.....	15
3.5. Técnicas e instrumentos de recolección.....	15
3.6. Tratamiento de la información.....	15
CAPITULO IV	16

4. Resultados y análisis	16
4.1 Adquisición de datos (Imágenes).....	16
4.2 Preprocesamiento de las imágenes.....	17
4.3 Arquitectura de la Red Neuronal Convolutiva.....	19
4.4 Entrenamiento y evaluación del modelo	23
4.5 Grafico del entrenamiento.....	27
4.6 Clasificación de Imágenes.....	29
4.7 Visualización de Resultado	30
CAPÍTULO V.....	33
Conclusiones	33
Recomendaciones	34
Referencias.....	35

INDICE DE TABLAS

Tabla 1. Explicación de los parámetros del objeto ImageDataGenerator.....	18
Tabla 2. Se detallan las capas, sus parámetros principales y la función de cada una en el proceso de extracción de características y predicción de la enfermedad.....	20
Tabla 3. Predicción del estado del cacao (sano o enfermo) con sus probabilidades.....	29

INDICE DE GRAFICOS

Figura 1. Carpetas.....	16
Figura 2. Configuración del generador de datos (ImageDataGenerator).....	17
Figura 3. Datos Detectados.....	18
Figura 4. Modelo de la Red Neuronal.....	19
Figura 5. Compilación y entrenamiento del modelo: muestra la definición del optimizador, la función de pérdida y la métrica de evaluación, junto con la configuración de EarlyStopping para evitar sobreajuste durante 30 épocas de entrenamiento sobre los datos.....	23
Figura 6. Evolución del entrenamiento del modelo con parada anticipada.....	24
Figura 7. Progreso - Época 1.....	24
Figura 8. Progreso - Época 5.....	24
Figura 9. Progreso - Época 7.....	25
Figura 10. Progreso - Época 12.....	25
Figura 11. Tiempo total en CPU y tiempo real (wall time) para entrenar el modelo, con las 12 épocas.....	25
Figura 12. Tiempo de 30 épocas.....	26
Figura 13. Modelo Keras generado tras el entrenamiento.....	26
Figura 14. Genera la Precisión.....	27
Figura 15. Genera la Pérdida.....	28
Figura 16. Precisión y Pérdida del Modelo durante el Entrenamiento.....	28
Figura 17. Carga de imágenes nuevas.....	29
Figura 18. Se muestran la clase predicha y la probabilidad correspondiente.....	30
Figura 19. Resultado con imagen de las Mazorcas de Cacao.....	31
Figura 20. Resultado con imágenes nuevas.....	31
Figura 21. Resultado con el modelo ya generado y posteriormente subido, para mostrar rápidamente el resultado.....	32

INTRODUCCIÓN

La actividad cacaotera es crucial en el país, generando empleo e ingresos para miles de familias, llegando a ser unos de los motores para la economía nacional y producto de exportación clave para Ecuador y otras naciones latinoamericanas.

Sin embargo, estos cultivos presentan diversas enfermedades que afectan la cantidad como la calidad de la producción. Entre ellas la moniliasis, causada por *Moniliophthora roreri*, considerada una de las devastadoras, provocando pérdidas que pueden superar el 40% en zonas afectadas.

Comúnmente, para identificar la moniliasis se realiza de manera manual, lo que presenta limitaciones tales como: dependencia del conocimiento del personal, subjetividad en la evaluación y la lentitud en la detección, teniendo una dificultad a la intervención temprana. Debido a este desafío, la inteligencia artificial y en particular las Redes Neuronales Convolucionales (CNN), se presenta como herramientas útiles y prometedoras para automatizar el diagnóstico de enfermedades agrícolas mediante el análisis de imágenes digitales.

El objetivo de esta investigación es desarrollar un modelo basado en CNN, que nos permita la detección y clasificación de la moniliasis en las mazorcas de cacao, contribuyendo a optimizar la gestión de los cultivos y reducir las pérdidas económicas. Incluyendo la adquisición y preprocesamiento de imágenes, el diseño y entrenamiento del modelo, así como también la evaluación de desempeño mediante métricas estándar.

Este trabajo proporciona un aporte significativo al campo de la agricultura de precisión, demostrado que la inteligencia artificial puede integrarse en la gestión agrícola para mejorar la eficiencia, la sostenibilidad y la toma de decisión en el sector cacaotero ecuatoriano.

CAPÍTULO I:

1. Marco Referencial

1.1. Planteamiento del Problema

En la actualidad investigadores nos han demostrado que la *Moniliophthora Roreri*, es una enfermedad causada por hongos afectan la producción del cacao en América Latina, tanto así que reduce significativamente el rendimiento y calidad del producto final. Hoy en día para identificar la enfermedad se la realiza de forma manual, que a su vez puede generar errores humanos y retrasos en la implementación de medidas de control efectivas.

Investigaciones recientes han demostrado que la inteligencia artificial y las Redes Neuronales Convolucionales, pueden mejorar la detección de enfermedades agrícolas con alta precisión y rapidez. Según Morales [1], el uso de las CNN ha permitido identificar enfermedades en cultivos así mismo automatizar el proceso de monitoreo con un alto grado de exactitud, tanto así que permite reducir el tiempo de respuesta ante brotes de la enfermedad

1.2. Formulación del Problema

Actualmente, la identificación de la moniliasis en los cultivos de cacao se realiza de manera manual, lo cual implica un proceso lento, propenso a errores humanos y dependiente del conocimiento del personal en campo. Esta situación dificulta la detección temprana de la enfermedad, permitiendo su avance y generando considerables pérdidas en la producción y calidad del cacao.

Dado el impacto negativo de esta enfermedad en la economía agrícola, especialmente en zonas como La Troncal y El Triunfo, se vuelve necesario implementar herramientas tecnológicas que permitan una detección rápida, precisa y automatizada. Sin embargo, aún existen limitaciones en la adopción de soluciones basadas en inteligencia artificial en el ámbito rural, tanto por falta de recursos como por desconocimiento de sus beneficios.

1.3. Antecedentes de la investigación

Se han descubiertos que unas de las técnicas más favorables para la detección de enfermedades agrícolas, son las Redes Convolucionales (CNN), ya que tienen una mejor

capacidad de análisis de imágenes y reconocimiento de patrones. Morales [1] documentó el uso de CNN en el reconocimiento de enfermedades en los cultivos, demostrando que su implementación mejora la detección temprana de patógenos. Estudios previos han demostrado que la Moniliasis puede ser identificada con modelos de aprendizaje profundo entrenados con imágenes de resolución.

Yanac Montesino [2] destacó la combinación de CNN con aprendizaje automatizado supervisado, ya que ha mejorado significativamente la detección de enfermedades en las plantas. Estos avances del uso de las Redes Neuronales en la Agricultura de precisión, aumentan y fortalecen la importancia de seguir investigando nuevas metodologías para mejorar la producción y reducir pérdidas causadas por enfermedades como la Moniliasis. Algunos patógenos del cacao se limitan a regiones específicas del mundo, como el virus del brote hinchado del cacao (CSSV) en países de África Occidental, mientras que otros se están expandiendo geográficamente, como *Moniliophthora roreri* en América.

La *Moniliophthora roreri*, es uno de los patógenos más amenazantes del cacao, ya que ataca directamente a las mazorcas, provocando una reducción significativa de la producción y, por consiguiente, pérdidas económicas [3]...”.

El aprendizaje profundo (DL), es la rama del aprendizaje automático (ML) e inteligencia artificial (IA) es considerado como una tecnología básica de la Cuarta Revolución Industrial. Gracias a su capacidad de aprendizaje de los datos, la tecnología DL se originó en red neuronal artificial (ANN), se ha convertido en un tema de gran relevancia en el ámbito de la computación, y se aplica ampliamente en diversas áreas de aplicación como la salud, el reconocimiento visual, la analítica de texto, la ciberseguridad y muchos más [4]...”.

Es ilustra el Big Data y el profundo impacto de la IA en la mejora de la salud de los cultivos, ya que mejora la sostenibilidad y aumentar el rendimiento. Como estas tecnologías evolucionan y se vuelven más accesibles, su aplicación en la agricultura expandirse, trayendo una nueva era de la agricultura de precisión basada en datos. El Papel fundamental del Big Data y CNN en manejo de enfermedades del cacao es una demostración del poder transformador de la tecnología en la agricultura. Aprovechando las capacidades de estas herramientas avanzadas, la industria del cacao está estableciendo

un precedente para un futuro en el que la agricultura se guíe por datos, optimizado por la tecnología, y caracterizada por la sostenibilidad y la resiliencia [5].

1.4. Justificación de la investigación

La Moniliasis en el cacao presenta un desafío para los agricultores, afecta significativamente la producción y calidad del fruto, generando pérdidas económicas considerables en las regiones productoras como el Ecuador. Ya que la detección temprana de la enfermedad es esencial para reducir su impacto y así evitar la propagación descontrolada en las plantaciones. Unos de las combinaciones más efectivas han resultado ser la inteligencia artificial y las redes convolucionales (CNN), ya que nos han demostrado ser efectivas en la identificación automatizada de la enfermedad en el cultivo de cacao. El modelo de aprendizaje profundo, nos ayuda a mejorar en la precisión y rapidez en la detección de patologías, acelerando los procesos de monitoreo y facilitando en la toma de decisión.

1.5. Objetivos

1.5.1. Objetivo general

Desarrollar un modelo basado en CNN para la detección y clasificación de la moniliasis en el cacao, mediante el análisis de imágenes.

1.5.2. Objetivos Específicos

1. Recopilar y preprocesar imágenes de vainas de cacao sanas y afectadas por moniliasis, para la representación de las distintas etapas de la enfermedad.

2. Diseñar y entrenar un modelo de redes neuronales convolucionales (CNN) para la detección y clasificación automática de la moniliasis en las imágenes recopiladas y procesadas.

3. Evaluar y validar el desempeño del modelo mediante métricas de rendimiento y pruebas con imágenes reales capturadas en campo.

1.6. Limitaciones

Para la obtención de la información se han presentado ciertas limitaciones, que van desde la movilidad, la facilidad de acceso a los espacios de cultivos, hasta la negatividad de los propietarios de las zonas de interés para brindar información, situación que se presume está ligado a los altos índices de violencia que se presenta en el sector de estudio.

1.7. Delimitaciones

Este trabajo busca ser una herramienta de sustento tecnológico para el agro en el sector costanero de la provincia del cañar, cantón La Troncal y en la provincia del Guayas cantón El Triunfo, partiendo del objeto de estudio que es la detección de moniliasis como enfermedad que se presenta en los cultivos de cacao, se pretende coleccionar datos a través de captura de imágenes fotográficas en plantaciones existentes en los sectores antes mencionados, actividad que se desarrolla en el primer semestre del año 2025.

CAPITULO II

MARCO TEÓRICO

Nos damos cuenta que en la actualidad lo que esta revolucionado la industria es la Inteligencia Artificial, y a su vez la salud esta siendo mas impactada.

La IA generativa, el aprendizaje profundo y el aprendizaje automático, esta siendo explorado por los fundamentos de la IA con una impórtate atención.

En la actualidad podemos darnos cuenta que quien nos permite en la identificación de patrones en grandes conjuntos de datos, y también quien nos permite mejorar con el tiempo sin llegar a tener la necesidad de programación explicita es el subconjunto del aprendizaje automático.

Se entiende que el aprendizaje profundo, es un subcampo más avanzado, que siendo utilizado con las redes neuronales multicapas procesa información compleja [1]...”.

Indicamos que por décadas el lenguaje natural aplicado a la medicina, fue de interés principalmente académico. En el 2017 ocurrió un avance crucial, investigadores de Google presentaron el transformador, que consiste en una red neuronal diseñada para la traducción automática, que alcanza niveles de precisión sin precedentes.

Los modelos tradicionales del aprendizaje automático que requerían datos específicos para cada tarea, a hora los grandes modelos de lenguaje (LLM por sus siglas en inglés) evolucionaron y actualmente se entrenan mediante arquitecturas neuronales transformadoras a partir de textos ya existentes en internet.

Aquel entrenamiento es una tarea aparentemente sencilla, que nos permite proporcionar un volumen suficiente de textos para que el modelo aprenda las reglas del lenguaje humano, identifique las relaciones entre los conceptos presentes en dichos textos y sea capaz de predecir la siguiente palabra a partir de una secuencia previas [2]...”.

En las últimas décadas la inteligencia artificial ha transformado la investigación científica. Tanto así que tiene la capacidad para procesar grandes volúmenes de datos, ya que han revolucionado en áreas como las ciencias naturales y sociales, esto os permiten identificar patrones, la generación de predicción y la creación de nuevos modelos teóricos y metodológico.

Sin embargo, su implementación enfrenta desafíos importantes, entre ellos la falta de un enfoque sistemático y estandarizado.

El objetivo de la investigación es examinar las tendencias de investigación en este campo. En la evolución temática, desde la investigación sobre el estudio científico del lenguaje hasta ChatGPT e investigación remota, los términos emergentes y en crecimiento fueron IA generativa, integridad científica y ChatGPT. Asimismo, se recomienda profundizar en los conceptos clave, a fin de enfrentar desafíos y capitalizar las oportunidades que brinda la inteligencia artificial en el ámbito de la investigación científica [3]...”.

Uno de los desafíos clave en el sector agrícola, es la detección temprana de la mazorca negra en las plantaciones de cacao, tanto así que afecta el rendimiento y calidad del grano.

A falta de métodos avanzados, nos hace dificultar la identificación oportuna. Tanto que en este estudio se desarrolla, modelo de visión artificial basados en redes neuronales convolucionales, para así mejorar la detección [4]...”.

Los modelos precisos en la inteligencia artificial como las redes neuronales artificiales, son empelados en tareas de clasificación y regresión para el estudio de fenómenos naturales. Suele ser considerados como “cajas negras” ya que no permiten explicación directa de aquello que abordan. Este trabajo analiza la posibilidad de una explicación científica a través de estos modelos y concluye que requieren de otros esfuerzos para entender su funcionamiento interno [5]...”.

También nos damos cuenta que el aprendizaje automático, gracias a su capacidad a sabido aprovechar las técnicas computacionales para el aprendizaje experiencial, que a su vez a influido en diversas disciplinas como, los negocios y la administración.

El progreso de estos campos y la llegada de la Inteligencia Artificial nos presenta nuevos desafíos como la ambigüedad respecto a las áreas específicas de avance significativo y aquella con potencial de mayor desarrollo.

Este análisis nos revela un enfoque distintivo para emplear, apartando las clasificaciones habituales encontradas en la literatura, destacando cuatro dominios empresariales típicos: Finanzas, Marketing, Estrategia de la Empresa y Gestión de Recursos Humanos [6]...”.

Unas de las herramientas que rápidamente se convirtieron en poderosas en numerosos campos son el reconocimiento de imágenes y voz, también el procesamiento del lenguaje natural e incluso la medicina.

Actualmente la privacidad de los datos y así mismo la consideración ética, necesidades de transparencia en el proceso hacia la toma de decisión, nos damos cuenta que son desafíos asociados a la tecnología.

En la actualidad tenemos muchas tecnologías con gran importancia, pero resaltamos que en el campo de la inteligencia artificial tenemos dos más revolucionarias que son: el aprendizaje profundo y el aprendizaje automático.

Que, a su vez gracias a la capacidad para realizar predicciones, analizar grandes conjuntos de datos y proporcionar información que anteriormente era imposible obtener, llegan a tener mucha popularidad en los últimos años.

Lo que hoy en día está siendo crucial ya que está transformando la interacción con la tecnología y a su vez abriendo nuevas posibilidades de innovación es el aprendizaje automático y aprendizaje profundo. Tanto así que tiene un gran impacto muy significativo en diversas industrias, y tienen el potencial inmenso de seguir revolucionando el mundo [7]...”.

Nos ofrecen sistemas inteligentes como la inteligencia artificial, que suele basarse en el aprendizaje automático.

Tienen la capacidad de aprender de datos de entrenamiento específico de un problema con el fin de automatizar el proceso de construcción, en el modelo analítico y resolver tareas asociadas.

Las redes artificiales actualmente se basan en el aprendizaje profundo con el concepto de aprendizaje automático [8]...”.

Hemos descubierto que las causas de que el 80% de cacao se pierda, hasta llegar al punto de pérdida del 100% en épocas altas de infección, son dos principales: la escoba de bruja y monilia.

En las últimas décadas se ha observado el repunte de otras enfermedades debido a que hemos incrementado nuevas plantaciones, del punto de vista económico han querido poner de secundaria importancia.

Entre ellas destacan la mazorca negra, el mal de machete y la muerte regresiva, enfermedades que pueden provocar la pérdida de la unidad productiva [9]...”.

Ecuador ocupa el cuarto lugar en exportaciones de cacao con 293.487 toneladas anuales, producidas en 559.617 hectáreas. Sin embargo, el rendimiento por hectárea es bajo debido principalmente a la presencia de enfermedades que afectan las mazorcas. Su principal objetivo es evaluar diferentes métodos de control de patógenos en la mazorca de *Theobroma cacao*. El uso de fungicidas (tanto químicos como biológicos), disminuyó la incidencia de moniliasis (*Moniliophthora roreri*), pudrición negra de la mazorca (*Phytophthora* spp.), y marchitez de los frutos. Sin embargo, la aplicación de fertilizantes no incrementó la efectividad de estos productos. Se concluye que el control químico y biológico es efectivo para controlar lo patógenos de las mazorcas de cacao. Y la combinación de ambos métodos de control permite a los productores de cacao obtener mayores ingresos [10]...”.

El cacao (*Theobroma cacao* L.) perteneciente a la familia Sterculiaceae de gran relevancia en la economía de países en desarrollo, por sus diferentes usos y derivados que se le da al fruto. El principal factor es la perdida de cultivos y los bajos rendimientos de la producción son estrechamente relacionadas por las enfermedades: la escoba de bruja (*Moniliophthora perniciosa* Stahel), la moniliasis (*Moniliophthora roreri*) y la pudrición negra de la mazorca (*Phytophthora*). El desarrollo de estas enfermedades está influenciado por las condiciones ambientales las precipitaciones, la humedad relativa alta y temperaturas frescas crean un ambiente favorable para el desarrollo del patógeno, donde sus fuentes principales de inóculo son suelo, raíces, hojas, cojines florales, flores y frutos infectados [11]...”.

La moniliasis ha sido abordada desde la ciencia y la tecnología con el proyecto desarrollado en la Provincia de Orellana, donde la moniliasis es una enfermedad fúngica que causa efectos devastadores incluyen la pudrición de las flores, vainas y frutos de cacao, lo que conlleva pérdidas significativas a los agricultores. Unos de los mayores

problemas que afecta el cacao es la Moniliasis, tanto así que es difícil detectar en etapas tempranas.

Para un mayor logro en la detección de esta enfermedad, se recopilaron datos de sensores y registros manuales para a su vez entrenar y validar un modelo predictivo mediante aprendizaje supervisado, donde se procedió a analizar las condiciones ambientales y los síntomas de la enfermedad.

El presente estudio demuestra la eficacia de un modelo predictivo basado en aprendizaje supervisado para la detección de la moniliasis en plantas de cacao en la Provincia de Orellana. Los resultados obtenidos destacan la relevancia de emplear herramientas de análisis de datos en el ámbito agrícola, particularmente para la detección temprana de enfermedades que pueden afectar la producción y calidad de los cultivos [12]...”.

Lo que nos sirve para realizar la segmentación de imágenes digitales que actualmente utilizamos para la identificación y delimitación de áreas de cultivos, también para detectar y medir las características de las plantas y cultivos son la agricultura de precisión.

Es de gran importancia para los agricultores a la hora de tomar decisiones, informarse sobre el uso de recursos y la gestión de los cultivos.

Actualmente, la visión por computadora, rama de la Inteligencia artificial, se utiliza para procesar y analizar imágenes digitales con el objetivo de extraer información relevante. En la agricultura de precisión, esta tecnología permite analizar imágenes de los campos de cultivo y proporcionar información valiosa sobre la salud de las plantas, la calidad del suelo y otros factores que afectan la producción de los cultivos [13]...”.

Han comenzado a adoptar estas técnicas en datos biomédicos e imágenes radiológicas, ya que la inteligencia artificial ha repercutido en varios aspectos de la vida cotidiana, del aprendizaje profundo o también conocido Deep Learning.

Se espera que el aprendizaje profundo tenga un efecto en el proceso de adquisición e interpretación de imágenes, como en la toma de decisiones [14]...”.

Los métodos tradicionales son la manera más difícil de poder clasificar el uso del suelo y vegetación en un ejercicio complejo, por eso una de las alternativas son los modelos de aprendizaje, ya que debido a que son altamente capaces de aprender esta semántica compleja.

El objetivo de este estudio fue proponer y evaluar un modelo de red neuronales convolucional basado en aprendizaje profundo para la clasificación de 22 clases distintas de cobertura y uso del suelo en la cuenca río Atoyac-Salado.

El aprendizaje profundo mediante redes neuronales convolucionales permite identificar patrones en los datos, lo que facilita una clasificación más precisa [15]...”.

Las redes neuronales convolucionales en los últimos años, tienen una gran mejora en su desempeño, tanto que han sido numerosos los trabajos que se realizan y publican cada año, por todo el mundo.

Cuenta con la habilidad de clasificar una variedad bastante amplia en cuanto a identificación de imágenes las Redes neuronales convolucional, tanto así que puede llegar aplicaciones mucho más complejas.

Otra ventaja que tiene la red es la rapidez con la que realiza el proceso complejo sin tener una capacidad de cómputo muy elevada [16]...”.

Según estudios realizados nos damos cuenta que el cacao es de suma importancia para la economía y ecología a nivel mundial.

Y a su vez en la Latinoamérica se ve afectado por la enfermedad denominada “podredumbre helada de la mazorca de cacao”, causada por el hongo llamado *Moniliophthora roreri*, que la consideran la enfermedad más destructiva que ataca al cacao y lo mata.

Unos de los posibles causantes para la expansión del hongo en zonas previamente no afectadas, es el aumento de la temperatura o la precipitación debido al cambio climático global.

Por ende, recomendamos establecer un sistema de monitoreo que nos permita la alerta temprana y el control de brotes ante la destrucción de las plantaciones cacaotera [22]...”.

Las enfermedades del cacao constituyen una amenaza crítica para la producción mundial de chocolate, afectando los medios de vida de los agricultores y la industria del cacao. Entre estas enfermedades, *Moniliophthora Roreri*, comúnmente conocida como podredumbre helada de la mazorca, es una de las más devastadoras, causando pérdidas en la producción de cacao de hasta un 40%. La detección temprana de esta enfermedad es esencial para una intervención oportuna y minimizar su impacto económico. Este estudio explora el uso de algoritmos de aprendizaje automático (ML) para identificar la presencia de *Moniliophthora Roreri* en frutos de cacao, centrándose en la clasificación automática de sus cuatro etapas de desarrollo: jorobas, manchas aceitosas, manchas marrones y polvo blanco o esporulación. El enfoque se centró en la construcción y el entrenamiento de redes neuronales para detectar síntomas visuales de la enfermedad del cacao. Se recopilaron, procesaron y analizaron datos de imágenes de campo de mazorcas de cacao infectadas y sanas para mejorar el rendimiento del modelo. El estudio evaluó dos arquitecturas de redes neuronales, MobileNetV2 y Xception, para evaluar su eficacia y fiabilidad en la clasificación de frutos de cacao enfermos y no enfermos. Los resultados mostraron que MobileNetV2 logró un mejor desempeño que Xception, alcanzando una precisión de 0,94 y un F1-Score macropromedio de 0,95, lo que demuestra su potencial para la aplicación en el mundo real en plantaciones de cacao [23]...”.

La visión por computadora en el campo de la agricultura tiene como objetivo encontrar soluciones para garantizar y asegurar a los agricultores la calidad de sus productos. Por lo tanto, los estudios para diagnosticar enfermedades y detectar anomalías en los cultivos, a través de la visión por computadora, han estado creciendo en los últimos años. Sin embargo, cultivos como el cacao requirieron mayor atención para impulsar los avances en la visión por computadora para la detección de enfermedades.

Este trabajo nos permitió explorar un algoritmo de aprendizaje automático para detectar enfermedades, implementado en aplicaciones móviles y del Internet de las Cosas (IoT) con el fin de identificar enfermedades que afectan los cultivos de cacao [24]...”.

El presente trabajo aborda la problemática en el sector agrícola; la disminución de la producción del cacao a causa de la enfermedad de la moniliasis (*Moniliophthora roreri*) enfermedad que provoca pérdidas de hasta el 90% en los cacaotales y que como alternativa se desarrolla KÄKÄWOL (Cacaotales en lengua chontal), una aplicación móvil para Android que utiliza inteligencia artificial (IA) con modelos U-net y redes

neuronales convolucionales (CNN), en particular la arquitectura U-net, resultan especialmente adecuadas para la detección de la moniliasis en la mazorca de cacao. A diferencia de los modelos de clasificación tradicionales, que se limitan a determinar la presencia o ausencia de la enfermedad, U-net ofrece segmentación semántica precisa, lo que permite identificar las distintas etapas de desarrollo de la moniliasis dentro de una misma imagen.

Mientras que las Redes neuronales convolucionales estándar no alcanzan este nivel de detalle, U-net proporciona una representación visual y cuantitativa del progreso de la enfermedad, distinguiendo y etiquetando pixel por pixel las áreas correspondientes a diferentes clases. Esto posibilita reconocer simultáneamente las frases iniciales de puntos negros, el crecimiento de manchas y la aparición de hongo blanco superficial. El uso de U-net en este contexto ofrece un análisis más exhaustivo y detallado. No obstante, se reconoce que la adopción de esta tecnología sigue siendo limitada en ciertos sectores económicos del país, lo que resalta la importancia de ampliar su implementación para fortalecer el desarrollo agrícola [25]...”.

El uso del aprendizaje automático (ML) en la detección de enfermedades de los cultivos ha ganado mucha atención últimamente tanto en el ámbito académico como en la industria. Este documento postula que las técnicas de ML pueden emplearse para la detección temprana y el diagnóstico de las dos (2) principales enfermedades que afectan la producción de cacao, a saber, el brote hinchado y la mazorca negra. En este sentido, se diseña una aplicación móvil con técnicas de ML integradas para permitir a los productores de cacao tomar una fotografía de la mazorca de cacao y subirla para el diagnóstico, que se realiza en un servicio en la nube backend. La detección y el diagnóstico automáticos de enfermedades se basan en las redes neuronales convolucionales (CNN) para el análisis y la clasificación de imágenes. En el documento, se construyen y entrenan cuatro (4) modelos de CNN. El modelo con mejor rendimiento es SSD MobileNet V2 con una puntuación de detección de confianza superior al 80% [26]..”.

CAPITULO III

3. Marco Metodológico

3.1. Enfoque de la Investigación

Este trabajo de investigación tuvo un enfoque cuantitativo, ya que se trabajó con datos numéricos (imágenes transformadas en matrices) utilizando herramientas matemáticas y computacionales, con el fin de analizar y clasificar las imágenes.

También es de tipo aplicado, porque se propuso una solución rápida y tecnológica a un problema real como lo es la detección de la moniliasis en el cacao.

En la actualidad, gracias a las técnicas de la inteligencia artificial (IA), es posible detectar a tiempo el cáncer de pulmón. Con el único objetivo de dar a conocer y aclarar el panorama para futuros investigadores, para el desarrollo de una herramienta de detección del cáncer de pulmón, mediante IA e imágenes médicas. Pero lo que hoy en día es una de las opciones más prometedoras para la pronta detección son los modelos híbridos basados en redes neuronales convolucionales [17].

3.2. Nivel de la Investigación

Esta investigación tuvo un nivel propositivo, porque se desarrolló un modelo de redes neuronales convolucionales, para la solución y detección de la moniliasis.

También, tiene como componente descriptivo ya que previamente se analizaron las características visuales tanto de las frutas afectadas, como de aquellas que no presentaban la enfermedad.

3.3. Población y Muestra

La población estuvo conformada por imágenes de frutas de cacao, tanto sanas como afectadas por moniliasis. La muestra consistió en 1000 imágenes, recolectadas mediante capturas directa en fincas de producción de cacao, utilizando teléfono de gama alta. El muestreo fue de tipo no probabilístico por conveniencia, debido a que las imágenes se recolectan de acuerdo a la accesibilidad y disponibilidad de los cultivos.

3.4. Métodos de Investigación

Se utilizó el método deductivo, debido a que partió de las teorías y principios del aprendizaje profundo y del procesamiento de imágenes para aplicarlos al caso específico de la moniliasis en el cacao. Asimismo, se empleó el método analítico, al descomponer el modelo en sus respectivas etapas: adquisición de datos, preprocesamiento, modelado, entrenamiento y evaluación.

3.5. Técnicas e instrumentos de recolección

Se utilizó la técnica de observación directa, mediante la toma de fotografía en campo.

El instrumento principal fue un teléfono de gama alta, el cual permitió capturar imágenes de excelente calidad para el entrenamiento del modelo. Asimismo, se usaron herramientas computacionales como Python, junto con TensorFlow para el preprocesamiento de imágenes.

3.6. Tratamiento de la información

Los datos fueron organizados en carpetas: una de imágenes de frutas sanas y otra con imágenes de frutas afectadas por la moniliasis.

Se realizó el proceso de preprocesamiento, que incluyó redimensionamiento, normalización de píxeles y aumento de datos.

El modelo de redes neuronales convolucionales fue entrenado, validado y probado. Para la evaluación se emplearon métricas tales como precisión, sensibilidad, puntaje F1 y matriz de confusión, las cuales permitieron valorar el desempeño de las tareas de clasificación binaria.

El análisis de los resultados se ejecutó mediante el lenguaje de programación Python, dentro del entorno colaborativo de Google Colab, lo que facilitó la ejecución de los algoritmos y la gestión eficiente de los datos.

CAPITULO IV

4. Resultados y análisis

4.1 Adquisición de datos (Imágenes)

Para el desarrollo del modelo de detección de la moniliasis en el cacao, se recopiló un total de 2000 imágenes provenientes de las plantaciones ubicadas en los cantones La Troncal y El Triunfo, durante el primer semestre del año 2025.

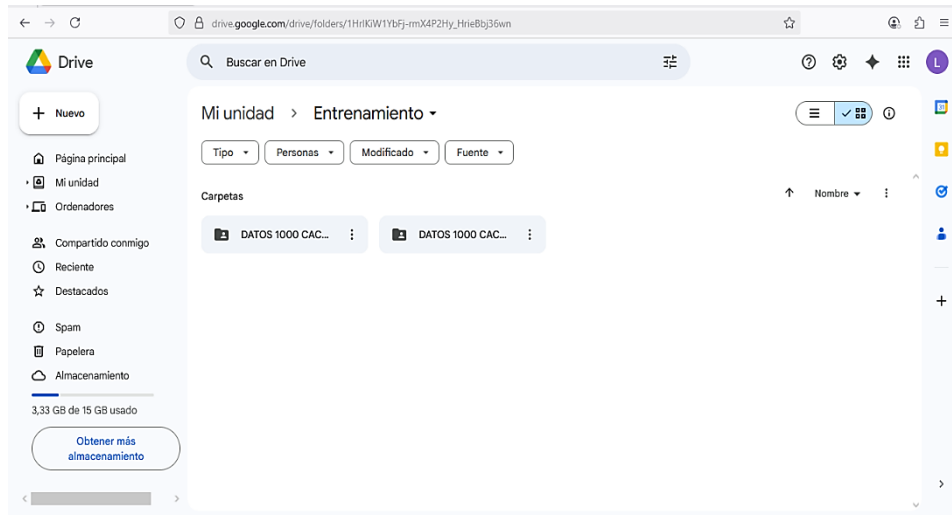


Figura 1. Carpetas

Fuente: Elaboración propia, (2025).

Las imágenes fueron organizadas en carpetas separadas dentro del directorio de entrenamiento en Google Drive: (/content/drive/MyDrive/Entrenamiento). Estas fueron capturadas con un dispositivo móvil de alta resolución, lo que aseguro una buena calidad visual para así facilitar el análisis de las características de las mazorcas.

Las imágenes se clasificaron en dos categorías:

Cacao sano 1000 imágenes

Cacao enfermo (moniliasis) 1000 imágenes

La clasificación se llevó a cabo de forma manual, identificando signos visibles de la enfermedad como manchas en la superficie de las mazorcas.

4.2 Preprocesamiento de las imágenes

Para el procesamiento de las imágenes se utilizó la clase (`ImageDataGenerator`) de Keras, aplicando técnicas de aumento de datos con el fin de incrementar la variabilidad del conjunto de entrenamiento y mejorar la capacidad de generalización del modelo.

Entre las técnicas se incluyeron:

Rotación: se aplicó un giro de las imágenes dentro de un rango determinado, eso permitió que el modelo reconociera detalladamente las características de la mazorca de cacao independientemente de su orientación en la fotografía

Traslación: se realizaron desplazamientos horizontales y verticales de las imágenes, simulando variaciones en la posición del objeto dentro del encuadre, con el objetivo de que la red neuronal aprendiera a identificar la enfermedad aun cuando la zona afectada no se encuentre centrada.

Zoom: se empleó un aumento aleatorio sobre las imágenes, lo que generó un acercamiento parcial que reforzó la capacidad del modelo para detectar patrones específicos de la enfermedad en distintos niveles de detalle.

Volteo horizontal: se invirtieron las imágenes de manera simétrica en el eje horizontal, lo que incremento la diversidad de dataset y reduciendo el riesgo de que el modelo memorice únicamente posiciones fijas de la mazorca.

```
datagen = ImageDataGenerator(  
    rescale=1./255,  
    validation_split=0.2,  
    rotation_range=20,  
    width_shift_range=0.1,  
    height_shift_range=0.1,  
    zoom_range=0.1,  
    horizontal_flip=True,  
)
```

Figura 2. Configuración del generador de datos (`ImageDataGenerator`)

Fuente: Elaboración propia, (2025).

Tabla 1. Explicación de los parámetros del objeto ImageDataGenerator

Línea de Código	Descripción académica
rescale=1. /255	Normaliza los valores de los píxeles en un rango entre 0 y 1, mejorando la eficiencia del entrenamiento y la estabilidad numérica del modelo.
validation_split=0.2,	Define que el 20% de las imágenes se utilicen para validación y el 80% restante para entrenamiento, permitiendo evaluar el desempeño del modelo en datos no vistos.
rotation_range=20,	Aplica una rotación aleatoria de hasta 20°, lo cual permite que el modelo reconozca patrones de la enfermedad en imágenes que no siempre están perfectamente alineadas.
width_shift_range=0.1,	Desplaza las imágenes horizontalmente hasta un 10% de su ancho, simulando cambios en la posición del objeto dentro del encuadre.
height_shift_range=0.1,	Desplaza las imágenes verticalmente hasta un 10% de su altura, generando ejemplos en los que la hoja o la mazorca no estén centradas.
zoom_range=0.1,	Aplica aumentos o reducciones aleatorias de hasta un 10%, permitiendo al modelo identificar patrones a distintas escalas y niveles de detalle.
horizontal_flip=True,	Realiza un volteo horizontal de las imágenes, incrementando la variabilidad del dataset y reduciendo la dependencia de posiciones fijas del objeto.

Fuente: Elaboración propia, (2025).

```
Found 1600 images belonging to 2 classes.
Found 400 images belonging to 2 classes.
CLASES: {'DATOS 1000 CACAO ENFERMO': 0, 'DATOS 1000 CACAO SANO': 1}
```

Figura 3. Datos Detectados

Fuente: Elaboración propia, (2025).

El generador de datos detectó 1600 imágenes para entrenamiento y 400 imágenes para validación, distribuidas en dos clases: cacao enfermo (0) y cacao sano (1).

La división del conjunto de datos fue del 80% para entrenamiento y 20% para validación.

Al aplicar las técnicas antes mencionadas, se permitió simular diferentes condiciones en las que podían ser capturadas las imágenes en un entorno real, contribuyendo así a que el modelo fuera más robusto y menos propenso al sobreajuste.

4.3 Arquitectura de la Red Neuronal Convolutiva

El modelo propuesto fue construido usando Keras con una arquitectura secuencial, compuesta por los siguientes elementos.

```
# Definir el modelo de la red neuronal
model = Sequential([
    Conv2D(32, (3, 3), activation='relu', input_shape=(224, 224, 3)),
    MaxPooling2D((2, 2)),
    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Flatten(),
    Dense(64, activation='relu'),
    Dense(1, activation='sigmoid')
])
```

Figura 4. Modelo de la Red Neuronal

Fuente: Elaboración propia, (2025).

```
# Definir el modelo de la red neuronal

model = Sequential([

    Conv2D(32, (3, 3), activation='relu', input_shape=(224, 224, 3)),

    MaxPooling2D((2, 2)),

    Conv2D(64, (3, 3), activation='relu'),

    MaxPooling2D((2, 2)),

    Flatten(),

    Dense(64, activation='relu'),

    Dense(1, activation='sigmoid')

])
```

Tabla 2. Se detallan las capas, sus parámetros principales y la función de cada una en el proceso de extracción de características y predicción de la enfermedad.

Capa	Parámetros principales	Función / Explicación
Conv2D (Capa 1)	32 filtros, kernel 3×3, activación ReLU, input_shape=(224, 224, 3)	Extrae características locales (bordes, texturas) de la imagen. input_shape define que las imágenes de entrada son de 224×224 píxeles con 3 canales RGB.
MaxPooling2D (Capa 1)	Pooling 2×2	Reduce la dimensionalidad manteniendo las características más importantes y disminuye la carga computacional.
Conv2D (Capa 2)	64 filtros, kernel 3×3, activación ReLU	Extrae características más complejas de la imagen, detectando patrones más altos y combinaciones de los anteriores.
MaxPooling2D (Capa 2)	Pooling 2×2	Reduce dimensionalidad de la segunda capa convolucional, manteniendo la información relevante.
Flatten	-	Aplana la salida 2D de las capas convolucionales a un vector 1D, para conectarlo con capas densas.
Dense (Oculto)	64 neuronas, activación ReLU	Capa totalmente conectada que interpreta los patrones extraídos. ReLU introduce no linealidad y mantiene solo valores positivos.
Dense (Salida)	1 neurona, activación Sigmoid	Produce la predicción final para clasificación binaria. La función Sigmoid entrega un valor entre 0 y 1 interpretado como probabilidad.

Fuente: Elaboración propia, (2025).

Capa 1: Conv2D (32 filtros, kernel 3x3, activación ReLU) + MaxPooling2D.

input_shape=(224, 224, 3)), : imágenes de entrada son de 224×224 píxeles con 3 canales RGB

Capa 2: Conv2D (64 filtros, kernel 3x3, activación ReLU) + MaxPooling2D.

Capa de Flatten: para aplanar las características extraídas.

Capa Densa Oculta: 64 neuronas con activación ReLU.

Capa de Salida: 1 neurona con activación Sigmoid (clasificación binaria).

1. Capa de Entrada (`input_shape=(224,224,3)`)

224×224 píxeles: es un estándar usado en muchas arquitecturas CNN, que nos facilita la compatibilidad con técnicas preentrenadas y procurar suficiente resolución para detectar detalles en las manchas del cacao.

3 canales (RGB): se usan imágenes a color en lugar de escala de grises. Esto es importante en mi caso porque el color y las variaciones de tonalidad en las mazorcas son una característica clave para diferenciar entre sanas y enfermas.

2. Capas Convolucionales + MaxPooling (bloques de extracción de características)

Conv2D (32 y 64 filtros): cada filtro es como una “lupa” que detecta patrones visuales (bordes, texturas, manchas).

Kernel 3×3: tamaño pequeño que permite capturar detalles locales de la imagen sin perder resolución.

MaxPooling (2×2): reduce el tamaño de la imagen (downsampling), conservando solo las características más relevantes y eliminando ruido.

3. Capa Densa Oculta: 64 neuronas con activación ReLU

Esta es una capa totalmente conectada (fully connected) que recibe la información procesada por las capas convolucionales y la interpreta. Tiene 64 neuronas, significa que cuenta con 64 unidades de procesamiento capaces de aprender patrones complejos de los datos.

ReLU (Rectified Linear Unit) es una función de activación que convierte todos los valores negativos en cero y mantiene los positivos tal cual.

Su uso es importante porque:

- Introduce **no linealidad** en la red, permitiendo que el modelo aprenda patrones más complejos.
- Es **computacionalmente eficiente** y evita problemas como el gradiente desvanecido que ocurren con funciones como la sigmoide o la tangente hiperbólica en capas ocultas.

Piensa en la ReLU como un filtro que “apaga” las señales negativas y deja pasar las positivas, enfocándose en la información más relevante para la clasificación.

4. Capa de Salida: 1 neurona con activación Sigmoid (clasificación binaria)

Esta capa es la última de la red y produce la predicción final.

1 neurona porque el problema es de clasificación binaria (solo dos clases: “mazorca sana” o “mazorca enferma”).

Función Sigmoid transforma el valor de salida en un número entre 0 y 1, interpretado como probabilidad.

- Por ejemplo, si la salida es 0.92, se interpreta como un 92% de probabilidad de que la mazorca sea sana (o enferma, según cómo se haya etiquetado la clase positiva).

La Sigmoid actúa como un “termómetro de probabilidad” que convierte el cálculo del modelo en un valor comprensible para decidir entre las dos clases.

4.4 Entrenamiento y evaluación del modelo

```
# Compilar el modelo
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])

# Configurar EarlyStopping
early_stop = EarlyStopping(monitor='val_loss', patience=5, restore_best_weights=True)

# Entrenar el modelo
model.fit(train_generator, epochs=30, validation_data=validation_generator, callbacks=[early_stop])
```

Figura 5. Compilación y entrenamiento del modelo: muestra la definición del optimizador, la función de pérdida y la métrica de evaluación, junto con la configuración de EarlyStopping para evitar sobreajuste durante 30 épocas de entrenamiento sobre los datos

Fuente: Elaboración propia, (2025).

Para la evaluación del desempeño del modelo se calcularon métricas de clasificación como: **Accuracy**, que indica el porcentaje de predicción correcta. **Precisión**, mide la proporción de verdaderos positivos sobre los positivos predichos. **Recall**, indica la capacidad del modelo para identificar todos los positivos reales. **F1-Score**, combina precisión y recall en un amétrica balanceada.

El modelo fue entrenado de 30 épocas con un mecanismo de parada anticipada (EarlyStopping) para evitar el sobreajuste, monitorizando la pérdida en el conjunto de validación.

En la figura 5: Aunque se configuro el entrenamiento para 30 épocas, el mecanismo de parada anticipada (EarlyStopping) interrumpió el proceso en la época 12, dado que a partir de ese punto no se observaron mejoras significativas en la pérdida de validación. Esto permitió optimizar el tiempo de entrenamiento y prevenir el sobreajuste del modelo.

Epoch 1/30
 50/50 ————— 77s 1s/step - accuracy: 0.5487 - loss: 4.0577 - val_accuracy: 0.7850 - val_loss: 0.4938
 Epoch 2/30
 50/50 ————— 71s 1s/step - accuracy: 0.8524 - loss: 0.4124 - val_accuracy: 0.8975 - val_loss: 0.2628
 Epoch 3/30
 50/50 ————— 78s 2s/step - accuracy: 0.8657 - loss: 0.3167 - val_accuracy: 0.9350 - val_loss: 0.1530
 Epoch 4/30
 50/50 ————— 73s 1s/step - accuracy: 0.9375 - loss: 0.1583 - val_accuracy: 0.9475 - val_loss: 0.1438
 Epoch 5/30
 50/50 ————— 81s 1s/step - accuracy: 0.9371 - loss: 0.1552 - val_accuracy: 0.9725 - val_loss: 0.0733
 Epoch 6/30
 50/50 ————— 71s 1s/step - accuracy: 0.9757 - loss: 0.0724 - val_accuracy: 0.9725 - val_loss: 0.0905
 Epoch 7/30
 50/50 ————— 72s 1s/step - accuracy: 0.9829 - loss: 0.0615 - val_accuracy: 1.0000 - val_loss: 0.0243
 Epoch 8/30
 50/50 ————— 71s 1s/step - accuracy: 0.9900 - loss: 0.0354 - val_accuracy: 0.9825 - val_loss: 0.0445
 Epoch 9/30
 50/50 ————— 72s 1s/step - accuracy: 0.9804 - loss: 0.0554 - val_accuracy: 0.9825 - val_loss: 0.0366
 Epoch 10/30
 50/50 ————— 71s 1s/step - accuracy: 0.9926 - loss: 0.0270 - val_accuracy: 0.9825 - val_loss: 0.0268
 Epoch 11/30
 50/50 ————— 78s 2s/step - accuracy: 0.9968 - loss: 0.0155 - val_accuracy: 0.9675 - val_loss: 0.0785
 Epoch 12/30
 50/50 ————— 78s 2s/step - accuracy: 0.9900 - loss: 0.0247 - val_accuracy: 0.9650 - val_loss: 0.0844

Figura 6. Evolución del entrenamiento del modelo con parada anticipada

Fuente: Elaboración propia, (2025).

Epoch 1/30
 50/50 ————— 77s 1s/step - accuracy: 0.5487 - loss: 4.0577 - val_accuracy: 0.7850 - val_loss: 0.4938

Figura 7. Progreso - Época 1

Fuente: Elaboración propia, (2025).

- **accuracy: 0.5487** → el modelo clasificó correctamente 54,87% de las imágenes de entrenamiento.
- **val_accuracy: 0.7850** → en el conjunto de validación, clasificó 78,5% correctamente.
- **loss alto al inicio (4.0577)**, normal al comenzar el entrenamiento.

Epoch 5/30
 50/50 ————— 81s 1s/step - accuracy: 0.9371 - loss: 0.1552 - val_accuracy: 0.9725 - val_loss: 0.0733

Figura 8. Progreso - Época 5

Fuente: Elaboración propia, (2025).

- **accuracy:** 0.9371 → el modelo ya aprende muy bien los datos de entrenamiento (93,7%).
- **val_accuracy:** 0.9725 → muy buena generalización a los datos de validación (97,25%).
- **val_loss:** 0.0733 → pérdida baja, lo que indica que las predicciones son precisas.

```
Epoch 7/30
50/50 ————— 72s 1s/step - accuracy: 0.9829 - loss: 0.0615 - val_accuracy: 1.0000 - val_loss: 0.0243
```

Figura 9. Progreso - Época 7

Fuente: Elaboración propia, (2025).

- **accuracy: 0.9829** y **val_accuracy: 1.0** → el modelo alcanza exactitud perfecta en validación.
- **val_loss: 0.0243** → muy bajo, indica predicciones muy correctas y consistentes.

```
Epoch 12/30
50/50 ————— 78s 2s/step - accuracy: 0.9900 - loss: 0.0247 - val_accuracy: 0.9650 - val_loss: 0.0844
```

Figura 10. Progreso - Época 12

Fuente: Elaboración propia, (2025).

- **accuracy: 0.9900** y **val_accuracy: 0.9650** → pequeñas variaciones, probablemente el EarlyStopping monitoreará **val_loss** para detener el entrenamiento si no mejora.

```
CPU times: user 14min 6s, sys: 23.2 s, total: 14min 29s
Wall time: 15min 56s
```

Figura 11. Tiempo total en CPU y tiempo real (wall time) para entrenar el modelo, con las 12 épocas

Fuente: Elaboración propia, (2025).

```

Epoch 7/30
50/50 ----- 83s 2s/step - accuracy: 0.9848 - loss: 0.0433 - val_accuracy: 0.8650 - val_loss: 0.2914
Epoch 8/30
50/50 ----- 84s 2s/step - accuracy: 0.9642 - loss: 0.1008 - val_accuracy: 0.9975 - val_loss: 0.0131
Epoch 9/30
50/50 ----- 82s 2s/step - accuracy: 0.9860 - loss: 0.0382 - val_accuracy: 0.9900 - val_loss: 0.0351
Epoch 10/30
50/50 ----- 82s 2s/step - accuracy: 0.9833 - loss: 0.0394 - val_accuracy: 0.9850 - val_loss: 0.0543
Epoch 11/30
50/50 ----- 84s 2s/step - accuracy: 0.9806 - loss: 0.0530 - val_accuracy: 0.9700 - val_loss: 0.0768
Epoch 12/30
50/50 ----- 85s 2s/step - accuracy: 0.9844 - loss: 0.0424 - val_accuracy: 1.0000 - val_loss: 0.0055
Epoch 13/30
50/50 ----- 85s 2s/step - accuracy: 0.9944 - loss: 0.0176 - val_accuracy: 0.9275 - val_loss: 0.1334
Epoch 14/30
50/50 ----- 88s 2s/step - accuracy: 0.9713 - loss: 0.0768 - val_accuracy: 0.9925 - val_loss: 0.0177
Epoch 15/30
50/50 ----- 85s 2s/step - accuracy: 0.9870 - loss: 0.0431 - val_accuracy: 0.9975 - val_loss: 0.0116
Epoch 16/30
50/50 ----- 85s 2s/step - accuracy: 0.9904 - loss: 0.0237 - val_accuracy: 1.0000 - val_loss: 0.0041
Epoch 17/30
50/50 ----- 85s 2s/step - accuracy: 0.9947 - loss: 0.0137 - val_accuracy: 0.9975 - val_loss: 0.0082
Epoch 18/30
50/50 ----- 84s 2s/step - accuracy: 0.9989 - loss: 0.0082 - val_accuracy: 1.0000 - val_loss: 0.0038
Epoch 19/30
50/50 ----- 82s 2s/step - accuracy: 1.0000 - loss: 0.0049 - val_accuracy: 0.9975 - val_loss: 0.0110
Epoch 20/30
50/50 ----- 83s 2s/step - accuracy: 0.9993 - loss: 0.0041 - val_accuracy: 0.9975 - val_loss: 0.0044
Epoch 21/30
50/50 ----- 83s 2s/step - accuracy: 0.9964 - loss: 0.0116 - val_accuracy: 1.0000 - val_loss: 0.0046
Epoch 22/30
50/50 ----- 83s 2s/step - accuracy: 1.0000 - loss: 0.0037 - val_accuracy: 0.9950 - val_loss: 0.0148
Epoch 23/30
50/50 ----- 85s 2s/step - accuracy: 1.0000 - loss: 0.0016 - val_accuracy: 1.0000 - val_loss: 8.0229e-04
Epoch 24/30
50/50 ----- 83s 2s/step - accuracy: 0.9957 - loss: 0.0083 - val_accuracy: 0.9875 - val_loss: 0.0383
Epoch 25/30
50/50 ----- 83s 2s/step - accuracy: 0.9724 - loss: 0.0741 - val_accuracy: 1.0000 - val_loss: 0.0064
Epoch 26/30
50/50 ----- 83s 2s/step - accuracy: 0.9866 - loss: 0.0391 - val_accuracy: 1.0000 - val_loss: 0.0090
Epoch 27/30
50/50 ----- 83s 2s/step - accuracy: 0.9910 - loss: 0.0190 - val_accuracy: 0.9950 - val_loss: 0.0173
Epoch 28/30
50/50 ----- 84s 2s/step - accuracy: 0.9986 - loss: 0.0071 - val_accuracy: 1.0000 - val_loss: 0.0026
CPU times: user 36min 7s, sys: 47.7 s, total: 36min 55s
Wall time: 1h 2min 35s

```

Figura 12. Tiempo de 30 épocas

Fuente: Elaboración propia, (2025).




Figura 13. Modelo Keras generado tras el entrenamiento

Fuente: Elaboración propia, (2025).

Como dato importante, debido a que la ejecución de las épocas requirió un tiempo prolongado (aproximadamente 1 hora) para completarse, como se muestra en la **Figura 12**, se optó por descargar el modelo Keras generado tras el entrenamiento. Posteriormente, para agilizar la obtención de resultados en las pruebas y visualizaciones, se cargó directamente la carpeta del modelo entrenado denominada “**mi_modelo.keras**”, lo que permitió reducir considerablemente el tiempo de procesamiento y mostrar de manera más rápida los resultados obtenidos.

4.5 Grafico del entrenamiento

Para generar mi grafico de precisión y perdida se utilizo el siguiente código:

```
# Gráfico 1: Accuracy (precisión)
plt.subplot(1,2,1)
plt.plot(history['accuracy'], label='Entrenamiento')
plt.plot(history['val_accuracy'], label='Validación')
plt.title('Evolución de la Precisión (Accuracy)')
plt.xlabel('Épocas')
plt.ylabel('Accuracy')
plt.legend()
plt.grid(True)
```

Figura 14. Genera la Precisión

Fuente: Elaboración propia, (2025).

- **plt.plot(history['accuracy'])**: curva de precisión en entrenamiento.
- **plt.plot(history['val_accuracy'])**: curva de precisión en validación.
- Se agregan título, etiquetas de ejes y leyenda.
- **plt.grid(True)** añade la cuadrícula para facilitar la lectura.

```

# Gráfico 2: Pérdida (Loss)
plt.subplot(1,2,2)
plt.plot(history['loss'], label='Entrenamiento')
plt.plot(history['val_loss'], label='Validación')
plt.title('Evolución de la Pérdida (Loss)')
plt.xlabel('Épocas')
plt.ylabel('Loss')
plt.legend()
plt.grid(True)

plt.tight_layout()
plt.show()

```

Figura 15. Genera la Pérdida

Fuente: Elaboración propia, (2025).

- Muestra la **pérdida (loss)** tanto en entrenamiento como en validación.
- Igual que antes, se agregan título, etiquetas y leyenda.

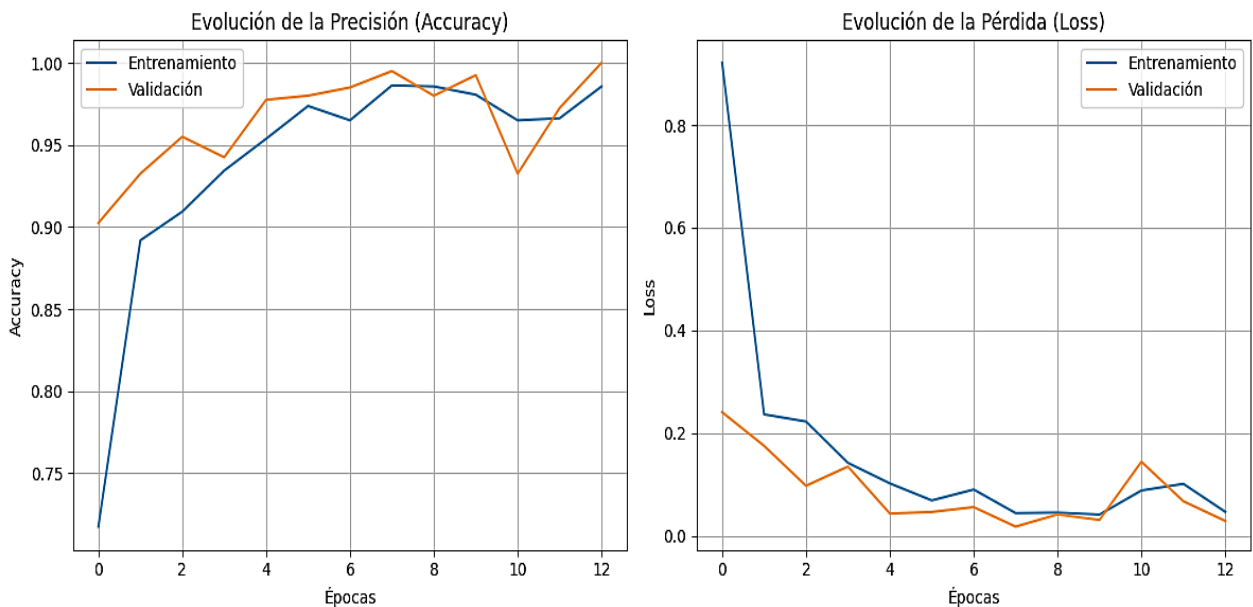


Figura 16. Precisión y Pérdida del Modelo durante el Entrenamiento

Fuente: Elaboración propia, (2025).

Izquierda: Figura 16. Precisión (Accuracy), mostro un incremento rápido en las primeras épocas, alcanzando valores superiores al 95%, mientras que la curva de validación mantuvo una tendencia similar, lo que evidencia una adecuada capacidad de generalización.

Derecha: Figura 16. Perdida (Loss), disminuyó de manera progresiva tanto en entrenamiento como en validación, estabilizándose en las últimas épocas, lo que indicó que el modelo no presentó sobreajuste significativo.

4.6 Clasificación de Imágenes

Para evaluar el rendimiento del modelo entrenado, se utilizó un conjunto de imágenes independiente que no formó parte del proceso de entrenamiento ni de validación.

```
print("▲ Sube varias imágenes desde tu computadora...")
uploaded = files.upload()
```

Figura 17. Carga de imágenes nuevas

Fuente: Elaboración propia, (2025).

Para evaluar el modelo, se cargaron imágenes nuevas usando `files.upload()` y se preprocesaron al mismo tamaño y escala que las utilizadas durante el entrenamiento (224x224 píxeles, normalización a [0, 1]).

Tabla 3. Predicción del estado del cacao (sano o enfermo) con sus probabilidades.

Imagen	Clase Predicha	Probabilidad
IMG_0912.JPG	Cacao enfermo por moniliasis	100.00%
IMG_0935.JPG	Cacao sano	100.00%

Precisión y Robustez: El modelo mostró un desempeño sólido en la clasificación binaria, distinguiendo entre mazorcas sanas y enfermas, con niveles altos de precisión visualmente comprobables.

Errores comunes: En algunos casos, imágenes con iluminación deficiente o parcialmente ocultas pudieron afectar la predicción.

Mejoras potenciales: Una limitación del estudio es la calidad y cantidad de imágenes disponibles, así como el preprocesamiento aplicado. Futuras mejoras podrían incluir la optimización de la arquitectura de la red, añadiendo más capas convolucionales, ajustando hiperparámetros o empleando modelos preentrenados como MobileNetV2 o EfficientNet mediante transferencia de aprendizaje.

4.7 Visualización de Resultado

```
1/1 ----- 2s 2s/step
📷 Imagen: IMG_1122.JPG
📊 Predicción: DATOS 1000 CACAO SANO
📊 Probabilidad: 100.00%
-----
1/1 ----- 0s 29ms/step
📷 Imagen: IMG_1128.JPG
📊 Predicción: DATOS 1000 CACAO SANO
📊 Probabilidad: 100.00%
-----
1/1 ----- 0s 28ms/step
📷 Imagen: IMG_1136.JPG
📊 Predicción: DATOS 1000 CACAO ENFERMO
📊 Probabilidad: 100.00%
-----
1/1 ----- 0s 28ms/step
📷 Imagen: IMG_1137.JPG
📊 Predicción: DATOS 1000 CACAO ENFERMO
📊 Probabilidad: 100.00%
-----
1/1 ----- 0s 29ms/step
📷 Imagen: IMG_1129.JPG
📊 Predicción: DATOS 1000 CACAO ENFERMO
📊 Probabilidad: 99.96%
-----
```

Figura 18. Se muestran la clase predicha y la probabilidad correspondiente

Fuente: Elaboración propia, (2025).



Figura 19. Resultado con imagen de las Mazorcas de Cacao

Fuente: Elaboración propia, (2025).



Figura 20. Resultado con imágenes nuevas.

Fuente: Elaboración propia, (2025).



Figura 21. Resultado con el modelo ya generado y posteriormente subido, para mostrar rápidamente el resultado

Fuente: Elaboración propia, (2025).

CAPÍTULO V

Conclusiones

La presente investigación demostró la relevancia de las redes neuronales convolucionales (CNN), como una alternativa eficaz para la detección y clasificación de la moniliasis en el cacao.

El modelo alcanzó un máximo nivel de precisión durante el entrenamiento y la validación. Los hallazgos clave muestran que las CNN son eficaces para diferenciar entre mazorca de cacao sanas y enfermas (moniliasis). Además, se observó que un buen preprocesamiento y la calidad de las imágenes influyeron directamente en el desempeño del modelo

El modelo propuesto clasificó con precisión las mazorcas en categorías de sanas y enfermas, mostrando un desempeño favorable en las pruebas realizadas, gracias al potencial como herramienta tecnológica para apoyar a los agricultores en la identificación temprana de la enfermedad.

Uno de los pasos determinante para la calidad del modelo fue el proceso de adquisición y preprocesamiento de imágenes. A su vez la recolección fotográfica en campo, aumento de datos y la normalización de imágenes permitieron mejorar la capacidad de generalización del sistema.

La calidad y cantidad limitada de imágenes restringe el desempeño del modelo. Futuras mejoras podrían incluir optimizar la arquitectura de la red, ajustar hiperparámetros o usar modelos preentrenados como MobileNetV2 o EfficientNet mediante transferencia de aprendizaje.

Adoptar estas innovaciones tecnológicas puede transformar la agricultura de precisión en Ecuador, impulsando la producción sostenible de cacao y reduciendo los impactos económicos de la moniliasis. Además, estos resultados motivan a futuras investigaciones que incluyan más factores, como variedades de cacao, condiciones climáticas y técnicas de manejo agrícola, para mejorar aún más la detección y control de la enfermedad.

Recomendaciones

Para mejorar la capacidad predictiva del modelo, se sugiere incrementar el tamaño del conjunto de datos mediante la inclusión de imágenes de distintas variedades de cacao, en diferentes condiciones climáticas y estados de desarrollo de la enfermedad.

Además, se recomienda el diseño de un prototipo de aplicación móvil o sistema web, que integre el modelo entrenado, permitiendo la toma de fotografías directamente en campo y generando un diagnóstico inmediato. Para optimizar el desempeño y reducir el consumo de recursos, sería beneficioso explorar el uso de técnicas de transferencia de aprendizaje con modelos preentrenados como MobileNetV2 O EfficientNet.

Asimismo, se deben realizar pruebas de validación en campo, involucrando agricultores y técnicos en condiciones reales de producción, para garantizar la utilidad del sistema, su aceptación y su impacto en la toma de decisión para reducción de pérdida.

De igual manera, es importante impulsar programas de capacitación en inteligencia artificial aplicada al agro, dirigidos a productores y estudiantes de áreas agrícolas y tecnológicas, para promover la adopción de estas herramientas en zonas rurales.

Finalmente, para futuros estudios, se sugiere combinar visión por computadora con datos ambientales (humedad, temperatura, precipitaciones), lo que permitiría brotes de la enfermedad de forma temprana y crear sistemas de alerta preventiva.

Referencias

- [1] M. Morales , J. Morocho, X. Lopez y P. Navas, Aplicación de Redes Neuronales Convolucionales para la Detección de Enfermedades en el Fruto de Cacao CCN-51 mediante una Aplicación Móvil, Springer International Publishing AG, 2024.
- [2] R. Yanac Montesino , J. L. Castillo - Sequera y J. A. Rosales - Huamani, «Detección de Phytophthora palmivora en frutos de cacao con aprendizaje profundo,» de *Conferencia Ibérica de Sistemas y Tecnologías de la Información (CISTI)*, Chaves, Portugal, 2021.
- [3] B. M. Reyes, P. L. Fonseca, N. M. Heming, L. B. Concepcion, K. T. Nascimento, K. P. Gramacho, E. Arevalo - Gardini, C. P. Pirovani y E. R. Aguiar, «"La caracterización de la dinámica de la microbiota asociada a Moniliophthora roreri, agente causal de la enfermedad de la pudrición helada de la mazorca del cacao, revela nuevas especies virales",» *Fronteras en Microbiología*, vol. 13, 2023.
- [4] I. H. Sarker, «Aprendizaje profundo: Una visión general de técnicas, taxonomía, aplicaciones e instrucciones de investigación",» *Springer Nature*, vol. 2, nº 420, 2021.
- [5] A. M. A, The Role of Big Data and CNNs in Cocoa Disease Management, Americas New York: Simon & Schuster, 2024.
- [6] R. R. Guzman, *Fundamentos de la inteligencia artificial*, Airbus España, Madrid, España: Sociedad Española de Senología y Patología Mamaria, 2025.
- [7] J. Bonis Sanz y R. Bravo Toledo, *Inteligencia artificial en atención primaria: ¿amiga o enemiga?*, Madrid, España: Elsevier, 2025.
- [8] E. A. Rodríguez Flores, L. F. Garcés Giraldo, J. Valencia y A. Valencia-Arias, «"Tendencias de investigación en el uso de técnicas de inteligencia artificial en la investigación científica",» *Revista Venezolana de Gerencia (RVG)*, vol. 30, nº 109, pp. 351 - 380, 2025.
- [9] C. Villalobos-Culqui, C. García-Rivas-Plata, y O. A. Tuesta Hidalgo, «"Modelo de visión artificial basado en redes neuronales convolucionales para la identificación de mazorcas negras en plantaciones de cacao",» *Revista Científica de Sistemas e Informática*, vol. 5, nº 1, 2025.
- [10] A. E. Rodríguez-Sánchez, «"La posibilidad de explicación científica a partir de modelos basados en redes neuronales artificiales",» *Revista Colombiana de Filosofía de la Ciencia*, vol. 24, nº 48, 2024.
- [11] A. Batz, D. F. D'Croz - Barzon, C. J. Vega Perez y C. A. Ojeda Sanchez, «"Integrar el aprendizaje automático en los negocios y la gestión en la era de la inteligencia artificial",» *Comunicación en Humanidades y Ciencias Sociales*, vol. 12, nº 1, 2025.
- [12] K. Sharifani y M. Amini, «"Aprendizaje automático y aprendizaje profundo: una revisión de métodos y aplicaciones",» *Revista Mundial de Tecnología de la Información e Ingeniería*, vol. 10, nº 07, pp. 3897-3904, 2023.

- [13] C. Janiesch, P. Zschech y K. Heinrich, «Machine learning and deep learning,» *Springer Nature*, vol. 31, p. 685–695, 2021.
- [14] Z. K. Solís Hidalgo, S. L. Peñaherrera Villafuerte y D. I. Vera Coello, *Las enfermedades del cacao y las buenas prácticas agronómicas para su manejo*, Mocache, provincia de Los Rios. Ecuador: Mocache, EC: INIAP, Estación Experimental Tropical Pichilingue, 2021.
- [15] V. Anzules-Toala, E. Pazmiño-Bonilla, L. Alvarado-Huamán, R. Borjas-Ventura, V. Castro-Cepero y A. Julca-Otiniano, «"Control de enfermedades del cacao (Theobroma cacao) en Santo Domingo de los Tsachilas, Ecuador",» *Agronomía Mesoamericana*, vol. 33, nº 1, 2022.
- [16] M. A. Guamán Villa, E. E. Jaramillo Aguilar y J. Bernal Morales, «"CONTROL BIOLÓGICO DE LA MAZORCA NEGRA (PHYTOPHTHORA PALMIVORA L.) EN EL CULTIVO DE CACAO (THEOBROMA CACAO L.)",» *Revista Metropolitana de Ciencias Aplicadas*, vol. 5, nº 3, pp. 195-154, 2022.
- [17] D. J. Castillo Lapo, M. N. Ramírez Cambo, W. G. Chango Sailema y P. S. Aguilar Encarnación, «"Desarrollo de un modelo predictivo utilizando técnicas de aprendizaje supervisado para detectar la moniliasis en plantas de cacao de la Provincia de Orellana",» *Revista Tecnológica Espol –RTE*, vol. 35, nº 3, pp. 46-67, 2023.
- [18] P. Ponce, M. Pusda Chulde y M. Ortega Bustamante , «Segmentación de imágenes agrícolas adquiridas con dron mediante algoritmos paralelos,» *INNOVATION & DEVELOPMENT IN ENGINEERING AND APPLIED SCIENCES*, vol. 4, nº 2, p. 16, 2023.
- [19] F. Lubinus Badillo, C. A. Rueda Hernandez, B. M. Narvaez y Y. E. Arias Trillos, «Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema,» *Rev. colomb. radiol*, vol. 32, nº 3, pp. 5591-5599, 2021.
- [20] R. Montiel Gonzales, M. Bolaños Gonzalez , A. Macedo Cruz , A. Rodriguez Gonzales y A. Lopez Perez , ««Clasificación De Uso Del Suelo Y vegetación Con Redes Neuronales Convolucionales»,» *Revista Mexicana De Ciencias Forestales*, vol. 13, nº 74, 2022.
- [21] A. Cifuentes , E. Mendoza , M. Lizcano, A. Santrich y S. Moreno-Trillos, «"Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes",» *Investigación y Desarrollo en TIC*, vol. 10, nº 2, pp. 7-17, 2019.
- [22] S. Ortega Andrade , G. Paez, T. Feria y J. Muñoz, «El cambio climático y el riesgo de propagación del hongo de la alta mortalidad de Theobroma cacao en América Latina,» *Biodiversidad neotropical*, vol. 3, nº 1, pp. 30 - 40, 2017.
- [23] J. Alvaro, J. F. Restrepo - Arias, D. Velasquez, J. D. Martinez - Vargas y M. Maiza, «Agricultura de precisión aplicada al cacao: Soluciones de aprendizaje automático para la clasificación de Moniliophthora Roreri,» de *Sistemas inteligentes y difusos*, Medellin, Colombia, 2025.

- [24] J. Alvarado, J. F. Restrepo - Arias, D. Velasquez y M. Maikel, «Detección de enfermedades en cultivos de cacao mediante técnicas de visión artificial: una revisión sistemática de la literatura,» *MDPI*, vol. 15, nº 10, 2025.
- [25] A. Aquino Ruíz, D. M. León De la O, R. García Mínguez, C. R. Muñoz Rodríguez, J. N. Garrido Vázquez y C. A. Arellano Cruz, «Uso de U-Net Y Redes Neuronales Convolucionales para la Detección de la Moniliasis (*Moniliophthora Roreri*) en Mazorcas De Cacao,» *Ciencia Latina Revista Científica Multidisciplinar*, vol. 9, nº 1, 2025.
- [26] S. Kumi, D. Kelly, J. Woodstuff, R. K. Lomotey, R. Orji y R. Deters, «Cocoa Companion: Aplicación para teléfonos inteligentes basada en aprendizaje profundo para la detección de enfermedades del cacao,» *Revistas Científicas (ASJC)*, vol. 203, nº 8, pp. 87-94, 2022.
- [27] R. Tueros, C. Canepa, C. Muñoz y Y. Guzman, «"Revisión Sistemática de Técnicas De Inteligencia Artificial para Detección de Cáncer Pulmonar en Imágenes Médicas",» *Revista Científica Emprendimiento Científico Tecnológico*, nº 5, 2024.
- [28] R. Yanac Montesino, J. A. Rosales - Huamani y J. L. Castillo - Segura, «"Detección de la phytophthora palmivora en el fruto del cacao utilizando aprendizaje profundo",» *Scopus*, 2021.



AUTORIZACIÓN DE PUBLICACIÓN EN EL REPOSITORIO INSTITUCIONAL

Daniela Lissbeth Lozano Ochoa portador(a) de la cédula de ciudadanía N° **0928933787**. En calidad de autor/a y titular de los derechos patrimoniales del proyecto de titulación **“MODELO BASADO EN REDES NEURONALES CONVOLUCIONALES (CNN) PARA LA DETECCIÓN Y CLASIFICACIÓN DE LA MONILIASIS EN EL CACAO.”** de conformidad a lo establecido en el artículo 114 Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, reconozco a favor de la Universidad Católica de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos y no comerciales. Autorizo además a la Universidad Católica de Cuenca, para que realice la publicación de éste proyecto de titulación en el Repositorio Institucional de conformidad a lo dispuesto en el artículo 144 de la Ley Orgánica de Educación Superior.

La Troncal, **27 de octubre de 2025**

Daniela Lozano

F:

Daniela Lissbeth Lozano Ochoa

C.I. 0928933787