



UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

CARRERA DE INGENIERÍA EN INFORMÁTICA Y SISTEMAS
COMPUTACIONALES

PROYECTO DE INVESTIGACIÓN

**IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING
APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao*
PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ,
PROVINCIA DE COTOPAXI**

Proyecto de Investigación presentado previo a la obtención del Título de Ingeniería en
Informática y Sistemas Computacionales.

Autoras:

Bustamante Ochoa Maria Jose
García Peña María José

Tutor:

Ing. MSc. Bajaña Zajia Johnny Xavier

LA MANÁ - ECUADOR
MARZO - 2021

DECLARACIÓN DE AUTORÍA

Nosotras, Bustamante Ochoa Maria Jose con C.I. No: 055071536-1 y García Peña María José con C.I. No: 235083592-8, declaramos ser autoras del presente proyecto de investigación: **“IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI”**, siendo el MSc. Bajaña Zajia Johnny Xavier, tutor del presente trabajo; y eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales.

Además, certifico que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo, son de nuestra exclusiva responsabilidad.

Atentamente,


Bustamante Ochoa Maria Jose
C.I: 055071536-1

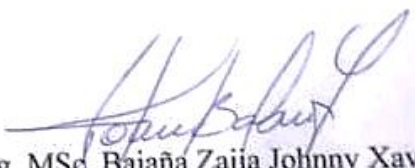

García Peña María José
C.I:235083592-8

AVAL DEL TUTOR DE PROYECTO DE INVESTIGACIÓN

En calidad de tutor del trabajo de Investigación sobre el título:

"IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI", de Bustamante Ochoa Maria Jose y García Peña María José de la carrera Ingeniería en Informática y Sistemas Computacionales, considero que dicho Informe Investigativo cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos a la evaluación del Tribunal de Validación de Proyecto que el Honorable Consejo Académico de la Facultad Académica de Ciencias de la Ingeniería y Aplicadas de la Universidad Técnica de Cotopaxi designe, para su correspondiente estudio y calificación.

La Maná, Marzo de 2021



Ing. MSc. Bajaña Zajia Johnny Xavier
CI: 120482711-5
TUTOR

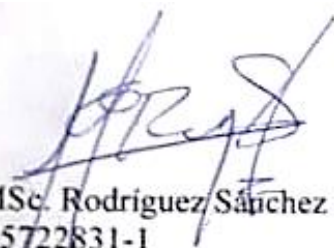
APROBACIÓN DEL TRIBUNAL DE TITULACIÓN

En calidad de Tribunal de Lectores, aprueban el presente informe de investigación de acuerdo a las disposiciones reglamentarias emitidas por la Universidad Técnica de Cotopaxi, y por la Facultad de **CIENCIAS DE LA INGENIERÍA Y APLICADAS**; por cuanto a las postulantes **BUSTAMANTE OCHOA MARIA JOSE Y GARCÍA PEÑA MARÍA JOSÉ** con el título de proyecto de Investigación: **“IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI”**, han considerado las recomendaciones emitidas oportunamente y reúne los méritos suficientes para ser sometido al acto de sustentación del proyecto.

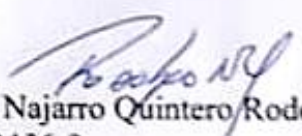
Por lo antes expuesto, se autoriza realizar los empastados correspondientes, según la normativa institucional.

La Maná, Marzo del 2021

Para constancia firman:



Ing. MSc. Rodríguez Sánchez Edel Ángel
CI: 175722831-1
LECTOR 1 (PRESIDENTE)



Ing. MSc. Najarro Quintero Rodolfo
CI: 172523456-9
LECTOR 2 (VOCAL)



Ing. MSc. Córdova Vaca Alba Marisol
CI: 180409377-9
LECTOR 3 (SECRETARIA)

AGRADECIMIENTO

Quiero expresar mi más sincero agradecimiento a Dios, por estar cuidándome en cada momento de mi vida, guiándome por el camino del bien y brindándome la sabiduría para realizar cada actividad.

Y por último mi más sentido y profundo agradecimiento en especial a mi amada familia Bustamante Ochoa, quienes son el pilar fundamental en mi vida, gracias por su apoyo en esta larga y ardua experiencia universitaria. A mis padres José David y Cecibel Angélica por cada esfuerzo que realizaron para culminar mi formación universitaria y enseñarme que todo lo que me proponga lo puedo lograr, a mis hermanas Mayra Alejandra, Vanessa Estefania y Leylis Eliana por su paciencia, dedicación y amor ... por ellos gracias familia.

Bustamante M.

Gracias a Dios por permitirme tener y disfrutar de mi familia, siempre protegiéndome y por estar conmigo en cada paso que doy, por fortalecer mi corazón e iluminar mi mente y por haber puesto en mi camino a aquellas personas que han sido mi soporte y compañía durante todo mi trayecto de vida. A mis padres y familiares por su apoyo incondicional en los buenos y malos momentos que he pasado, gracias por haberme cuidado y ayudado en toda mi formación profesional y vida.

Peña M.

DEDICATORIA

Mi proyecto de investigación lo dedico llena de amor, esperanza y mucho sacrificio a mis seres amados, los cuales han sido la inspiración para culminar con mucho éxito y regocijo.

A Dios por guiarme y cuidarme, a mi padre José David Bustamante Chichandi por su sacrificio, confianza, esfuerzo y esmero siendo el pilar fundamental en mi formación profesional, a mi madre Cecibel Angélica Ochoa Montiel por su amor, paciencia y la motivación en cada actividad que realice, y a mis hermanas Mayra Alejandra Bustamante Ochoa por su esfuerzo, cuidado y confianza, Vanessa Estefanía Bustamante Ochoa y Leylis Eliana Bustamante Ochoa por ser consideradas, tenerme y el amor que me brindan. Por su esfuerzo y sacrificio familia este proyecto es por ustedes!!!.

Bustamante M.

Le dedico primeramente mi trabajo a mis padres que siempre me apoyaron incondicionalmente en la parte moral y económica para poder llegar a ser un profesional de la Patria.

A la Universidad Técnica de Cotopaxi en conjunto con todo su equipo de colaboradores, en especial a los docentes de la carrera de Ingeniería en Informática y Sistemas Computacionales, por guiarnos hacia una educación de excelencia.

Peña M.

UNIVERSIDAD TÉCNICA DE COTOPAXI

FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS

TÍTULO: "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI".

Autoras:

Bustamante Ochoa María José
García Peña María José

RESUMEN

En la actualidad los procesos Machine Learning aplicados en el campo de la agricultura está teniendo un gran éxito en diversos aspectos, estos incluyen la detección de diversas enfermedades de las plantas dentro del sector agrícola, para lograr esta precisión se requiere contar con métodos rápidos y eficaces de detección y evaluación de enfermedades de los frutos. Existe una gran variedad de microorganismos que causan enfermedades al cultivo del *Theobroma cacao L.*, siendo que los hongos se constituyen como unos de los principales grupos, existe una cantidad de 8000 especies de hongos que producen variedades de enfermedades en el fruto, lo cual pueden reproducirse con mayor intensidad cuando existe una gran concentración de humedad. El presente proyecto tiene como objetivo determinar las enfermedades y el porcentaje de precisión en la mazorca de cacao, mediante una aplicación móvil que contiene modelos de inteligencia artificial de tipo Deep Learning. Gracias al desarrollo de esta aplicación móvil se contribuye con el agricultor que no tiene cognición de las enfermedades que afectan al cultivo de cacao, los profesionales agrícolas realizan pruebas eficientes mediante cámaras húmedas y por microscopio para identificar que patógenos infecciosos está afectando al fruto.

Palabras claves: Machine Learning, Deep Learning, Modelos, Enfermedades, *Theobroma Cacao L.*

TECHNICAL UNIVERSITY OF COTOPAXI

FACULTY OF ENGINEERING AND APPLIED SCIENCES

TITLE: "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI".

Authors:

Bustamante Ochoa María José
García Peña María José

ABSTRACT

Nowadays, Machine Learning processes applied in the field of agriculture are having great success in various aspects, these include the detection of various plant diseases within the agricultural sector, to achieve this accuracy is required to have fast and effective methods of detection and evaluation of fruit diseases. There is a great variety of microorganisms that cause diseases to the crop of *Theobroma cacao L.*, and fungi are one of the main groups, there are 8000 species of fungi that produce varieties of diseases in the fruit, which can reproduce more intensely when there is a high concentration of moisture. This project aims to determine the diseases and the percentage of accuracy in the cocoa pod, using a mobile application that contains artificial intelligence models of Deep Learning type. Thanks to the development of this mobile application contributes to the farmer who has no cognition of the diseases that affect the cacao crop, agricultural professionals perform efficient tests using wet cameras and microscopy to identify which infectious pathogens are affecting the fruit.

Keywords: Machine Learning, Deep Learning, Models, Diseases, *Theobroma Cacao*.

AVAL DE TRADUCCIÓN

En calidad de Docente del Centro Cultural de Idiomas de la Universidad Técnica de Cotopaxi, Extensión La Maná; en forma legal CERTIFICO que: La traducción de la descripción del Proyecto de Investigación al Idioma Inglés presentado por las señoritas: Bustamante Ochoa María José y García Peña María José cuyo título “IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI”; lo realizó bajo mi supervisión y cumple con una correcta estructura gramatical del Idioma.

Es todo cuanto puedo certificar en honor a la verdad y autorizo al peticionario hacer uso del presente certificado de la manera ética que estimare conveniente.

La Maná, Marzo del 2021



Mg. Ramón Amores Sebastián Fernando

CI: 050301668-5

COORDINADOR CENTRO CULTURAL DE IDIOMAS UTC LA MANÁ

ÍNDICE

Contenido

DECLARACIÓN DE AUTORÍA	ii
AVAL DEL TUTOR DE PROYECTO DE INVESTIGACIÓN	iii
APROBACIÓN DEL TRIBUNAL DE TITULACIÓN.....	iv
<i>AGRADECIMIENTO</i>	v
<i>DEDICATORIA</i>	vi
RESUMEN	vii
ABSTRACT	viii
AVAL DE TRADUCCIÓN.....	ix
ÍNDICE.....	x
ÍNDICE DE TABLA	xiv
ÍNDICE DE GRÁFICOS.....	xv
ÍNDICE DE FIGURA	xvi
ÍNDICE DE ANEXOS	xvii
1. INFORMACIÓN GENERAL	1
2. RESUMEN (DESCRIPCIÓN) DEL PROYECTO	2
3. JUSTIFICACIÓN DEL PROYECTO.....	3
4. BENEFICIARIOS DEL PROYECTO	4
5. PROBLEMA DE INVESTIGACIÓN.....	5
6. OBJETIVOS.....	6
5.1. Objetivo General	6
5.2. Objetivos Específicos	6
6. ACTIVIDADES Y SISTEMA DE TAREAS EN RELACIÓN A LOS OBJETIVOS PLANTEADOS	7
7. FUNDAMENTACIÓN CIENTÍFICO TÉCNICA.....	8
7.1. Antecedentes de la investigación	8

7.2.	Base teórica	10
7.2.1.	Implementación	10
7.2.2.	Inteligencia Artificial (IA).....	10
7.2.3.	Modelos Machine Learning.....	11
7.2.3.1.	Tipos de Machine Learning.....	11
7.2.4.	Redes Neuronales Artificiales (ANN).....	12
7.2.5.	Convolutional Neuronal Network (CNN)	13
7.2.5.1.	Convolución	14
7.2.5.2.	Pooling.....	14
7.2.6.	EL CACAO (<i>Theobroma cacao</i> L)	14
7.2.6.1.	Importancia.....	14
7.2.6.2.	Enfermedades que afectan al cacao.....	15
7.2.7.	Epidemiología	18
7.2.8.	Huertas Agroecológicas	18
7.3.	HERRAMIENTAS DE DESARROLLO	19
7.3.1.	Jupyter Notebook para IA	19
7.3.2.	Google Colab.....	19
7.3.4.	Python.....	20
7.3.5.	Sistema operativo más usado en el mercado	21
7.3.6.	Entorno de desarrollo Android Studio.....	21
7.3.7.	Lenguaje de programación Java	21
8.	METODOLOGÍAS DE INVESTIGACIÓN.....	22
8.1.	Métodos de investigación.....	22
8.1.1.	Método Documental	22
8.1.2.	Método analítico sintético	22
8.1.3.	Método deductivo.....	22
8.2.	Tipos de Investigación.....	23

8.2.1.	Investigación Bibliográfica	23
8.2.2.	Investigación de Campo.	23
8.2.3.	Investigación Aplicada	23
8.3.	Técnica de Investigación	24
8.3.1.	Entrevista.....	24
8.3.2.	Encuesta.....	24
8.3.3.	Observación.....	24
8.4.1.	Población	24
8.4.2.	Muestra de la encuesta	25
8.4.3.	Muestra de los datos (imágenes)	27
9.	ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS.....	27
9.1.	Resultados de la entrevista Aplicada.....	28
9.2.	Resultados de la encuesta Aplicada.....	29
9.3.	Diseño de la propuesta	31
9.3.1.	Plan de Ataque.....	31
9.3.2.	Arquitectura de Modelo.....	32
9.3.3.	Normalization y Data Augmentation.	34
9.3.4.	Entrenamiento del modelo.....	35
9.3.5.	Entrenamiento de la Red Neuronal Convolutiva de Arquitectura DenseNet	37
9.3.6.	Aplicación móvil con TensorFlow en Android nativo.....	40
9.3.7.	Configuración de entorno	43
9.3.8.	Gestión de la base de datos en el entorno de desarrollo (Datasets).....	44
9.3.9.	Implementación de la red convolutiva entrenada por proceso de transfer learning en Android.....	45
9.3.10.	Implementación del modelo clasificador de enfermedades del cacao en sistemas Android.....	51
9.3.11.	Evaluación obtenidos dentro de la fase de entrenamientos	56

9.3.12.	Resultado Obtenidos en la fase de pruebas en la aplicación Android.....	60
10.	IMPACTO DEL PROYECTO.	60
11.	PRESUPUESTO PARA LA PROPUESTA DEL PROYECTO.....	61
12.	CONCLUSIONES Y RECOMENDACIONES	62
13.	BIBLIOGRAFÍA.....	64
14.	ANEXOS.....	68
15.	CERTIFICADO DE REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO.....	105

ÍNDICE DE TABLA

Tabla 1. Beneficiarios directos e indirectos.....	4
Tabla 2. Actividades y sistema de tareas en relación a los objetivos planteados	7
Tabla 3. Población	25
Tabla 4. Distribución de la muestra por segmentos.....	26
Tabla 5. Personas que intervienen en el proyecto de investigación	27
Tabla 6. Resultados de la Aplicación de la Encuesta	29
Tabla 7. Argumentos de ficheros TensorFlow	47
Tabla 8. Tasas de aprendizaje y cantidad En pasos	49
Tabla 9. Argumentos de los ficheros a procesar	50
Tabla 10. Resultados del Clasificador implementado en Android	60
Tabla 11. Presupuesto del proyecto	61
Tabla 12. ¿Cuáles son las enfermedades más comunes de cacao que afectan a su cultivo? ...	78
Tabla 13. ¿Usted sabe reconocer estas enfermedades en su cultivo?	79
Tabla 14. ¿Cuál ha sido su experiencia con las aplicaciones móviles?	80
Tabla 15. ¿Conoce usted una aplicación móvil que identifique las enfermedades del cultivo de cacao?	81
Tabla 16. ¿Considera usted que una aplicación móvil orientada al campo agrícola aportara al sector productivo cacaotero?	82
Tabla 17. ¿Cree usted que las aplicaciones móviles dirigidas al campo agrícola permitirán reducir el tiempo utilizado por el agricultor para poder identificar una plaga o enfermedad en el cultivo del cacao?	83
Tabla 18. ¿Cree usted que las aplicaciones móviles incrementaran los niveles de información que se obtienen acerca de la plaga o enfermedad identificada; en sectores de producción agrícola?.....	84

ÍNDICE DE GRÁFICOS

Gráfico 1. Bloques DenseNet	33
Gráfico 2. Multiplicado de Imagen Data Augmentation	35
Gráfico 3. Método Gradiente Descendente	37
Gráfico 4. Aplicación Ejecutada en un Terminal Virtual Android.....	53
Gráfico 5. IDE Android Studio Cámara Activity	55
Gráfico 6. Gráfico de precisión de época del Modelo IA.....	58
Gráfico 7. Gráfico de pérdida de época del Modelo IA	58
Gráfico 8. Gráfico de disminución del error por época	59
Gráfico 9. Gráfico de exactitud cercano a uno	59
Gráfico 10. ¿Cuáles son las enfermedades más comunes de cacao que afectan a su cultivo? 78	
Gráfico 11. ¿Usted sabe reconocer estas enfermedades en su cultivo?	79
Gráfico 12. ¿Cuál ha sido su experiencia con las aplicaciones móviles?.....	80
Gráfico 13. ¿Conoce usted una aplicación móvil que identifique las enfermedades del cultivo de cacao?.....	81
Gráfico 14. ¿Considera usted que una aplicación móvil orientada al campo agrícola aportara al sector productivo cacaotero?	82
Gráfico 15. ¿Cree usted que las aplicaciones móviles dirigidas al campo agrícola permitirán reducir el tiempo utilizado por el agricultor para poder identificar una plaga o enfermedad en el cultivo del cacao?	83
Gráfico 16. ¿Cree usted que las aplicaciones móviles incrementaran los niveles de información que se obtienen acerca de la plaga o enfermedad identificada; en sectores de producción agrícola?.....	84

ÍNDICE DE FIGURA

Figura 1. Plan de Ataque	31
Figura 2. Modelo de Predicción	32
Figura 3. Arquitectura de Modelo	33
Figura 4. Red Convolutacional DenseNet.....	33
Figura 5. Pre-entrenado Imagenet	34
Figura 6. Multiplicado de Imagen Data Augmentation.....	35
Figura 7. Spoch de Entrenamiento	36
Figura 8. Entrenamiento de Intuición.....	36
Figura 9. Ecuacion Binary Cross Entropy.....	37
Figura 10. Steps de Entrenamiento 60 Épocas (Spoch)	38
Figura 11. Script de Steps de Entrenamiento 60 Épocas (epochs)	38
Figura 12. Proceso de Evaluación	39
Figura 13. Matriz de Confusión.....	40
Figura 14. Dependencia de TensorFlow.....	41
Figura 15. Clase Interpreter para la carga de modelo.....	42
Figura 16. Clase Mapped Byte	42
Figura 17. ByteBufer de directorio.....	43
Figura 18. Inicializador de Interpreter para la salida de datos	43
Figura 19. Código de arquitectura MobileNet.....	48
Figura 20. Script de optimización mediante la API TensorFlow	49
Figura 21. Etiquetas obtenidas en la clase del clasificador	50
Figura 22. Almacenamiento de Fichero de Etiquetas.....	51
Figura 23. Proceso de conversión para la obtención de mejores resultados	52
Figura 24. Clase de tipo ImageClassifier.java.....	53
Figura 25. Clase de tipo Grafico Matplotlib.....	57
Figura 26. Número total de predicciones alcanzadas	57

ÍNDICE DE ANEXOS

Anexo 1. Currículun Vitae Docente tutor MSc. Bajaan Johnny Xavier	68
Anexo 2. Currículun Vitae Autora Bustamante María José.....	71
Anexo 3. Currículun Vitae Autora García María José.....	73
Anexo 4. Formato de la entrevista Aplicada	75
Anexo 5. Formato de la encuesta realizada a los agricultores cacaotero de La Maná	76
Anexo 6. Resultados de la tabulación de los datos de la encuesta	78
Anexo 7. Arquitectura de desarrollo del proyecto de Investigación	85
Anexo 8. Socialización de las actividades a realizar en el campus Sasha Wiwa UTC	85
Anexo 9. Técnica de la Observación paso numero 1	86
Anexo 10. Técnica de la Observación paso numero 2	86
Anexo 11. Informe técnico de las enfermedades	87
Anexo 12. Red Neuronal Convolutcional	91
Anexo 13. Inicio.....	91
Anexo 12. Visualizando Imagen de dataset	91
Anexo 13. Visualizando imagenes	92
Anexo 14. Pre procesamiento de datos	92
Anexo 15. Resultados de Data augmentation.....	92
Anexo 16. Carga de dataset TEST sin aplicar data argumentation	93
Anexo 17. Construcción de la Red Neuronal Artificial	93
Anexo 18. Congelar los params en el Feature Extractor.....	93
Anexo 19. Agregado el clasificador propio.....	94
Anexo 20. Entrenando la Red Neuronal Artificial	94
Anexo 21. Entrenando la Red Neuronal Convolutcional	94
Anexo 22. Grafica del resultado de entrenamiento	95
Anexo 23. Evaluación de la Red Neuronal Artificial.....	95
Anexo 24. Interfaz del archivo manifest en Android Studuio.....	95
Anexo 25. Interfaz y código de la aplicación móvil en Android Studio	96
Anexo 26. Implementación del clasificador MobilNet.Java de las imágenes en Android Studio	96
Anexo 27. Implementación del clasificador EfficientNet.Java de las imágenes en Android Studio.....	96
Anexo 28. Código de los métodos de la cámara Activity	97

Anexo 29. Librerías adicionales en Gradle de Android Studio.....	97
Anexo 30. Pruebas de la aplicación móvil en el campo	97
Anexo 31. Manual de usuario.....	98

1. INFORMACIÓN GENERAL

Título del Proyecto:

"Implementación de modelos Machine Learning aplicados al estudio de enfermedades del *Theobroma cacao* para huertas agroecológicas del Cantón La Maná, Provincia de Cotopaxi".

Fecha de inicio: Noviembre 2020

Fecha de finalización: Marzo 2021

Lugar de ejecución: Cantón La Maná, Provincia de Cotopaxi

Unidad académica que auspicia: Facultad de Ciencias de la Ingeniería y Aplicadas

Carrera que auspicia: Ingeniería en Informática y Sistemas Computacionales

Proyecto de investigación vinculado: Universidad Técnica de Cotopaxi Extensión La Maná

Equipo de trabajo:

Estudiante: Bustamante Ochoa Maria Jose
Correo: maria.bustamante3561@utc.edu.ec
Teléfono: 0961544960
Estudiante: García Peña María José
Correo: maria.garcia5928@utc.edu.ec
Teléfono: 0988094650
Tutor: MSc. Bajaña Zajia Johnny Xavier
Correo: johnny.bajana@utc.edu.ec
Teléfono: 0996179534

Área de conocimiento: Desarrollo de Software

Línea de Investigación: Tecnologías de la Información y Comunicación (TICs).

Los proyectos de investigación que se enmarquen en esta línea tendrán como objetivo desarrollar tecnologías y herramientas informáticas de apoyo a la incorporación de planes y programas de desarrollo, utilizar las TICs para la optimización y sistematización de procesos y diseñar tanto software como sistemas informáticos y métodos de inteligencia artificial.

Sub líneas de investigación de la carrera: Inteligencia artificial e inteligencia de negocios.

2. RESUMEN (DESCRIPCIÓN) DEL PROYECTO

Los procesos de aprendizaje automático aplicados en el campo de la agricultura tienen éxito en diversos aspectos, en los que detectan diversas enfermedades de las plantas en el sector agrícola, para alcanzar la tecnología de precisión en el campo es necesario procedimientos y eventos, para lograrlo, ejemplo los robots, imágenes de satélite con drones., esto es posible con métodos rápidos y eficientes para detectar y evaluar enfermedades de la fruta o plantas. Se logró determinar las enfermedades y el porcentaje de avance en la mazorca del cacao, a través de una aplicación móvil que brinda soporte a los agricultores para reconocer las enfermedades, a través de imágenes con inteligencia artificial del tipo Deep Learning.

Con la aplicación móvil, ayuda al agricultor que no esté al tanto de las enfermedades que afectan al cultivo del cacao, y esta aplicación le permitirá conocer rápidamente el tipo de enfermedades del fruto, con lo cual ahorra tiempo y dinero a los agricultores. Los profesionales agrícolas, realizan un proceso extenso y laborioso mediante pruebas eficientes utilizando cámaras húmedas y microscopio para identificar patógenos infecciosos que afectan al fruto, y estas pruebas no están al alcance de todos los productores de cacao.

3. JUSTIFICACIÓN DEL PROYECTO

La agricultura ecuatoriana es la actividad exportadora más dinámica. El cacao es uno de los cultivos que ha ganado importancia en muchos países latinoamericanos, hasta convertirse en uno de los generadores de riqueza de numerosos territorios, es el caso de Ecuador que es conocida como la “Pepa de Oro”, la producción de esta planta que se realiza de manera agroecológica y convencional, la elaboración de este cultivo ha incrementado ganancias a los consumidores locales y extranjeros, el cacao ecuatoriano y el CCN51, es la materia prima reconocida en el mercado,(Guzmán et al., 2012).

En la actualidad, la tecnología se ha involucrado en varias áreas del conocimiento, uno de ellos es el sector agrícola, por lo cual resulta mejoras al optimizar los recursos. Las técnicas de Machine learning son empleadas para realizar clasificaciones, predicciones, entre otros que involucraría gran consumo de recursos, teniendo resultados satisfactorios y de aprovechamiento hacia los agricultores. Por lo tanto, se plantea el uso de Modelos Machine Learning para la clasificación y precisión de avance de la enfermedad en la mazorca del cacao mediante operaciones tales como Pooling y Convolución, dando gran aporte a la agricultura.

La finalidad que enfrasca el estudio es contribuir con el agricultor que desconoce la identificación de enfermedades del cacao mediante una herramienta que facilite el proceso de reconocimiento de las enfermedades, los técnicos del área de agronomía realizan pruebas mediante cámara húmeda o microscopio para identificar qué patógenos infecciosos afectan al fruto; con la aplicación móvil ayuda al agricultor a reconocer de manera temprana la enfermedad, a través del monitoreo del cacao, lo cual la aplicación clasificará el agente causal que padece la mazorca, contribuyendo con el agricultor a evitar la pérdida de su cultivo.

4. BENEFICIARIOS DEL PROYECTO

Los beneficiarios son las personas que se dedican al cultivo orgánico y a personas con falta de conocimiento sobre las enfermedades que afectan la *Theobroma cacao L*, así también al sector agroecológico y los investigadores que empleen inteligencia artificial.

Tabla 1. Beneficiarios directos e indirectos

Beneficiarios directos	Beneficiarios indirectos
Asociación de productores Agrícola “PEPA DE ORO”	Productores cacaoteros convencionales
Asociación de productores Agrícola “CALOPE”	Investigadores IA
Asociación de productores Agrícola “ASOPROCAMAN”	Ingenieros y técnicos Agronómicos
Finca Independientes	

Fuente: MAGAP-La Maná

Realizado por: Las Investigadoras

5. PROBLEMA DE INVESTIGACIÓN

En la actualidad, las velocidades de perfeccionamiento de las máquinas tienen la capacidad de aprender de forma autónoma las tareas, para las que fueron diseñadas. Esta tecnología recibe el nombre de Machine Learning, el aprendizaje de las máquinas (Modernag, 2018). El desarrollo de interés y su adopción implica el despliegue de sensores, drones o software de análisis de información que tiene como objetivo final mejorar la toma de decisiones y optimizar el uso de los recursos, lo que se traduce en una reducción de costes y un incremento en el rendimiento de los cultivos, (Zhang, Dabipi, & Brown, 2018).

El problema incide en que las herramientas tecnológicas que se han implementado en el campo de la agricultura no llegan a los agricultores pequeños y medianos, que no cuentan con los recursos económicos que se requiere, para implementar estos equipos tanto de hardware como software, a su vez carecen de conocimientos necesarios para identificar las enfermedades que afectan al *Theobroma cacao L*, cuyos efectos causan pérdidas en la producción superiores al 60% , estos padecimientos perjudican a toda la Latinoamérica,(Toala, Borjas, Alvarado, Castro, & Otiniano, 2019), se pretende ayudar a la productividad del cultivo con una detección temprana de las enfermedades. Este tipo de herramientas permitirán al agricultor tener fácil acceso, en la actualidad las personas cuentan con un teléfono celular de gama media – alta y puedan gozar de la aplicación.

6. OBJETIVOS

5.1. Objetivo General

Diseñar modelos de clasificación de imágenes empleando técnicas de Machine Learning, para la detección de enfermedades del *Theobroma cacao L* en huertas agroecológicas del Cantón La Maná.

5.2. Objetivos Específicos

- Identificar los aspectos que intervienen en la clasificación y predicción de enfermedades del (*Theobroma cacao L*) para desarrollar el proyecto mediante la investigación bibliográfica y de campo.
- Establecer técnicas de Deep Learning para la creación de modelos de clasificación de enfermedades del cacao (*Moniliophthora roreri* y *Phytophthora palmivora*).
- Implementar modelos de inteligencia artificial mediante la aplicación móvil empleando caso de estudio real para la clasificación y predicción de enfermedades del cacao.

6. ACTIVIDADES Y SISTEMA DE TAREAS EN RELACIÓN A LOS OBJETIVOS PLANTEADOS

Tabla 2. Actividades y sistema de tareas en relación a los objetivos planteados

Objetivo	Actividad	Resultado de la actividad	Medios de verificación
<p>Objetivo Especifico 1: Identificar los aspectos que intervienen en la clasificación y predicción de enfermedades del (Theobroma cacao L) para desarrollar la propuesta del proyecto mediante la investigación bibliográfica y de campo.</p>	<p>Investigar datos bibliográficos</p> <p>Determinar los artículos que serán analizados.</p> <p>Utilizar fuentes de consulta confiables tales como libros, revistas y artículos científicos.</p> <p>Determinación de 5 áreas de estudio en diferentes sectores del Cantón La Maná.</p> <p>Recolección de fotos para el datasets.</p>	<p>Revisión Bibliográfica.</p> <p>Listado de referencias bibliográficas, libros y artículos científicos.</p> <p>Marco teórico de la Investigación.</p> <p>5 áreas de estudio.</p> <p>Datasets lista para desarrollar la propuesta del proyecto.</p>	<p>Definiciones en la investigación.</p> <p>Fuentes bibliográficas.</p> <p>Anexos de las áreas de estudio.</p> <p>Anexos del datasets.</p>
<p>Objetivo Especifico 2: Establecer técnicas de Deep Learning para la creación de modelos de clasificación de enfermedades del cacao (Moniliophthora roreri y Phytophthora palmivora).</p>	<p>Analizar las operaciones Pooling y de Convolución.</p> <p>Determinación de las herramientas de desarrollo.</p>	<p>Modelo de IA.</p> <p>Herramientas de desarrollo.</p>	<p>Diseño de la propuesta.</p>
<p>Objetivo Especifico 3: Implementar modelos de inteligencia artificial mediante la aplicación móvil empleando caso de estudio real para la clasificación y predicción de enfermedades del cacao.</p>	<p>Desarrollar pruebas unit Testing.</p>	<p>Evaluar los criterios de salida de las fases aprobadas en el periodo unit testing.</p>	<p>Aplicación funcional que permita identificar el tipo y avance de la enfermedad del Theobroma Cacao.</p>

Elaborado por: Las Investigadoras

7. FUNDAMENTACIÓN CIENTÍFICO TÉCNICA

7.1. Antecedentes de la investigación

Tema: Diagnóstico automatizado de enfermedades de las plantas mediante la innovadora aplicación de Android (Plantix) para agricultores en el estado indio de Andhra Pradesh. El problema de investigación del proyecto Plantix es la identificación de plagas y enfermedades de los cultivos tales como raíces, tubérculos y plátanos que a menudo es imposible de detectar para el sector agrario, además que los investigadores, autoridades sanitarias de vegetal y las organizaciones carecen de datos que ayuden al agricultor, el Instituto Internacional de Agricultura Tropical conjunto con James Legg, David Hughes y la bióloga Penn State encabezaron el proyecto.

Plantix es una aplicación móvil que brinda asesoramiento sobre el cultivo, mediante el reconocimiento de imágenes con inteligencia artificial diagnostica las enfermedades de las plantas, daño por las plagas y su deficiencia en nutrientes y brinda el tratamiento correspondiente para cada afección, (Rupavatharam, Kennepohl, Kummer, & Parimi, 2018).

Tema: Crops diagnosis using digital image processing and precision agriculture technologies. El objetivo principal de la aplicación móvil CropDiagnosis es desarrollar decisiones para la gestión de plagas con diagnóstico preciso de los cultivos e instrucciones personalizadas mediante la asistencia de la aplicación. Los detalles de los cultivos, incluyendo el tipo, la ubicación, el suelo, etc., y se proporcionan a través de una interfaz sencilla en forma de cuestionario inteligente. Algunas otras características como el tipo de cultivo, el aspecto y el crecimiento también se alimentan y se realiza el diagnóstico más probable. La aplicación requiere información detallada de las características del cultivo, como el tipo, la ubicación, el suelo y características como aspecto, tipo y crecimiento de la planta para poder tomar cualquier decisión, (Jiménez, Quiroz, Acevedo, & Salamanca, 2015).

Tema: Aplicación SaillogAgrio, es una solución basada en la IA para ayudar a los agricultores a detectar y tratar las enfermedades y plagas de los cultivos. Agrio es una aplicación interactiva para teléfonos móviles englobada en Saillog y es gratuita. Los usuarios de esta aplicación hacen clic en las fotografías de las plantas infectadas y las suben a través de un teléfono inteligente. Y su continuidad, de estas imágenes se analizan y se realiza una detección automática de las

enfermedades. A veces también se ofrece una solución inmediata. Hace uso de técnicas de IA y proporciona soluciones completas a diferentes problemas de gestión de enfermedades y plagas. Su motor de IA es capaz de identificar cientos de enfermedades y defectos, (Saillog LTD, 2019).

La identificación de las enfermedades de las plantas es un tema que preocupa mucho a los agricultores, debido a que predice directamente el rendimiento que afecta a la productividad. Para identificar una planta con alguna enfermedad y recomendar los movimientos necesarios de recuperación (Dipakkumar, 2018), se requiere una gran experiencia y conocimientos. Para diagnosticar la enfermedad y sugerir medidas de control, se están utilizando muchos sistemas asistidos por ordenador en casi todos los países, (Harjeet, Deepak, & Madhuri, 2019).

A Byod y Sun propusieron un prototipo de sistema experto para el diagnóstico de enfermedades de la patata (Boyd & Sun, 1994). El prototipo propuesto emulaba la experiencia humana en el diagnóstico de las enfermedades de la planta, según la patata en función de los síntomas. Otros trabajos relacionados con la identificación de enfermedades de las plantas fueron el del cultivo de arroz que con [(Sarma, Singh, & Singh, 2010), (Ballede, et al, 2014)] base de conocimientos consistía en diferentes enfermedades de la planta. Tilva et al., propusieron un modelo basado en la lógica difusa para predecir enfermedades basadas en la duración de la humedad de las hojas (Trival, Patel, & Bhatt, 2013). El sistema creado utilizaba el conocimiento de las condiciones climáticas favorables para varios microorganismos responsables de enfermedades.

(Babu & Rao, 2007) utilizaron redes neuronales de retro propagación en su sistema de reconocimiento de hojas para el control de plagas y enfermedades en los cultivos, (Ismail & Mustikasari, 2013). crearon un sistema inteligente para la detección de enfermedades en las hojas de té, También se sugirieron algunos sistemas híbridos. Huang propuso un modelo de procesamiento de imágenes acoplado a un modelo de red neuronal artificial para clasificar las enfermedades de las plantas de Falanopsis (Hanson, Joy, & Francis, 2017) y (Huang, 2007). Sannakki et al. aplicaron un enfoque de lógica difusa acoplado al procesamiento de imágenes para detectar el porcentaje de infección en la hoja (Sannakki, et al, 2011). Un sistema que utiliza el algoritmo de segmentación K-Means fue desarrollado por (Al-Hiary, et al, 2011) y (Bashish, Braik, & Bani-Ahmad, 2011). El Dr. Wheat es un sistema de desarrollado por (Khan, et al, 2008), para el diagnóstico de enfermedades del trigo.

7.2. Base teórica

7.2.1. Implementación

De acuerdo a Tanenbaum, (2003), es la instalación de una aplicación informática, elaboración o la construcción de un plan, idea, modelo científico, diseño, relación, tipo, algoritmo o política. En cómputo, es la ejecución de una especificación técnica o algoritmos como un programa, componente software, u otro sistema computacional. En el ambiente del software, la similitud se establece con la implementación del software: distribución de los archivos de una aplicación en donde los requerimos. El concepto de ejecución incluye estas acciones (Adobe Systems Incorporated, 2010):

- **Instalar:** para que los usuarios puedan iniciar la aplicación, se copian los archivos de la aplicación desde un medio físico o electrónico al sistema en el que se va a ejecutar la aplicación y configurar el sistema operativo.
- **Actualizar:** para añadir la adaptación nueva o mejorada a la versión presente, se realiza la modificación, se añade, se elimina o substituye elementos de los archivos existentes de la aplicación.
- **Desinstalar:** para que la aplicación ya no se pueda iniciar se elimina los archivos de la aplicación y configurar el sistema operativo de modo.
- **Reinstalar:** combinar las acciones de desinstalar e instalar en una sola acción
- **Realizar seguimiento de instalación:** informarse sobre las ubicaciones y los equipos en los que están instaladas las aplicaciones.

7.2.2. Inteligencia Artificial (IA)

La inteligencia artificial es la ciencia de construir máquinas o softwares que piensen como humanos y actúen racionalmente. En informática, la máquina "inteligente" ideal es una persona flexible y racional que puede percibir el entorno circundante y actuar. Maximice sus posibilidades de éxito en determinadas metas o tareas. En lenguaje hablado, cuando las máquinas imitan las funciones "cognitivas" asociadas con los humanos otros pensamientos humanos, como aprender y resolver, problema, (Rich, Knight, Calero, G, & Bodega, 1994).

7.2.3. Modelos Machine Learning

Las metodologías de aprendizaje automático se definen como un conjunto de técnicas competentes capaces de detectar de manera automática los patrones en los datos. El aprendizaje automático o Machine Learning es un método científico que nos permite usar computadoras y otros dispositivos con poder de cómputo para permitirles aprender a extraer patrones y relaciones que existen en los datos por sí mismos. Estos patrones se pueden usar para predecir el comportamiento y tomar decisiones, (Ramiro, 2018).

El aprendizaje automático da a los ordenadores la capacidad de aprender sin ser inequívocamente personalizados, fundamentalmente lo mismo que el trabajo de un ser humano. La máquina está aprendiendo de los encuentros pasados (que se ocupan en la información) en relación con algunas clases de recados, si la presentación de la asignación mejora con más conocimiento.

7.2.3.1. Tipos de Machine Learning

➤ Aprendizaje supervisado

El aprendizaje supervisado se refiere a un conjunto de datos con nombre, incluidos los límites de entrada y salida, para preparar modelos, (Amara, Bouaziz, & Algergawy, 2017). Al preparar un modelo, la relación entre la preparación y la información de la prueba se mantiene en 80:20. El aprendizaje supervisado se cataloga en clasificación y regresión. El acuerdo es parte del método supervisado de tareas de aprendizaje donde la salida es un valor discreto. Este valor discreto puede ser un valor multiclase o paralelo. Aunque la recaída es un modelo de aprendizaje supervisado que produce un valor persistente, el objetivo de la recaída es anticipar un valor más cercano al valor de salida.

➤ Aprendizaje no supervisado

En el aprendizaje no supervisado, los objetivos no se dan a la pantalla para ser preparados, por lo que sólo hay límites de entrada y no se da ningún de salida al modelo. El agrupamiento y la asociación son dos tipos de aprendizaje no supervisado, (pothuganti, 2013). El agrupamiento se aplica a la información orquestada como reuniones hechas por diferentes ejemplos distinguidos por el modelo de la máquina. Mientras que un método basado en el estándar para

ordenar las relaciones entre los límites de una vasta colección informativa, se denomina Asociación.

➤ **Aprendizaje Semi-supervisado**

El funcionamiento del Aprendizaje Semi-supervisado se encuentra en las proximidades de los procedimientos mencionados anteriormente. Este tipo de aprendizaje se utiliza cuando se trata de información, parte de la cual tiene nombre, y otra parte no tiene etiqueta. La estrategia no supervisada se utiliza para calcular las marcas y, posteriormente, (Amara, Bouaziz, & Alergawy, 2017), estas cualidades determinadas se tienen en cuenta para las estrategias de aprendizaje supervisado. En los conjuntos de datos de imágenes en los que una gran parte de las imágenes no tienen nombre, este procedimiento, es más conocido.

➤ **Aprendizaje reforzado**

La ejecución del modelo sigue mejorando con las críticas para aprender ejemplos y conductas. Cada vez que la información se encuentra y se añade a la información que se está preparando. Así, cuanto más se aprende, mejor se prepara y posteriormente se experimenta, (Narendrakumar, 2018). Los algoritmos para el aprendizaje por refuerzo son Temporal Difference, QLearning y Deep Adversarial Networks.

7.2.4. Redes Neuronales Artificiales (ANN)

Las redes neuronales artificiales o artificial neural networks constituyen técnicas de aprendizaje automático inspiradas en el comportamiento del cerebro humano. Crea redes con diferentes capas de interconexión para procesar información. Cada capa consta de un conjunto de nodos, que transmiten información a otros nodos en capas posteriores, (Martinez, 2018).

Las redes neuronales aparecieron en 1950, pero la habilidad mejorada de cálculo, relacionado con el fenómeno de big-data hacer posibles los algoritmos basados en algoritmos en deep learning se aproximan o mejoran el desempeño humano en las siguientes áreas reconocimiento de voz o imagen.

Una red neuronal artificial se caracteriza por:

- La topología: corresponde al número de capas y nodos, y la dirección en la que la información pasa de un nodo al siguiente dentro o entre capas. Las redes más grandes y complejas suelen identificar patrones más útiles y límites de decisión complejos.
- Algoritmo de entrenamiento: determina la importancia de que cada conexión transmita o no la señal del nodo correspondiente.
- Función de activación: la función de recibir un conjunto de entradas e integrar señales para transmitir información a otro nodo o capa.

La mayoría de los métodos de aprendizaje automático usan arquitecturas neuronales, por lo que las arquitecturas de aprendizaje profundo usan modelado de redes neuronales, por ejemplo:

- Deep Neural Network (DNN) o Redes neuronales profundas
- Convolutional Neuronal Network (CNN) o Redes neuronales profundas convolucionales
- Deep Belief Network (DBN) o Redes de creencia profundas

7.2.5. Convolutional Neuronal Network (CNN)

Se concentra en la construcción de aprendizaje profundo Convolutional Neural Network (CNN), que está transcrito al español, trata de redes neuronales convolucionales. En este tipo de arquitectura, se utiliza el modelado de redes neuronales artificiales, donde las neuronas corresponden a campos receptivos similares a las neuronas en la corteza visual del cerebro humano V1. Este tipo de redes son muy efectivas para las siguientes tareas, (Heras, 2017):

- Detección y categorización de objetos
- Clasificación y segmentación de imágenes

El objetivo de CNN es aprender funciones de alto nivel mediante operaciones de convolución. Dado que la red neuronal convolucional consigue formar la relación entrada-salida (en el cual la entrada es una fotografía), en convolución, cada píxel de salida es una composición lineal de píxeles de entrada, (Itelligent, 2018).

7.2.5.1. Convolución

La convolución implica filtrar la imagen usando una máscara. Diferentes máscaras producirán resultados diferentes. La máscara representa las conexiones entre neuronas en la capa anterior. Estas capas aprenden gradualmente las características de alto orden de la entrada original. Las redes neuronales convolucionales utilizan dos tipos de formación de capas: convolución y agrupación. Después de una o más capas convolucionales, se utilizan capas de agrupación. La función de la capa de Pooling o agrupación es resumir las respuestas de salida cercanas.

7.2.5.2. Pooling

La función de la capa de agrupación es resumir las respuestas de salida cercanas. Las principales características de la capa de agrupación son dos. Primero, la capa de agrupación reduce gradualmente el tamaño del espacio de datos. En segundo lugar, la agrupación ayuda a obtener una representación constante con una pequeña cantidad de conversión de entrada.

7.2.6. EL CACAO (*Theobroma cacao* L)

Las diferentes especies de plantas tropicales pertenecen al género *Theobroma*. Se han reportado 22 especies, pero solamente una, el cacao (*Theobroma cacao* L., familia Sterculiaceae), presenta una significativa importancia para su comercialización (Guerra, 2005), y debido a esto ha sido estudiada más profundamente. Es nativo de América del Sur, concretamente de las Cuencas Hidrográficas de la cúspide Amazonas y Orinoco, al este de la Cordillera de Los Andes, en regiones que hoy pertenecen a Ecuador, Perú, Colombia, Venezuela, Brasil y las Guyanas. En esa amplia zona aún persisten variedades silvestres el *Theobroma cacao*, el componente graso característico de la almendra es el más importante en el uso de la industria chocolatera, farmacéutica y de cosméticos, por otra parte, las semillas de *Theobroma cacao*, fueron previamente reconocidas como una rica fuente de bioelementos, (Motamayor, 2002).

7.2.6.1. Importancia

El cultivo de cacao representa el principal rubro de las familias campesinas dedicadas a siembra del mismo. Las semillas obtenidas de las mazorcas son fermentadas, tostadas, rotas y esparcidas para dar un polvo del cual se obtiene la grasa este es el cacao, para obtener la materia prima para la obtención los diferentes subproductos como son pasta de chocolate, sabores artificiales,

y manteca de cacao, entre otros. Dominan en gran cantidad, se manejan en la producción de medicinas, cosméticos, y limpiadores, su importancia en el patrimonio de la colonia fue enorme, debido a que era uno de los productos del nuevo continente más codiciados por los Europeos, (Sicacao, 2015).

El cacao contiene cerca de 300 misceláneos volátiles conteniendo ésteres, hidrocarbólicas, monocarbonilos, piroles, y otros más. Se ha dicho que los trascendentales componentes de sabor son ésteres alifáticos, polifenoles, carbonilos fragantes insaturados, pirazinas y teobromina. El cacao también contiene cerca de 18% de proteínas (8% digestibles) (Premier Salud, 2016).

7.2.6.2. Enfermedades que afectan al cacao

Entre los primordiales padecimientos se identifica la moniliasis, mancha negra, antracnosis, mal de machete, bubas y descomposición de raíz. Las enfermedades causan problema en la producción del grano de cacao, las cuales pueden causar pérdidas hasta del 90%. Desde el punto de vista parasitológico *Moniliophthora roreri* es una verdadera limitante para la sobrevivencia de cacao criollo (cacao nacional). Los antecedentes obtenidos revelan que afecta al 100% de los cacaos y devasta el 76.98% de la producción. Permite establecer estrategias para el manejo integrado, además, con la descripción de las mismas, permitirá que el productor las identifique y realice un buen control, (Rica, 2018).

Mazorca negra o *Phytophthora* (*Phytophthora palmivora*).

Causada por *Phytophthora palmivora*, esta es el padecimiento más sugestivo del cacao en todas las superficies cacaoteras del mundo; producida por setas del complejo *Phytophthora*, es responsable de más males en las recolecciones de cualquier otro padecimiento, existente esta enfermedad en otras regiones en todos los países que plantan cacao. Fue conseguida por primera vez en el año 1727 en la isla de Trinidad. Es conocida incluso como pudrición parda del cacao, (Instituto Nacional de Investigaciones Agropecuarias).

Este padecimiento ataca varios fragmentos de la planta, pero los perjuicios más significativos se dan en los frutos, especialmente en los próximos a la madurez. Se origina por una mancha café de borde regular que tiene un crecimiento rápido y alcanza a envolver al fruto en pocos días. Internamente, causa una pudrición café. Manchas de color café empiezan a aparecer en

uno de los extremos del fruto; el micelio del hongo se forman esporas; la pudrición interna daña parcial o totalmente las semillas. en pocos días, las unicelulares cubren el fruto, (Línea Agrícola, 2012).

Cómo se contagia la enfermedad: La vía más común de infección es por medio de dispersión de las esporas, las cuales se activan cuando hay mucha humedad y se da en un espacio de bajo clima continuo por otro caliente. Las esporas son transportadas por la salpicadura de lluvia, las corrientes de agua, el viento, las hormigas, etc. La relación directa entre los frutos sanos y enfermos del mismo modo es una fuente importante de contaminación, La etapa más infecciosa de la mazorca negra es durante la espectro del micelio; debemos evitar la enfermedad eliminando las mazorcas enfermas antes de que se produzcan las esporas, (Catie, 2011).

Moniliasis (*Moniliophthora roreri*).

Las primeras informaciones acerca de la enfermedad conocida como moniliasis (*Moniliophthora roreri*) aparece en el año de 1916 en Ecuador (FHIA, 2012), descrita por J. B. Rorer y considerándose que la región de Quevedo era el punto de origen de la enfermedad, pero estudios realizados por Phillips (2006), mencionan que se originó en Antioquia, Colombia; desde en aquel momento se han esparcido a países como Venezuela, Surinam, Perú, Bolivia, Panamá, Costa Rica, Honduras, Guatemala, Belice y México.

La Moniliasis, enfermedad causada por el hongo *Moniliophthora roreri*, que ataca únicamente las mazorcas o frutos de cacao en cualquier edad, causando pudrición de los granos. La dureza del ataque de la Monilla se modifica según la zona y período del año, de acuerdo con el entorno del clima, en mazorcas pequeñas de dos meses el signo más habitual es a formación de “jorobas” o “gibas”; en frutos de dos y cuatro meses es la presencia de puntos verdes oscuros y en mazorcas de mayores de cuatro meses se presentan puntos aceitosos, maduración prematura, manchas irregulares de color café; los cuales se reconocen por ser más pesado, (Instituto Nacional de Investigaciones Agropecuarias).

La pudrición de conidias se prolonga mientras el fruto permanezca adherido al árbol son llevadas hasta los frutos sanos principalmente por el viento. Otros agentes de esparcimiento son el salpique de la lluvia, los animales y los individuos. Cuando el área del fruto está fresca, las

esporas germinan y los contagian. Los daños se observan varias semanas después. Los frutos jóvenes, de menos de 3 meses de edad, son los más atacados, (Catie, 2011).

Componentes que ayudan el desarrollo de la enfermedad: Se deben almacenar todos los frutos contagiados semanalmente antes de su esporulación; no hacerlo es el mayor origen de pérdida de la recolección del fruto. Esta labor debe ejercerse en cualquier temporada o clima.

Control de Moniliasis: Cuando la espora o semilla del hongo germina, produce unas estructuras llamadas hifas infectivas que se encargan de penetrar el fruto. La inoculación llega a los tejidos céntricos, incluyendo los granos de cacao, e inicia el progreso de la necrosis desde la parte interna. Finalmente, el fruto es el único órgano infectado. Las indagaciones han permitido establecer que las sintomatologías varían según la edad del fruto al instante de la infección, pero la prontitud de su progreso depende del entorno ambiental, básicamente de la temperatura y de la susceptibilidad del clon o variedad de cacao (Línea Agrícola, 2012).

Escoba de bruja (*Moniliophthora perniciosa*).

Enfermedad que ataca el cultivo de cacao. Es causada por el hongo *Moniliophthora perniciosa* y afecta los tejidos en crecimiento de la planta, las escobas típicas en las plántulas se forman por la hipertrofia tanto del brote principal como de las yemas axilares hay proliferación, agrandamiento y persistencia de las estípulas en la parte apical de las yemas e hipertrofia de la base del pecíolo de las hojas, además de clorosis de las hojas.

Mal del machete (*Ceratocystis fimbriata*).

Producida por el hongo *Ceratocystis fimbriata* arruina árboles en su totalidad. El hongo constantemente contagia al cacao por medio de contusiones en los troncos y ramas principales, las cuales pueden matar a un árbol rápidamente. Si no se ejecuta un buen control de los árboles infectados por esta enfermedad, puede producir una pérdida de hasta del 30%, (Porrás, 2015).

El cacao es una planta que pueden sufrir daños enormes a causa de las larvas y hongos, y por ello precisan de algunas técnicas para su producción; un mal uso de insecticidas podría ser fatal de tal manera que la cosecha se podría dañar quedando como resultado de muchas pérdidas económicas. De igual manera los insectos perjudican los cacaotales, existen insectos favorables

como los predadores, polinizadores y parásitos que son nocivos para la planta, lastimosamente son muchos, también existen insectos que son transmisores de enfermedades; como los pequeños abejones, que pueden transmitir o propagar la enfermedad llamada “Mal de Machete”, (Productor, 2017).

7.2.7. Epidemiología

El inicio de la causa de las infecciones depende de las condiciones ambientales, la lluvia relativa alta y los bajos climas. Las épocas de lluvias, por ejemplo, son propicios para la emancipación de las esporas y su propagación. Su transmisión se facilita bajo ciertos entornos ambientales, (Juan, 2012):

- Cuando hay salpicadura de la lluvia, pues aprovecha el inóculo presente en el suelo para afectar a las mazorcas más cercanas al suelo.
- La escorrentía que transporta en la corriente del agua las esporas y permite la dispersión del patógeno.
- También el viento moviliza las esporas atrapadas en microgotas de agua. De esta manera las esporas transmiten la enfermedad.

7.2.8. Huertas Agroecológicas

Las huertas agroecológicas son ambientes campesinos, que han sido determinados como sistemas reformados por las personas con el fin de producir provisiones, fibras u otros productos agrícolas (Conway, 1987). Estos ambientes se ubican cerca del lugar de residencia y se caracterizan por presentar gran variedad de plantas cultivadas, nativas y una alta proporción de especies exóticas, constituyendo ensamblajes botánicos poco comunes en un espacio reducido presentan ciclos más largos a un año y son ecológicamente más complejos que un monocultivo.

Las huertas agroecológicas no viven a cuenta de altos requerimientos de energía como químicos, abonos, máquina o pesticidas, usualmente manejados en los monocultivos. Se conservan gracias al manejo que toman las asociaciones y aplican el conocimiento particular, esto ha permitido que los cultivadores tradicionales extiendan la seguridad de las cosechas y que al restablecerlas se vuelvan resistentes a plagas y padecimientos. En algunos casos, las huertas familiares generan ingresos económicos a sus propietarios, pues parte de los productos obtenidos son vendidos en el mercado, (Blanckaert, 2004).

De este modo, las huertas han organizado un medio elemental para el sostén y prosperidad de los grupos rurales, teniendo en cuenta un texto social en el que la necesidad, debilidad y degradación ambiental se han convertido en situaciones comunes en los países en vía de desarrollo, en este tipo de ecosistemas agrícolas, se utiliza frecuentemente el conocimiento tradicional para la obtención de productos a partir de las plantas, que benefician a las familias campesinas, (Biodiversity International, 2006).

7.3. HERRAMIENTAS DE DESARROLLO

7.3.1. Jupyter Notebook para IA

Jupyter Notebook: es un ambiente de desarrollo interactivo fundado en web para cuadernos de código y datos de Jupyter. JupyterLab es muy flexible, configura y organiza la interfaz de usuario para admitir varios flujos de trabajo en ciencia de datos, informática científica y aprendizaje automático. JupyterLab es extensible y modular, escribe complementos para agregar nuevos componentes e integrarse con los componentes existentes, (Project Jupyter, 2020).

Jupyter Notebook es una aplicación web de código abierto que consiste en crear y compartir instrumentos que contienen código en tiempo real, ecuaciones, visualizaciones y texto descriptivo. Los usos contienen limpieza y transformación de datos, simulación numérica, modelado estadístico, visualización de datos, instrucción automática, etc., (Project Jupyter, 2020).

7.3.2. Google Colab

Google Colaboratory, más conocido como "Google Colab" o simplemente "Colab", es un proyecto de investigación para la creación de prototipos de modelos de aprendizaje automático en potentes opciones de hardware como GPU y TPU. Proporciona un entorno de cuaderno Jupyter sin servidor para el desarrollo interactivo. Google Colab es de uso gratuito como otros productos de G Suite, (Bisong, 2019).

En este proyecto de investigación la herramienta utilizada para el desarrollo del modelo de IA se empleó la IDE de Google Colab debido a que se encuentra alojado en la nube, utiliza menos recursos en la parte de rendimiento y tiene soporte de varios lenguajes de programación

orientados al desarrollo de Inteligencia Artificial a diferencia del IDE Jupyter Notebook que es de instalación local, se deben importar las librerías de manera manual y consume más recurso de máquina.

7.3.3. Tensorflow - Keras

TensorFlow: Es una biblioteca de cálculo numérico especializada en el aprendizaje profundo. Tiene un ambiente completo y elástico de herramientas, bibliotecas y recursos comunitarios que accede a los desarrolladores promover el aprendizaje automático innovador y permite a los investigadores compilar e efectuar fácilmente aplicaciones basadas en IA. (TensorFlow, 2020). Con la tecnología TensorFlow, los desarrolladores, investigadores y diversas comunidades corporativas utilizan ML para resolver problemas prácticos complejos.

Keras: es una API diseñada para humanos y no para máquinas. Keras sigue las excelentes prácticas para oprimir la carga cognitiva, suministra una API simple y sólida, disminuye la cantidad de operaciones que el usuario necesarias para los casos de uso habituales y provee mensajes de error claros y procesables. También cuenta con una extensa documentación y guías para desarrolladores, (Keras Team, 2020). Edificado sobre TensorFlow 2.0, Keras es un cuadro de trabajo macizo de la industria que puede encaramar a grandes grupos de GPU o un pod completo de TPU. No sólo es posible; es fácil.

7.3.4. Python

Python es un lenguaje de programación de propósito general de alto nivel, portátil y de código abierto. Cuenta con un intérprete que proporciona un entorno interactivo, un sistema de tipo dinámico y una gestión automática de la memoria. Al estar orientado a objetos, su uso está muy extendido y ofrece una amplia y completa biblioteca para aplicaciones del mundo real (Nagar, 2018). Python 2 y Python 3 son dos versiones de intérpretes de Python que se utilizan actualmente. Python ha ganado popularidad entre los científicos de datos debido a la disponibilidad de bibliotecas fáciles de usar y a la facilidad para trabajar con una variedad de formatos de archivo tanto en local como en remoto.

7.3.5. Sistema operativo más usado en el mercado

El avance de la tecnología móvil se incrementó en los últimos años, especialmente desde la llegada de plataformas como iOS y Android, que han dominado prácticamente todo el sector de los dispositivos tecnológicos. Cada día usamos más nuestros teléfonos celulares, ya sean tabletas o teléfonos inteligentes, y buscamos nuevas formas de incorporarlos a nuestra vida personal, (Freesia, 2020). En el mercado los sistemas operativos para los Smartphone más usados es Android e iOS, en estadísticas la cuota en el mercado entre el 2014 y 2019 el sistema operativo de Android se situó en la primera posición con el 86,1% de unidades distribuidas, mientras que el sistema operativo de iOS con el 13,9% de smartphones distribuidos, de una distribución de dispositivos móviles de 1.372 millones, (Mena, 2020).

7.3.6. Entorno de desarrollo Android Studio

Android Studio proporciona la herramienta más rápida para crear aplicaciones en todo tipo de dispositivos Android, incluido un editor de diseño visual, y crear diseños de ConstraintLayout complejos agregando las restricciones de cada vista a otras vistas y modos. Luego, seleccionando una de varias configuraciones del dispositivo o simplemente ajustando el tamaño de la ventana de vista previa, el diseño se puede ver en cualquier tamaño de pantalla. (Android Studio, 2020). El simulador es instalable y ejecutable, sus aplicaciones son más rápidas que los dispositivos físicos y pueden simular diferentes configuraciones y funciones, entre ellas ARCore (la plataforma de Google para crear experiencias de realidad aumentada).

7.3.7. Lenguaje de programación Java

Java es un lenguaje de programación y una plataforma informática creada y vendida por Sun Microsystems en 1995. Es un lenguaje orientado a objetos cuyo propósito es permitir a los desarrolladores de aplicaciones escribir programas para él solo una vez. Y se puede ejecutar en cualquier dispositivo, (Martínez & De Guevara, 2017).

Java proporciona potentes funciones de lenguaje derivadas de C y C ++, pero sin estas funciones menos utilizadas y confusas, es más sencillo. Java proporciona una gran biblioteca estándar y herramientas para distribuir programas. Es independiente de la plataforma esto significa que los programas escritos en lenguaje Java pueden ejecutarse en cualquier tipo de hardware, lo que lo hace portátil.

8. METODOLOGÍAS DE INVESTIGACIÓN

8.1. Métodos de investigación

8.1.1. Método Documental

Esta metodología permitió la recolección de información mediante la revisión de textos, artículos, revistas, sitios webs y bibliografías sobre el tema "Implementación de modelos Machine Learning aplicados al estudio de enfermedades del *Theobroma cacao* para huertas agroecológicas del Cantón La Maná, Provincia de Cotopaxi", se muestra el uso de este método en la fundamentación científica-técnica y en las herramientas a utilizar en la ejecución o desarrollo de la aplicación móvil, además permite la selección, análisis y presentación de los datos documentados de una manera ordenada y siguiendo los objetivos del proyecto.

8.1.2. Método analítico sintético

Este método dualista permite al investigador llegar a la veracidad de las cosas, en primer lugar, descomponiéndose en sus partes o elementos para observar las causas, naturaleza y efectos del problema de la investigación como los modelos machine learning, enfermedades del *theobroma cacao* y las herramientas de software. El análisis de estos temas permitirá obtener un gran conocimiento para la realización de una síntesis concisa que ayude en el desarrollo del proyecto.

8.1.3. Método deductivo

Mediante este método permite especificar los atributos sobre el tema "Implementación de modelos Machine Learning aplicados al estudio de enfermedades del *Theobroma cacao* para huertas agroecológicas del Cantón La Maná, Provincia de Cotopaxi", partiendo de lo general a lo partícula, en el problema del proyecto, además permite extraer las conclusiones y recomendaciones, admite examinar los resultados de la entrevista de manera lógica y válidas, obteniendo así información relevante y útil para el proyecto.

8.2. Tipos de Investigación

8.2.1. Investigación Bibliográfica

Es importante conocer las bases teóricas y científicas expresadas por los autores en referencia al tema de investigación, mediante esta investigación se recolecto atributos o características sobre el tema "Implementación de modelos Machine Learning aplicados al estudio de enfermedades del *Theobroma cacao* para huertas agroecológicas del Cantón La Maná, Provincia de Cotopaxi", esta información se respalda en varias obras bibliográficas, de libros, revistas, articulas, sitios webs lo que permitirá fundamentar el tema de la investigación y como estas repercutirán en el objeto de estudio que para la presente investigación.

8.2.2. Investigación de Campo.

La investigación de campo es la recolección de datos distintas fuentes primarias para una intención específica, está enfocada a entender, observar e interactuar con las personas en su entorno original. Mediante esta investigación se pudo obtener las enfermedades que afectan al cultivo del cacao en la zona de La Maná, imágenes para el datasets y la valoración técnica de la ingeniera agrónoma Bustamante Alejandra. Esta investigación permitirá conocer y obtener datos reales mediante la entrevista y la observación.

8.2.3. Investigación Aplicada

La investigación desarrollada género óptimos conocimientos para desarrollar la propuesta de investigación con el tema "Implementación de modelos Machine Learning aplicados al estudio de enfermedades del *Theobroma cacao* para huertas agroecológicas del Cantón La Maná, Provincia de Cotopaxi", mediante las especificaciones técnicas de las herramientas como entorno de desarrollo IA, Frameworks y lenguajes de programación a usar en el diseño de modelos machine learning para la aplicación de clasificación de enfermedades del cultivo *Theobroma cacao L.*

8.3. Técnica de Investigación

8.3.1. Entrevista

Mediante esta técnica se pudo recopilar información a través de un cuestionario de 7 preguntas que fueron elaboradas por el equipo de investigación para plantear a la entrevistada y conocer su valoración y criterio acerca de las enfermedades. La entrevista permitió conocer la opinión profesional de la Ing. Agrónoma Mayra Bustamante, técnica Especialista Agraria, para recopilar la información necesaria sobre las enfermedades del cultivo del cacao, con el fin de obtener conocimientos suficientes del objeto de estudio.

8.3.2. Encuesta

Mediante esta técnica se puede obtener datos de varias personas, se utiliza un listado de preguntas escritas, se lo conoce como cuestionario que se entregan al encuestado y esta debe de responderlo, de esta técnica se obtiene información de los agricultores cacaoteros de la zona de La Maná sobre los datos del cultivo del cacao y la influencia de la tecnología. La técnica que se empleo es el cuestionario estructurado que permitió redactar las preguntas de forma coherente, y organizadas, secuenciadas y estructuradas con el fin de obtener toda la información necesaria.

8.3.3. Observación

Mediante la técnica de observación permite observar y realizar el levantamiento de datos y muestra sobre las enfermedades (Monilia y Phytophthora) que afectan al cultivo *Theobroma cacao L*, se tomó como referencia a 5 áreas diferentes del Cantón La Maná con el muestreo intencional o conveniencia debido a sus ubicaciones y a la cantidad de muestras que se van a tomar.

8.4. Población y muestra

8.4.1. Población

Se realizó la investigación a los agricultores cacaoteros agroecológicos del Cantón La Maná. Por medio de la observación realizada a las diferentes asociaciones agrícolas, las del siguiente

listado son las que cumplir con los criterios de estudios y las capacidades técnicas para el desarrollo de la investigación, considerando que no todas las asociaciones y fincas tiene la capacidad para implementar esta herramienta.

Tabla 3. Población

Indicadores	Población
Asociación de productores Agrícola “PEPA DE ORO”	28
Asociación de productores Agrícola “CALOPE”	37
Asociación de productores Agrícola “ASOPROCAMAN”	34
Fincas independientes	13
TOTAL	112

Elaborado por: Las investigadoras

8.4.2. Muestra de la encuesta

Para la obtención del tamaño de la muestra se recurrirá a un muestreo aleatorio estratificado que consiste en dividir la población en estratos, es indispensable aplicar la siguiente fórmula para la obtención de los resultados.

Cálculo de la muestra de agricultores cacaoteros agroecológicos del Cantón la Maná

Formula (1) Muestra

$$n = \frac{N}{(E)^2 (N-1) + 1}$$

Datos

n = Tamaño de la muestra =?

N = Población a investigarse = 112

E = Índice de error máximo admisible = 0,05

Desarrollo

$$n = \frac{112}{(0,05)^2 (112-1) + 1}$$

$$n = \frac{112}{(0,0025) (111) + 1}$$

$$n = \frac{112}{1.28}$$

$$n = 88$$

Después de realizar el respectivo cálculo, se obtendrá una muestra de 88 agricultores que pertenecen a asociaciones y agricultores independientes de una población de 112 personas que ejercen el cultivo agroecológico cacaotero en el Cantón La Maná.

Distribución de la muestra

Se aplicará la siguiente fórmula del coeficiente de proporcionalidad permitiendo conocer de manera detallada cada uno de los estratos de la clasificación o grupos.

Formula N° 2. Índice de proporcionalidad de las asociaciones y grupo independientes.

$$f = \frac{n}{N} \quad f = \frac{88}{112} \quad f = 0,7857142857$$

Tabla 4. Distribución de la muestra por segmentos

SEGMENTO	CANTIDAD	índice	CANTIDAD
Asociación de productores Agrícola “PEPA DE ORO”	28	0,7857	22
Asociación de productores Agrícola “CALOPE”	37	0,7857	29
Asociación de productores Agrícola “ASOPROCAMAN”	34	0,7857	27
Fincas independientes	13	0,7857	10
TOTAL	112	0,7857	88

Elaborado por: Las Investigadoras

8.4.3. Muestra de los datos (imágenes)

Muestreo por conveniencia o juicio

Se escogen las unidades a estudiar siguiendo criterios de conveniencia del investigador, de un asesor técnico o de los objetivos de la investigación. Los investigadores usan su propio juicio para elegir la muestra de estudio, al contrario del muestreo aleatorio simple donde las posibilidades de que cualquier miembro se elija son las mismas.

Se tomaron como muestra 5 fincas del Cantón La Maná, de acuerdo al criterio técnico de la ing. Bustamante Alejandra se tomaron fotos de las mazorcas de manera aleatoria de las enfermedades y de estado saludable, se recogieron muestras para la confirmación de la enfermedad y se las realizaron por el método de la observación (cámara húmeda y microscopio) en la cual se determinó que las enfermedades reconocidas en el campo corresponden al objeto de estudio.

9. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS

Tabla 5. Personas que intervienen en el proyecto de investigación

Agente	Funciones	Técnicas, espacios y distribución	Población	Muestra
Tutor	Guía	Técnica experimental	1	1
Estudiantes	Investigadores	Ejecutores del proyecto	2	2
Ingeniera agrónoma	Técnico Agrícola	Entrevista	1	1
Agricultores	Suministran información	Encuesta	112	88

Elaborado por: Las Investigadoras

9.1. Resultados de la entrevista Aplicada

Mediante la entrevista que se realizó se pudo obtener los siguientes datos:

La entrevista se realizó a la ingeniera agrónoma Mayra Bustamante Técnica Especialista de la empresa INVERTIAGRO CIA. LTDA, quien brindó la información fundamental para el desarrollo de la propuesta del proyecto de investigación con el título “IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI”.

Dicha entrevista fue de tipo estructurada permitiendo preparar previamente todas las preguntas que se estableció para conocer las enfermedades que más afecta en el sector cacaotero, trato en la recolección de muestras del fruto del cacao para las pruebas técnicas y las características del comportamiento de las enfermedades como la Monilia y Phytophthora.

Las enfermedades más importantes del cacao en el Ecuador son: Moniliasis (*Moniliophthora roreri*) y Mazorca negra (*Phytophthora* sp), cuyos efectos causan pérdidas a la producción superiores al 60%.

La Moniliasis

Enfermedad causada por el hongo *Moniliophthora roreri*, distinguida como: monilia, consiste en una descomposición acuosa y helada; ataca a frutos en cualquier estado de desarrollo siendo más susceptibles cuando menor es su estado de crecimiento. Las sintomatologías comienzan con pequeñas manchas de color amarillo en mazorcas verdes; igualmente se observan bultos y aspecto de manchas pardas; en situaciones favorables se desarrolla el micelio del hongo formando una felpa blanca, produciendo una gran cantidad de esporas (cuerpos infectivos), que se caracterizan por el color blanco crema.

Mazorca negra

Es causada por un complejo de hongos del género *Phytophthora*, que atacan a diferentes partes del árbol de cacao como: cojinetes florales, chupones, brotes, hojas, ramas, tronco y raíces; el principal daño se muestra en mazorcas en cualquier estado de avance provocando mermas considerables a la producción. En la mazorca el contagio surge en forma de manchas de color

café oscuras, iniciándose habitualmente en los extremos invadiendo ágilmente toda su superficie; en estado desarrollado aparecen minúsculos hilos entrelazados que establece el micelio que a simple vista tienen el aspecto de un algodoncillo blanquecino, donde se originan las esporas y otras estructuras productivas que actúan como fuentes de contagio, dentro de la mazorca causan pérdida a la calidad del grano.

El manejo de la recolección de muestras y datos de las mazorcas enfermas se lo realiza a través de fundas individuales donde se colocará cada muestra para darles el debido procedimiento para la toma de patrones por medio de fotos.

9.2. Resultados de la encuesta Aplicada

Tabulación de la encuesta dirigida a los agricultores agroecológicos cacaoteros del Cantón La Maná conformados por grupos de asociaciones y agricultores independientes.

Tabla 6. Resultados de la Aplicación de la Encuesta

Pregunta	Resultado	Interpretación
1.-¿Cuáles son las enfermedades más comunes de cacao que afectan a su cultivo?	Monilia 88 Phytophthora 88 Escoba bruja 55 Mancha de agua 20 Mal del machete 32	Tras analizar el resultado obtenido del 100% de la población encuestada dan como resultado que las enfermedades que más afectan al cultivo del cacao son la Monilia y Phytophthora siendo estas enfermedades las que más afectan en la producción del cacao para los agricultores.
2.- ¿Usted sabe reconocer estas enfermedades en su cultivo?	Si 26% No 74%	Tras conocer los resultados obtenidos refleja que la mayoría de la población desconocen contra que enfermedades están tratando
3.- ¿Cuál ha sido su experiencia con las aplicaciones móviles?	Buena 65% Regular 27% Mala 8%	Tras conocer el análisis se determina que la mayoría de la población encuestada han tenido buenas y regulares experiencias con el uso de aplicaciones móviles.

4.-¿Conoce usted una aplicación móvil que identifique las enfermedades del cultivo de cacao?	Si 0% No 100%	Tras conocer los resultados del desconocimiento de aplicaciones móviles por parte de los encuestados da como efecto la importancia de este proyecto.
5.- ¿Considera usted que una aplicación móvil orientada al campo agrícola aportara al sector productivo cacaotero?	Si 93% No 7%	Tras conocer los resultados obtenidos la mayoría de la población encuestada que representa un 93% está de acuerdo que una aplicación móvil aportaría de mucho a este sector
6.-¿Cree usted que las aplicaciones móviles dirigidas al campo agrícola permitirán reducir el tiempo utilizado por el agricultor para poder identificar una plaga o enfermedad en el cultivo del cacao?	Si 97% No 3%	Tras conocer los resultados el 97% de la población que vendrían siendo 85 agricultores indicaron óptimos resultados.
7.-¿Cree usted que las aplicaciones móviles incrementaran los niveles de información que se obtienen acerca de la plaga o enfermedad identificada; en sectores de producción agrícola?	Si 97% No 3%	Tras conocer los resultados el 97% de la población encuestada indican que están de acuerdo que por medio de las aplicaciones móviles si se puede obtener más información acerca de las diferentes enfermedades que padecen el cultivo del cacao.

Elaborado por: Las Investigadoras

La tabulación de los resultados se encuentran detallados en el anexo 5.

9.3. Diseño de la propuesta

9.3.1. Plan de Ataque

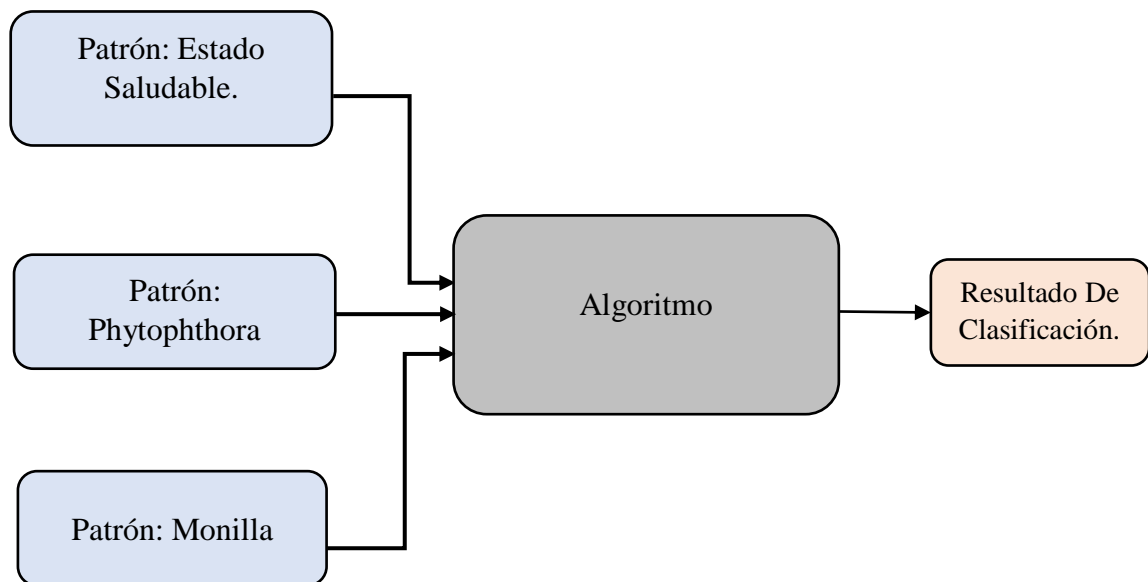
Dentro de los procesos del plan de ataque el objetivo es construir el modelo para diagnosticar el estado del fruto.

En un modelo de machine learning, el proceso de construcción se da en dos fases:

Entrenamiento

- Entrenar el algoritmo a reconocer los patrones de la información almacenadas en el datasets con una cantidad de patrones obtenidos mediante fotografías en alta resolución.

Figura 1. Plan de Ataque



Descripción: Esquema sobre el plan de ataque a desarrollar en el modelo de Inteligencia Artificial.

Predicción

Una vez superada la fase de la construcción del modelo se implementará el proceso de input o imagen nueva que se desconoce su enfermedad en el fruto, por lo cual el algoritmo previamente entrenado dará su pronóstico acerca que si dicha imagen del fruto es de estado saludable o infectada por una enfermedad (Monilia o Phytophthora).

Figura 2. Modelo de Predicción



Descripción: Modelo de predicción con los patrones desconocidos y el algoritmo previamente entrenado.

9.3.2. Arquitectura de Modelo

El algoritmo desarrollado proporciona como resultado predicciones del fruto de estado saludable o infectado, en este caso la arquitectura del modelo de IA que se implementará se basa en una Red Neuronal Convolutiva lo cual está basada en dos componentes:

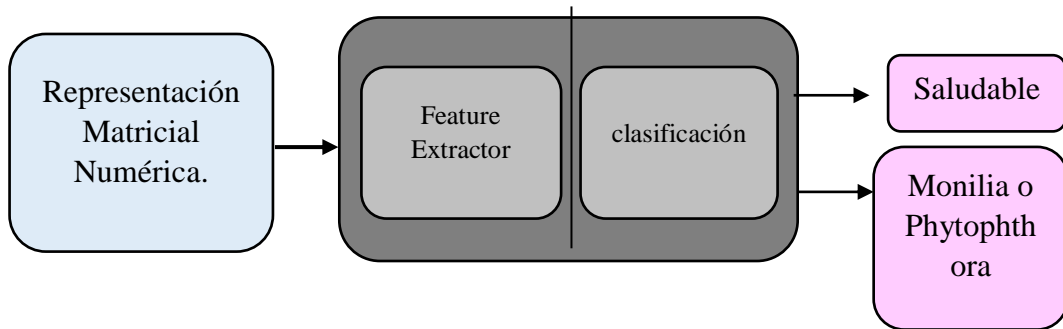
Feature Extractor (Convulsión)

- Este componente realizará operaciones matemáticas de matrices llamadas operaciones de convulsión, lo cual este procesamiento permitirá que sea posible que una red convulsional pueda aprender y entender los patrones que existen en dichas imágenes los cuales estas serán convertidas a su representación matricial numérica.

Clasificación

- En esta fase de clasificación se realizará el proceso de categorización, lo cual determina si que la información que está recibiendo es de tipo saludable, Monilia o Phytophthora basada en porcentajes.

Figura 3. Arquitectura de Modelo




Descripción: Modelo de la arquitectura de convolución para el proceso de clasificación de los patrones.

Red convolucional: DenseNet

DenseNet se compone de bloques densos. Dentro de esos bloques, las capas están densamente conectadas entre sí: cada capa obtiene la entrada de mapas de características de salida de capas anteriores. Esta reutilización extrema de residuos crea una supervisión profunda porque cada capa recibe más supervisión de la capa anterior y, por lo tanto, la función de pérdida reacciona en consecuencia y, debido a esta metodología, la convierte en una red más poderosa.


Gráfico 1. Bloques DenseNet



Fuente: <https://ichi.pro/es/explicacion-de-las-redes-neuronales-convolucionales-cnn-de-ultima-generacion-densenets-75969814801645>

Elaborado por: ichi.pro

Figura 4. Red Convolucional DenseNet




Descripción: Dentro del desarrollo de la arquitectura de modelo se debe tener en cuenta, una red pre entrenada de tipo DenseNet para tomar los pesos que obtuvo la red neuronal en un proceso de entrenamiento anterior, permite tomar imágenes de otro datasets.

Técnica de Transfer learning

La técnica de transfer learning consiste en el aprendizaje automático dentro de la inteligencia artificial, lo cual se aprovecha dentro de los modelos IA una cantidad de información relacionada a patrones con una mayor cantidad de volumen y peso. Esto permitirá que la arquitectura de red neuronal acelere su aprendizaje.

Figura 5. Pre-entrenado Imagenet



Descripción: Dentro del mecanismo de trabajo del proyecto de investigación se toma la red neuronal de tipo DenseNet y pesos de un entrenamiento anterior, lo cual se procede a remover los componentes de modelos de clasificación de tal forma que solo se quedará el modelo de convolución manteniendo sus respectivos pesos almacenados en modelos pre entrenados-Imagenet, lo que permitirá montar el modelo de clasificación lo cual permite entrenar dicho modelo aplicando la técnica de transfer learning.

Pre-procesamiento de datos

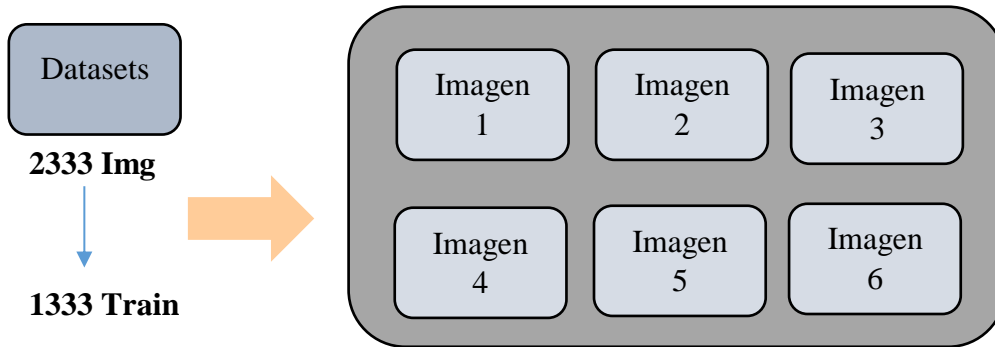
La técnica de procesamiento de datos consiste en optimizar la función matemática para cumplir un objetivo dentro de un contexto, lo cual necesitamos como resultado un procesamiento de datos de manera más eficiente a la hora de ejecutar una aplicación.

9.3.3. Normalization y Data Augmentation.

Dentro del proyecto de investigación se cuenta con imágenes almacenadas por tres secciones, lo cual se toman las imágenes por sección que serán parte del entrenamiento de la neurona artificial para así medir el impacto del modelo a la hora de predecir las imágenes, aplicando la


técnica de data augmentation para generar más datos de nuestro algoritmo con el mismo conjunto de datos.

Figura 6. Multiplicado de Imagen Data Augmentation



Descripción: Multiplicador de patrones mediante las imágenes almacenadas en la datasets.

Gráfico 2. Multiplicado de Imagen Data Augmentation



Elaborado por: Las Investigadoras

9.3.4. Entrenamiento del modelo

El proceso de entrenamiento de inteligencia artificial consiste que una arquitectura de modelo esté completamente defina, lo cual esta será procesada mediante la lectura de los datos de entrada, estos se codificaran para agruparse y luego dividirse en lotes hasta que los algoritmos sufran actualizaciones para que vuelva a leer los parámetros y datos de lotes.

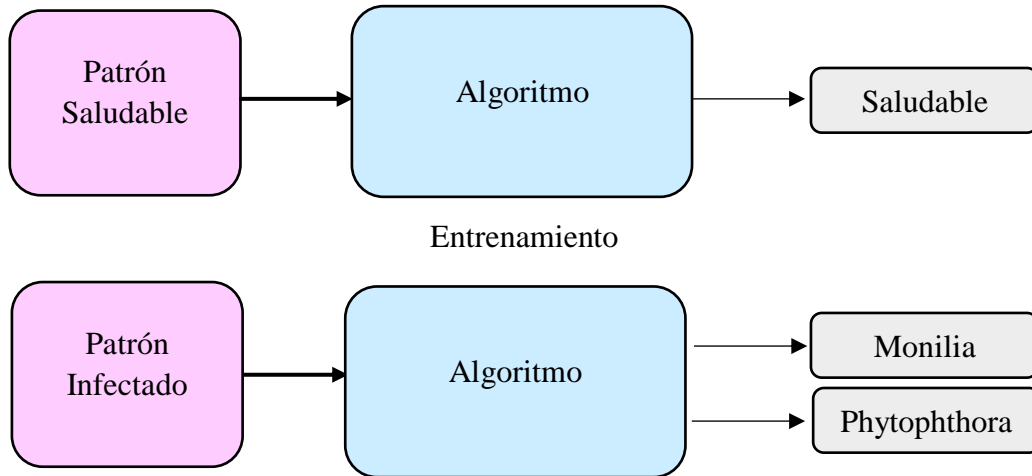
Figura 7. Spoch de Entrenamiento

```
Epoch 1/20  
31/31 [=====] - 986s 32s/step - loss: 0.1495 - accuracy: 0.9335 - val_loss: 1.4944e-04 - val_accuracy: 0.9951  
Epoch 2/20  
31/31 [=====] - 280s 9s/step - loss: 0.0036 - accuracy: 1.0000 - val_loss: 5.5818e-06 - val_accuracy: 1.0000  
Epoch 3/20  
31/31 [=====] - 275s 9s/step - loss: 0.0038 - accuracy: 0.9992 - val_loss: 1.5110e-05 - val_accuracy: 1.0000  
Epoch 4/20  
31/31 [=====] - 274s 9s/step - loss: 0.0020 - accuracy: 1.0000 - val_loss: 3.5693e-06 - val_accuracy: 1.0000  
Epoch 5/20  
31/31 [=====] - 275s 9s/step - loss: 0.0018 - accuracy: 1.0000 - val_loss: 2.6911e-06 - val_accuracy: 1.0000  
Epoch 6/20  
31/31 [=====] - 277s 9s/step - loss: 0.0023 - accuracy: 1.0000 - val_loss: 2.6604e-06 - val_accuracy: 1.0000  
Epoch 7/20  
31/31 [=====] - 278s 9s/step - loss: 0.0029 - accuracy: 1.0000 - val_loss: 2.1974e-06 - val_accuracy: 1.0000  
Epoch 8/20  
31/31 [=====] - 277s 9s/step - loss: 0.0013 - accuracy: 1.0000 - val_loss: 8.1208e-07 - val_accuracy: 1.0000  
Epoch 9/20  
31/31 [=====] - 277s 9s/step - loss: 0.0021 - accuracy: 1.0000 - val_loss: 1.7723e-06 - val_accuracy: 1.0000  
Epoch 10/20  
31/31 [=====] - 276s 9s/step - loss: 0.0017 - accuracy: 1.0000 - val_loss: 1.3569e-06 - val_accuracy: 1.0000  
Epoch 11/20  
31/31 [=====] - 277s 9s/step - loss: 0.0011 - accuracy: 1.0000 - val_loss: 6.4007e-07 - val_accuracy: 1.0000  
Epoch 12/20  
31/31 [=====] - 276s 9s/step - loss: 7.6460e-04 - accuracy: 1.0000 - val_loss: 3.2000e-07 - val_accuracy: 1.0000  
Epoch 13/20
```

Descripción: Los Spoch de entrenamiento suministrarán al algoritmo las imágenes previamente proporcionadas; lo cual el ejercicio de entrenamiento está contemplado para la realización de 60 vueltas (Spoch) al modelo para que se entrene y este pueda correlacionar las imágenes.

Proceso de intuición

Figura 8. Entrenamiento de Intuición



Descripción: A mayor número de imágenes que provee a la clase, existen mayores posibilidades de que el algoritmo va entender y clasificar como resultado de salida de las predicciones. Este proceso de entrenamiento no es automático, lo cual se tiene que repetir en varias ocasiones a través de interacciones, al principio del algoritmo no va reconocer de forma óptima las imágenes adoptando un grado de error.

Compilación de la red neuronal convolucional

Para medir el margen de error de los entrenamientos de la red convolucional se aplica la siguiente función matemática llamada; Función de costo o Binary Cross-Entropy.

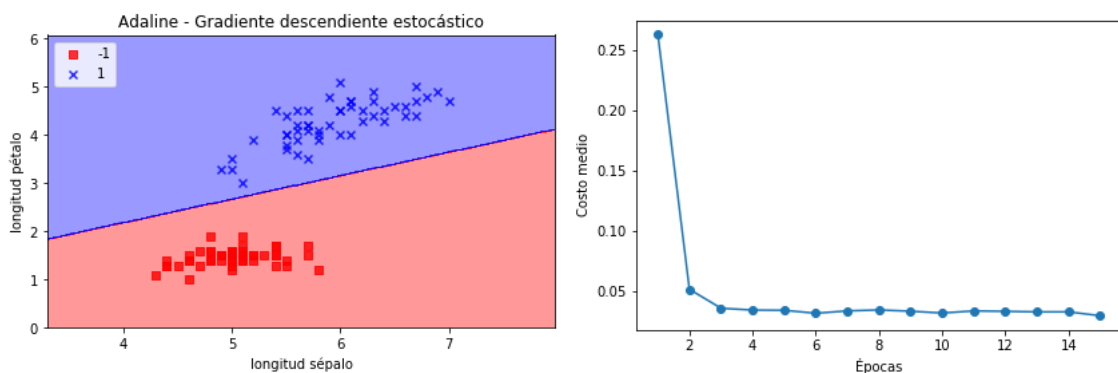
Figura 9. Ecuacion Binary Cross Entropy

$$H_p(q) = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i))$$

Binary Cross-Entropy / Log Loss

Descripción: Dentro del proceso de la compilación de la red neuronal convolucional se debe tener en cuenta que estos modelos también pasan por un proceso de optimización, lo cual va a minimizar la función de costo o error; Para ello se aplica el método de optimización llamado Gradiente Descendente Estocástica (SGD). El método Gradiente Descendente Estocástica (SGD) es un método matemático lo cual va hacer buscar un mínimo de la reducción para la función Cross-Entropy.

Gráfico 3. Método Gradiente Descendente

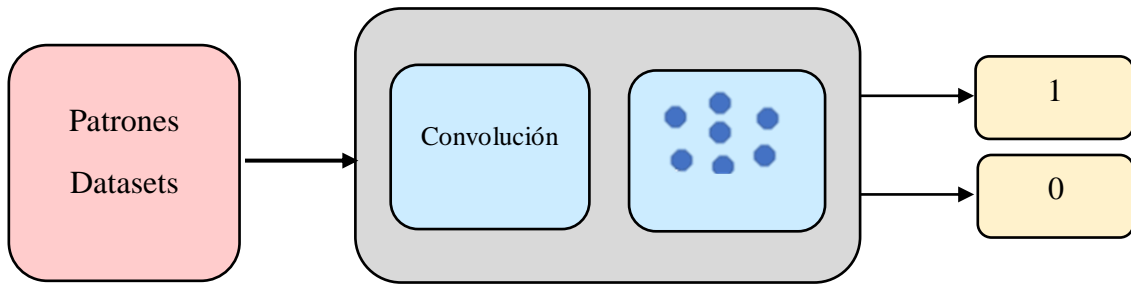


Elaborado por: Las Investigadoras

9.3.5. Entrenamiento de la Red Neuronal Convolutiva de Arquitectura DenseNet

En el proceso de entrenamiento de la red neuronal convolutiva de arquitectura DenseNet, se expondrá toda la recopilación de imágenes que se encuentran almacenados en los datasets; patrones para el proceso de entrenamiento, lo cual serán almacenados en variables de 1-0.

Figura 10. Steps de Entrenamiento 60 Épocas (Spoch)



Descripción: Se proporcionará imágenes divididas por lotes para que sean entrenadas y se ajustan los pesos de manera interna con una interacción de 60 veces, lo cual a esto se denomina épocas. Lo que permitirá es enviar las imágenes al modelo para que pueda asociar cada una de las imágenes; 1 para que el patrón sea detectado de manera saludable y 0 para que detecte que este fruto está infectado.

Figura 11. Script de Steps de Entrenamiento 60 Épocas (epochs)

```
%%time

epochs=60

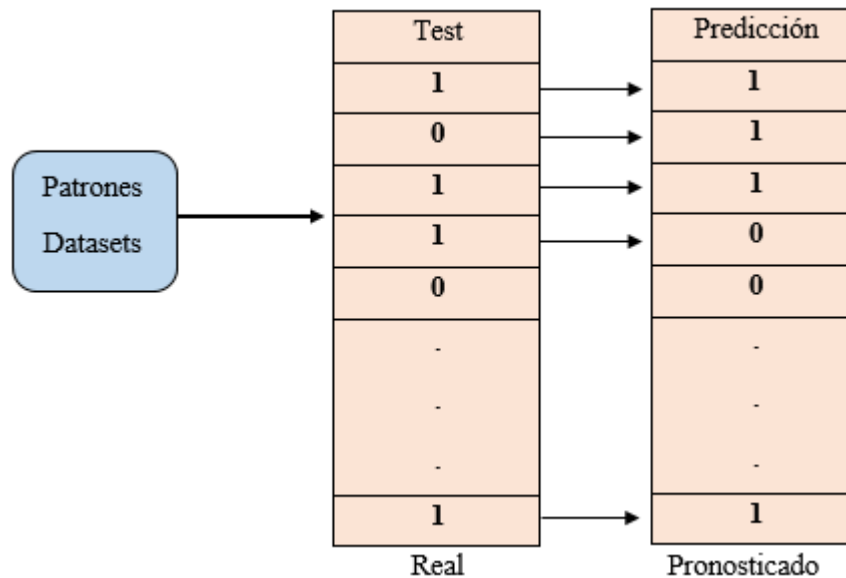
# Entrenar
history = model.fit_generator(training_set_imgs,
                              epochs=epochs,
                              steps_per_epoch=np.ceil(num_imgs_training/batch_size),
                              validation_data=testing_set_imgs,
                              validation_steps=np.ceil(num_imgs_testing/batch_size))
```

Descripción: Código de la función epochs

Evaluación del modelo

Dentro del proceso de evaluación del modelo IA consta que una vez el algoritmo ya está entrenado, se debe realizar procesos de evaluación para medir los resultados de su efectividad para realizar las predicciones adecuadas de imágenes que el modelo desconoce. Para ello utilizaremos una cantidad de entrada de imágenes que corresponden al datasets del testing para la prueba.

Figura 12. Proceso de Evaluación



Descripción: Dentro de los procesos de la evaluación se encontrará con dos valores que son; pronósticos de valores reales y valores pronosticados producto de haber pasado las imágenes al modelo y que él mismo ha pronosticado su resultado, lo cual se debe medir su efectividad mediante una matriz de comparación de resultados en la que los números binarios 0-1 estarán almacenados en variables de test y predicción. Esto permitirá que la matriz logre determinar en donde el modelo se haya equivocado, lo cual este tipo de análisis se puede aplicar en distintos procesos de testing e investigación en el desarrollo de modelos de IA; lo cual también se puede aplicar mediante una matriz de confusión.

Matriz de confusión

En el campo de la inteligencia artificial y el aprendizaje automático una matriz de confusión es una herramienta que permite visualizar el desempeño de un algoritmo de aprendizaje supervisado. Las métricas son: Por una parte, la exactitud y la precisión y por otra la sensibilidad y la especificidad.

Exactitud

- La Exactitud (en inglés, “Accuracy”) se refiere a lo cerca que está el resultado de una medición del valor verdadero. En términos estadísticos, la exactitud está relacionada con el sesgo de una estimación. También se conoce como Verdadero Positivo (o “True positive

rate”). Se representa por la proporción entre los positivos reales predichos por el algoritmo y todos los casos positivos.

Precisión

- La Precisión (en inglés “Precision”) Se refiere a la dispersión del conjunto de valores obtenidos a partir de mediciones repetidas de una magnitud. Cuanto menor es la dispersión mayor la precisión. Se representa por la proporción entre el número de predicciones correctas (tanto positivas como negativas) y el total de predicciones.

Sensibilidad y Especificidad

- La sensibilidad y la especificidad son dos valores que indican la capacidad del estimador para discriminar los casos positivos, de los negativos. La sensibilidad es la fracción de verdaderos positivos, mientras que la especificidad, es la fracción de verdaderos negativos.

Figura 13. Matriz de Confusión

Matriz de confusión		Estimado por el modelo			
		Negativo (N)	Positivo (P)		
Real	Negativo	a: (TN)	b: (FP)	Precisión ("precision") Porcentaje predicciones positivas correctas:	$d/(b+d)$
	Positivo	c: (FN)	d: (TP)		
		Sensibilidad, exhaustividad ("Recall") Porcentaje casos positivos detectados	Especificidad ("specificity") Porcentaje casos negativos detectados	Exactitud ("accuracy") Porcentaje de predicciones correctas (No sirve en datasets poco equilibrados)	
		$d/(d+c)$	$a/(a+b)$	$(a+d)/(a+b+c+d)$	

Descripción: Representación de la matriz de confusión representado por positivo y negativo.

9.3.6. Aplicación móvil con TensorFlow en Android nativo.

Tensorflow

TensorFlow Lite es un conjunto de herramientas para ayudar a los desarrolladores a ejecutar modelos de TensorFlow en dispositivos incorporados, móviles o de IoT. Permite la inferencia de aprendizaje automático en dispositivos con una latencia baja y un tamaño de objeto binario pequeño.

Componentes de inferencia

El término inferencia se refiere al proceso de ejecutar un modelo de TensorFlow Lite en el dispositivo para realizar predicciones basadas en datos de entrada. Para realizar una inferencia con un modelo de TensorFlow Lite, se debe ejecutar a través de un intérprete.

Tipo de inferencias en Tensorflow

- **Carga de modelo:** Se debe cargar el modelo en formato. tflite en la memoria, que contiene el gráfico de ejecución del modelo.
- **Transformación de datos:** Los datos de entrada sin procesar para el modelo generalmente no coinciden con el formato de datos de entrada esperado por el modelo. Por ejemplo, es posible que deba cambiar el tamaño de una imagen o cambiar el formato de la imagen para que sea compatible con el modelo.
- **Ejecución de inferencia:** El uso de la API de TensorFlow Lite a la ejecución del modelo. Implicará algunos pasos, como la construcción del intérprete y la asignación de tensores, como se describe en las siguientes secciones.
- **Interpretación de salida:** Cuando recibe los resultados de la inferencia del modelo, debe interpretar los tensores de una manera significativa que sea útil en su aplicación. Por ejemplo, un modelo puede devolver solo una lista de probabilidades. Depende de usted asignar las probabilidades a categorías relevantes y presentarlas a su usuario final.

Ejecuciones de modelos en lenguaje Java

Figura 14. Dependencia de TensorFlow

```
org.tensorflow:tensorflow-lite .
```

Descripción: La API de Java para ejecutar una inferencia con TensorFlow Lite está diseñada principalmente para su uso con Android, por lo que está disponible como una dependencia de biblioteca de Android.

Figura 15. Clase Interpreter para la carga de modelo

```
public Interpreter(@NotNull File modelFile);
```

O con un `MappedByteBuffer` :

```
public Interpreter(@NotNull MappedByteBuffer mappedByteBuffer);
```

Descripción: Una vez cargada la dependencia en Android estudio se procede a cargar la clase de tipo Interpreter para realizar la carga de modelos, lo cual permitirá obtener los valores de entrada de los tensores para así obtener a su vez los valores de salida.

Figura 16. Clase Mapped Byte

```
try (Interpreter interpreter = new Interpreter  
    interpreter.run(input, output);  
}
```

Descripción: En ambos casos, debes proporcionar un modelo de TensorFlow Lite válido o la API legal Argument Exception. Si usa Mapped Byte Buffer para inicializar un Interpreter, debe permanecer sin cambios durante toda la vida útil del Interpreter.

Tipos de datos admitidos

Para usar TensorFlow Lite, los tipos de datos de los tensores de entrada y salida deben ser uno de los siguientes tipos primitivos:

- Float
- Int
- Long
- Byte

Los tipos de son String admitidos, pero se codifican de forma diferente a los tipos primitivos. En particular, la forma de un tensor de cuerda dicta el número y la disposición de las cuerdas en el tensor, y cada elemento en sí es una cuerda de longitud variable.

Entradas

Cada entrada debe ser una matriz o matriz multidimensional de los tipos primitivos admitidos, o un Byte Buffer sin Byte Buffer del tamaño apropiado. Si la entrada es una matriz o una matriz

multidimensional, el tensor de entrada asociado se redimensiona implícitamente a las dimensiones de la matriz en el momento de la inferencia.

Figura 17. ByteBuffer de directorio

```
Interpreter.resizeInput()
```

Descripción: Cuando se aplica Byte Buffer, se debe utilizar búferes de bytes directos, esto permite al Interpreter evitar copias innecesarias.

Salidas

Cada salida debe ser una matriz o matriz multidimensional de los tipos primitivos admitidos, o un ByteBuffer del tamaño apropiado. Hay que tener en cuenta que algunos modelos tienen salidas dinámicas, donde la forma de los tensores de salida puede variar según la entrada. No hay una forma sencilla de manejar esto con la API de inferencia de Java existente, pero las extensiones planificadas lo harán posible.

Figura 18. Inicializador de Interpreter para la salida de datos

```
try (Interpreter interpreter = new Interpreter(file_of_a_tensorflowlite_model)) {  
    interpreter.run(input, output);  
}
```

Descripción: Código Interpreter para la salida de datos

9.3.7. Configuración de entorno

Dentro la implementación del framework que se seleccionó la cual va hacer TensorFlow, depende de herramientas anclas como el entorno de anaconda para así obtener la instalación de Python y sus librerías correspondientes, lo cual en primera instancia los modelos de inteligencia artificial van a ser procesados en una máquina local mediante los procesadores CUDA de la marca Nvidia, lo que proporciona un mejor procesado de imagen y poder trasladar un modelo al entorno de Android Studio. El sistema donde se desarrolla el proyecto de investigación se basa en el sistema operativo Windows 10 Pro, el cual cuenta con un procesador Intel Core I3-2100 a una velocidad de 3.10 Ghz, Memoria Ram de 12GB y una tarjeta gráfica Nvidia GTX 750 Ti.

Anaconda

Anaconda es un software de distribución libre de código abierto. Se utiliza comúnmente en el desarrollo de aplicaciones basadas en la inteligencia artificial, ciencia de datos y procesamiento de grandes volúmenes de información. Tiene un gestor de paquetes denominado anaconda, el cual se encargará de ejecutar el software destino. Para realizar la instalación de dicho gestor se siguen los pasos en su página oficial de Anaconda.

TensorFlow para GPU

Dentro del Frameworks de TensorFlow se puede seleccionar modalidades de procesamiento de imágenes distintas las cuales son: Modo CPU y Modo GPU. El de tipo CPU tomará los valores de carga dependiendo la cantidad de hilos de procesamiento que obtenga dicho dispositivo a cargar la información, en el caso de disponer un dispositivo de gama media-alta se puede aplicar el procesamiento mediante GPU dedicada, la cual proporciona que la máquina tome los núcleos de procesamiento gráfico para evitar la sobrecarga de información a procesar. La tecnología basada en procesamiento se conoce como la arquitectura unificada de dispositivos de computación (Compute Unified Device Architecture - CUDA), esto hace referencia a la plataforma de computación de tipo paralelo basada en una codificación algorítmica sobre la GPU de un fabricante, en este caso se ejecutará mediante el cliente Nvidia.

Android Studio

Android es un sistema operativo de código abierto, en la actualidad es desarrollado por la compañía de Google, lo cual está enfocado al desarrollo de aplicaciones nativas con sistemas de pantalla táctil. El desarrollo de aplicaciones nativas para dicho sistema operativo es de manera amplia y de manera asequible, es por eso que la compañía de Google decide lanzar un entorno de desarrollo integrado (Integrate Development Environment-IDE). Android Studio en la actualidad es el IDE oficial para la plataforma Android lo cual se puede obtener de manera gratuita y todas sus herramientas a disposición.

9.3.8. Gestión de la base de datos en el entorno de desarrollo (Datasets)

Dentro de los aspectos del desarrollo de modelos de inteligencia artificial de tipo red convolucional, se debe tener en cuenta la ejecución de su implementación lo cual un tipo de red

de clasificación debe cumplir con la calidad de datos utilizados en sus fases de planeación, creación, entrenamiento y testing del modelo final. Esto permitirá comprender cómo tratar los modelos de manera interna y poder establecer criterios de condición capaces de enfrentar adversidades existentes en modo de producción del clasificador de imagen.

El datasets o imágenes que lo compone al modelo de inteligencia artificial, deberá tener la medición exacta de la relación de aspecto que las imágenes que son captadas en tiempo real en la aplicación. El propósito es implementar una aplicación móvil nativa para los sistemas Android. La API de tensorflow se encargará de gestionar al dispositivo que en este caso es la cámara, lo cual tendrá un apartado de resolución por defecto de 1920 x 720 píxeles, cuya proporción de ratio será de 16:9, independientemente del modelo de móvil donde se ejecutará el proceso de clasificación. Estos datos serán redimensionados por el proceso de entrada de datos de la red; tanto así guardarán relación y precisión del clasificador como la gestión de los datos lo cual resultará más eficiente.

Dentro de la ejecución de pruebas de manera local se han seleccionado 12 imágenes en formato JPG, lo cual tiene como finalidad realizar las pruebas previamente ya definidas. Como se trata de un clasificador de imágenes y dentro del caso de estudio es determinar el estado del fruto, deberán ser las imágenes fragmentadas en tomas que representen dicho estado de salud. El tiempo de ejecución de la medición del estado de la fruta es de 1 segundo, por lo cual en temas técnicos de imagen estas son reproducidas a 30 FPS por segundo, dependiendo del móvil donde se ejecute la aplicación.

TensorFlow recibirá la información del modelo puesto en producción, lo cual interpretará en un lenguaje de etiquetas como (“Sana”, “Monila”, “Phytophthora”), una especie de organización de directorios conectados mediante una API y ficheros de la misma clase; para una mayor optimización de los ficheros tenemos que basarnos en las etiquetas.

9.3.9. Implementación de la red convolucional entrenada por proceso de transfer learning en Android

La técnica que se empleó en el proceso de desarrollo del modelo de inteligencia artificial es conocida como transferencia de aprendizaje o transfer learning. Lo cual este método es utilizado para utilizar modelos entrenados de manera previa en bases de datos distintas lo cual centra en

modificar los restantes de la capa de salida de la red convolucional. Aplicar la técnica de transfer learning ayuda al desarrollador a centrarse en sus datos más representativos del datasets, la cual puede formar conjuntos reducidos de datos gracias el método antes mencionado. El nivel de procesamiento computacional se reduce a medida, los modelos previamente entrenados reciben la técnica de reentrenamiento de modelos.

Una vez que se cumplieron las fases de entrenamiento, optimización y pruebas en el proceso de desarrollo de los modelos IA; como última fase se debe realizar las tasas de precisión donde se obtengan los resultados que se buscan, lo cual es necesario a la fase de optimización del modelo para así mejorar los resultados deseados.

Implementación de arquitectura MobileNet en Android

TensorFlow contiene un repositorio de scripts destinados para la implementación de reentrenamiento de modelos de inteligencia artificial de tipo transfer learning. Dentro de la etapa de implementación del modelo los datasets se emplean de modo que los clasificadores de imágenes sean capaces de captar el reconocimiento del estado del fruto cuando la imagen de entrada no es de signo identificable o no es de previa preparación.

Dentro de la implantación de clases, el script se encargará de preparar la red neuronal lo cual se recibe con el nombre de cuantificación, diseñado para que se ejecute en la arquitectura de MobileNet, este modelo opta de un cálculo computacional elevado pero convertido a una versión ligera para el despliegue en terminales de baja capacidad de procesamiento. Dicha arquitectura se descarga en el IDE de desarrollo mediante los servidores de TensorFlow y la importación de dependencias.

Una vez seleccionado el modelo que se va implementar en las clases de java, debemos tener en cuenta que el proceso de cuantificación realizará una configuración de manera automática llamado proceso de cuello de botella, lo cual consta que las imágenes de la base de datos eviten el bajo rendimiento de procesamiento con los dispositivos móviles. Este tipo de capa se entrena para generar valores de buena condición para que los clasificadores a la hora de ejecutarse sean capaces de distinguir entre clases lo que se debe de reconocer.

Los scripts permitirán elegir el modelo de salida a procesar, se puede aplicar la técnica de data augmentation, procede multiplicar los valores del datasets y así evitar la sobrecarga de procesamiento en el terminal donde se ejecute la aplicación.

Tabla 7. Argumentos de ficheros TensorFlow

Argumentos	Descripción del argumento
--output_graph	Modelos de proceso de salida
--output_labels	Etiquetas de modelo
--learnig_rate	Tasa de aprendizaje neuronal
--testing_percentage	Número de imágenes del test
--validation_percentage	Número de imágenes de validación
--model_dir	Directorio de modelo
--final_tensor_name	Nombre del tensor final en ejecución
--architecture	Arquitectura de partida

Elaborado por: Las Investigadoras

Dentro del proceso de configuración múltiple del modelo MobileNet, existe el proceso de resolución de imágenes de entrada que oscilan entre 160, 192 y 224 píxeles lo cual determina el tiempo de procesamiento de la red; en cuanto mayor resolución de pixeles obtenga la imagen más tiempo tomará en procesar el modelo para mostrar los resultados de la predicción.

En la arquitectura podremos elegir el tamaño relativo del modelo, lo cual posibilita elegir un estimado del 25% hasta el 100% en MobileNet, la diferencia será en el número establecido de capas dentro de la arquitectura.

Las variables de asignación de la arquitectura deseada se tienen que definir en una variable de tipo "Architecture" a un estimado de tamaño relativo del 100%; normalizado de 1 – 224% píxeles utilizando el modelo de inteligencia artificial de mayor calidad mediante fragmentos o clases de Código de Java.

Figura 19. Código de arquitectura MobileNet

```
ARCHITECTURE="mobilenet_1.0_224"  
py    | scripts.retrain \  
      --bottleneck_dir=tf_files/bottlenecks \  
      --architecture="${ARCHITECTURE}" \  
      --model_dir=tf_files/models/ \  
      --output_graph=tf_files/default/retrained_graph.pb \  
      --output_labels=tf_files/default/retrained_labels.txt \  
      --image_dir=tf_files/gestures
```

Descripción: En la finalización del proceso de transfer learning, se procede a crear nuevos modelos en base a la arquitectura de etiquetas, lo cual tenemos que indicar a los directorios donde exportamos los modelos mediante el argumento de `retrained_graph` y `retrained_labels.txt`. El primer argumento lo emplea el framework TensorFlow de manera automática y el segundo fichero de tipo texto contendrá las etiquetas que se asignaron a los patrones que fueron clasificados previo entrenamiento en la preparación del modelo.

Los parámetros del script se pueden utilizar por defecto debido a los resultados obtenidos en el proceso de salida de la clasificación no sufren de alteraciones, este proceso se lo realiza con el fin que los resultados que se requieren sean de manera óptima y lo cual se procede a la elaboración de la optimización del modelo en Android.

Optimización de la arquitectura MobileNet en Android

Dentro de la implementación de la arquitectura MobileNet, necesita que el lote realice una iteración a la hora de comenzar el entrenamiento, Los números de pasos representan la cantidad que la imagen va hacer procesada almacenada en un datasets con un batch size de 20, adjuntando la variable de training que consta de 60 steps.

La tasa de aprendizaje marcará el valor que se utilizará para entrenar el modelo mediante la aplicación de algoritmos de tipo “Gradientes”. Esta técnica evita la perdida de los pesos mediante el cálculo de los parámetros condicionados de los datos obtenidos de los entrenamientos. Este algoritmo logra combinar los pesos parametrizados en función de cada capa, lo cual se multiplicará en los valores de la tasa de aprendizaje por el gradiente y su producto final.

Dentro de la dinámica de la optimización, considera parámetros previamente definidos, lo cual se procedió a insertar 5 modelos para medir distintos valores de learning rate o tasa de aprendizaje; cada uno con sus pasos u training Steps de cada modelo.

Tabla 8. Tasas de aprendizaje y cantidad En pasos

Nombre del modelo	Identificadores	Nivel de aprendizaje	Steps
Modelo 1	LR_1_ST_400	1	20
Modelo 2	LR_1_ST_400	1	20
Modelo 3	LR_0.5_ST_1200	0,5	20
Modelo 4	LR_0.1_ST_500	0.1	60

Elaborado por: Las Investigadoras

Para optimizar los entrenamientos steps y learning rate, debemos tener en cuenta los comandos que se van a insertar para nombrar los directorios que componen los modelos, estos van hacer representados por fragmentos de código para ejecutar dicha funcionalidad.

Figura 20. Script de optimización mediante la API TensorFlow

```
read -p "Training steps: " STEPS # Ask for the training steps hyperparameter
read -p "Learning rate: " LR # Ask for the learning rate hyperparameter
mkdir tf_files/LR_"$LR"_ST_"$STEPS"/ # Creates a new directory for this model
python -m scripts.retrain \
  --bottleneck_dir=tf_files/bottlenecks \
  --architecture="{ARCHITECTURE}" \
  --how_many_training_steps="$STEPS" \
  --model_dir=tf_files/models \
  --learning_rate="$LR" \
  --summaries_dir=tf_files/training_summaries/LR_"$LR"_ST_"$STEPS" \
  --output_graph=tf_files/LR_"$LR"_ST_"$STEPS"/retrained_graph.pb \
  --output_labels=tf_files/LR_"$LR"_ST_"$STEPS"/retrained_labels.txt \
  --image_dir=tf_files/gestures
```

Descripción: Mediante la ejecución del script de optimización se almacenarán ficheros de manera automática para garantizar que los modelos estén en correcto funcionamiento del clasificador de imagen.

Fase de pruebas del modelo en la arquitectura MobileNet

La fase de prueba consistirá que; el modelo de inteligencia artificial previamente desarrollado y empaquetado debe ser trasladado a la implementación del clasificador de imágenes en

Android. Para ello se debe realizar el proceso de análisis y tiempo de clasificación de la imagen, esto determinará el proceso de etiquetas de las imágenes a clasificar.

Para ello se debe tener en cuenta las características de entrada y salida de datos de la red neuronal.

Tabla 9. Argumentos de los ficheros a procesar

Argumentos	Descripción del argumento
--image	Imagen que se procede a clasificar
--labels	Modelo de etiqueta a utilizar
--input_height	Altura de la capa de la red neuronal
--input_width	Anchura de la capa de la red neuronal
--input_mean	Media de la capa de entrada
--input_std	Desviación típica de la capa
--input_layer	Nombre de la capa de entrada
--output_layer	Nombre de la capa de salida

Elaborado por: Las Investigadoras

Figura 21. Etiquetas obtenidas en la clase del clasificador

```

key = top_k[0] # Save the top
label template = "{:0.5f}"

        array = [file_name, labels[key],
template.format(results[key])] toCSV = ','.join(array) # Format
        to tensor

        print(toCSV)

```

Descripción: Como objetivo principal es comprobar la medición de tasas de precisión de los 4 modelos creados en las fases de planeación, entrenamiento y optimización. Para el almacenamiento de los resultados, añadiremos varias líneas de script, cuyo fin será registrar las etiquetas del empaquetado obtenidas por el clasificador y su tasa de nivel de aciertos.

Mediante el fichero codificado debemos iterar el paquete de datasets de las imágenes y modelos denominado “classify.sh”. Estos fragmentos de código permitirán emplear funciones para ejecutar los modelos y así almacenar en fichero, para obtener la salida del clasificador.

Figura 22. Almacenamiento de Fichero de Etiquetas

```
## FUNCTION TO CLASSIFY THE TEST IMAGES
function classify {

    python -m label_image \
        --graph=../TransferLearning/tf_files/LR_"$LR"_ST_"$STEPS"/retrained_graph.pb \
        --
        labels=../TransferLearning/tf_files/LR_"$LR"_ST_"$STEPS"/retrained_labels.txt \
        --image=test/Test"$TEST".jpg
}

classify >> csv/TEST_LR_"$LR"_ST_"$STEPS".csv
```

Descripción: Culminado el proceso de almacenamiento, se procede analizar los datos obtenidos de la prueba del modelo, para así determinar si existe una tasa de aciertos superior. Los modelos fueron seleccionados de manera óptima para ser implementados en la fase de desarrollo del clasificador de enfermedades del cacao en Android.

9.3.10. Implementación del modelo clasificador de enfermedades del cacao en sistemas Android

TensorFlow Lite

TensorFlow Lite o TFLite es una solución liviana para dispositivos móviles e integrados desarrollada por Google LLC y que pertenece a la plataforma TensorFlow. Permite implementar aplicaciones en iOS y Android mediante una API de C++, aunque para la plataforma Android existe un intérprete en Java.

Para poder utilizar modelos de redes neuronales artificiales en los dispositivos móviles, estos se implementan en una máquina de características adecuadas al nivel de procesamiento requerido, para más tarde ser convertidas al formato en que trabaja esta solución: “. lite”.La precisión de modelos dentro de TensorFlow no alcanza los niveles de precisión obtenidos dentro de las arquitecturas planteadas dentro del proceso del desarrollo del modelo, pero cabe destacar que si resulta suficiente para el tipo de aplicación que deseamos.

Instalado TensorFlow para Android, podemos utilizar el script que permitirá convertir el modelo ya desarrollado con anterioridad con el formato.” lite”. Esto se define mediante un proceso de argumentos de la característica de la red neuronal tanto sus datos de entrada como de salida, ubicación y tipo de dato.

Figura 23. Proceso de conversión para la obtención de mejores resultados

```
tflite_convert \  
    --graph_def_file=retrained_graph.pb \  
    --output_file=graph.lite \  
    --input_format=TENSORFLOW_GRAPHDEF \  
        --output_format=TFLITE \  
    --input_shape=1,224,224,3 \  
    --input_array=input \  
    --output_array=final_result \  
    --inference_type=FLOAT \  
    --input_data_type=FLOAT
```

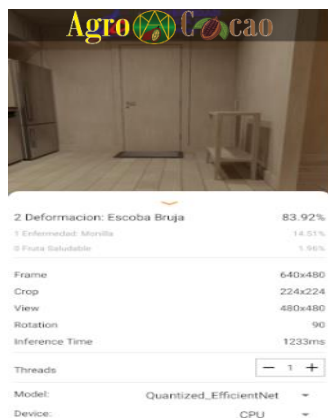
Descripción: Código del proceso de conversión para la obtención de resultados.

Clasificación de imágenes en sistemas Android

Android Studio, el IDE oficial para el sistema operativo Android, tiene disponible en su repositorio una librería para procesar imágenes en dispositivos móviles: camera2 API. Lo cual gestionará por medio de métodos y clases en Java el uso de las cámaras en terminales móviles.

Dentro del proceso de codificación de la aplicación se tomará como lenguaje de programación Java. El aspecto de manera inicial será que al ejecutarse la aplicación móvil este contendrá un layout con los tipos de opciones de procesamiento de imágenes y las etiquetas de los modelos para mostrar los resultados.

Gráfico 4. Aplicación Ejecutada en un Terminal Virtual Android



Elaborado por: Las Investigadoras

El fichero “AutoFitTextureView.java” determinara mediante una clase que realice la función de auto dimensionado del terminal en ejecución. Esto permitirá que la aplicación móvil capture la imagen desde la cámara, lo cual procede ajustar la proporción de aspecto que utilizara la aplicación.

Figura 24. Clase de tipo ImageClassifier.java

```
private String printTopKLabels() {  
  
    for (int i = 0; i < labelList.size(); ++i) {  
        sortedLabels.add(  
            new AbstractMap.SimpleEntry<>(labelList.get(i), labelProbArray[0][i])); if  
            (sortedLabels.size() > RESULTS_TO_SHOW) {  
                sortedLabels.poll();  
            }  
        }  
        for (int i = 0; i < size; ++i) {  
            Map.Entry<String, Float> label = sortedLabels.poll();  
  
            if (label.getKey().equals("none") | label.getValue() < 0.85f) { textToShow  
                = null;  
            } else {  
                textToShow = String.format("%s", label.getKey()) + textToShow; textToShow  
                    = textToShow.substring(0, 1).toUpperCase() +  
                        textToShow.substring(1);  
            }  
        }  
        return textToShow;  
    }  
}
```

Descripción: La clase “ImageClassifier.java” permitirá que exista una comunicación dentro de la API de TensorFlow para utilizar los modelos convertidos. Este se iniciará en una sesión de entorno y con la misma técnica se puede clasificar las imágenes de entrada para así poder determinar el resultado de muestra en las etiquetas que se encontraran en la parte superior del box de información.

Esto tendrá el fin de asociar los resultados de manera robusta, lo cual impondrá condiciones de muestra de los resultados, a no ser que en casos las tasas de precisión sean superiores al 80%. El procedimiento conlleva a la implementación del código, donde estableceremos un condicional “if” que evaluará el proceso de la etiqueta “vacía” o si la presión es menor que 0.80.

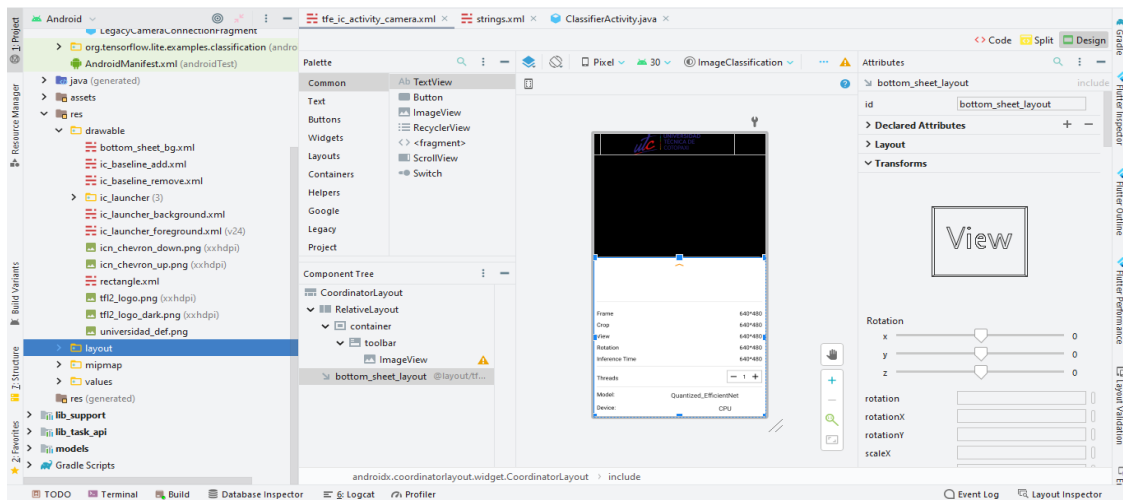
La clase del “fragment.java” se encargará de gestionar la cámara del terminal Android, para este proyecto gestionaremos la captura con la cámara trasera, lo cual se ajusta la proporción de aspecto para aplicar la funcionalidad de auto dimensionado y así poder a ejecutar la clasificación de imágenes, mostrar en pantalla los resultados esperados mediante la clase “imageClassifier.java” por defecto.

Interfaz gráfica para el usuario

La interfaz gráfica actuará como un intermediario entre el procesamiento de datos (Computador-terminal móvil) y el cliente final u beneficiario, mediante objeto gráfico podemos representar información y acciones disponibles para su uso en la aplicación de manera fácil e intuitiva.

El entorno de Android Studio proporciona elementos prediseñados que podemos también modificar elementos mediante un lenguaje marcado extensible (XML). Lo cual permite realizar cambios para que el usuario pueda observar desde su terminal la clasificación de los frutos. Implementaremos la interfaz gráfica de TensorFlow, lo cual invita al usuario a una aplicación amigable y profesional.

Gráfico 5. IDE Android Studio Cámara Activity



Elaborado por: Las Investigadoras

Para el proceso de desarrollo de la aplicación del usuario, se basa en la interfaz gráfica de tipo clasificación de la API de TensorFlow, al ejecutar la aplicación solicitará los respectivos permisos para acceder al hardware, en este caso la cámara trasera. En la parte inferior del aplicativo se encontrarán con el box de información donde el clasificador a través de las etiquetas comenzará a mostrar los resultados obtenidos en tiempo real.

Dentro del cálculo de resultados de la clasificación de enfermedades, también se encuentra los apartados de configuración cual son los siguientes:

- **Frame:** Desliza una ventana de tamaño `frame_length` sobre la dimensión del eje de la señal. Si `pad_end` es `True` (Verdadero), las posiciones de la ventana que sobrepasan el final de la dimensión del eje se rellenan con `pad_value` hasta que la ventana se mueve completamente más allá del final de la dimensión. De lo contrario, solo se generan las posiciones de ventana que se superponen completamente con la dimensión del eje.
- **Crop:** Extrae cultivos del tensor de imagen de entrada y los redimensiona mediante muestreo bilineal o muestreo de vecino más cercano (posiblemente con cambio de relación de aspecto) a un tamaño de salida común especificado.
- **View:** Renderización de imágenes por tensores.
- **Interference time:** Realiza operaciones matemáticas subyacentes que serán las mismas que entrenaron los modelos, principalmente realizará operaciones de multiplicación de matrices para que los valores realicen las operaciones de suma y multiplicación subyacentes. Esto

implica si el gráfico contiene algunas estructuras de flujo de control más avanzadas que pueden influir en el tamaño real en función de los valores de ciertos tensores.

- **Rotation:** Gira las imágenes en sentido antihorario por los ángulos pasados de tipo radianes.
- **Threads:** Obtiene el número de subprocesos utilizados para el paralelismo entre operaciones independientes
- **Model:** El modelo agrupa capas en un objeto con funciones de entrenamiento e inferencia.
- **Device:** Especifica el dispositivo para operaciones creadas / ejecutadas en este contexto.

Modelos de inteligencia artificial

Los resultados obtenidos a lo largo de la presente investigación se enfocarán a las fases de la implementación de modelos de inteligencia artificial dentro de su estado inicial hasta el final. La fase de entrenamientos, donde se aplicó un reentrenamiento de los distintos modelos desarrollados, lo cual estos provienen de la arquitectura MobileNet. Permitirá que estos resultados a analizar son especificaciones gráficas representativas de los modelos en cuanto al nivel de maduración neuronal.

Una vez obtenido el modelo de inteligencia artificial se implementará la fase de pruebas, lo cual se busca mejorar la arquitectura dentro de las tasas de precisión sobre determinado conjunto de imágenes. Dentro del análisis, se debe representar la calidad del modelo a ejecutar, donde cada modelo obtiene diferentes tasas de aciertos. Para visualizar la calidad del modelo, debemos ejecutar la prueba de forma manual, esto representará los resultados. En esta ocasión se aplicará la matriz de confusión para dicha prueba.

9.3.11. Evaluación obtenidos dentro de la fase de entrenamientos

Dentro de la plataforma de TensorFlow dispone varias herramientas de visualización gráfica para la medición de presiones de datos. Esto permite aplicar gráficos de entrenamiento, generar medidas de tipo cuantitativas de la calidad de los modelos de inteligencia artificial hacer analizados.

Figura 25. Clase de tipo Grafico Matplotlib

```
# GRAFICANDO resultados
import matplotlib.pyplot as plt
fig = plt.gcf()
fig.set_size_inches(12, 8)
```

Descripción: Los gráficos utilizados en los resultados se obtienen mediante un comando que se introduce en las celdas de codificación; antes de ejecutar el entrenamiento de la red, se debe tener en cuenta que consiste en crear contenido de forma periódica durante toda la fase de entrenamiento y finalizando el proceso dentro del mismo terminal.

Se analizan los gráficos representativos de los distintos escenarios ejecutados en la fase de entrenamiento. Se resuelve analizar las características de la gráfica de precisión y gráfica de función de pérdida.

Figura 26. Número total de predicciones alcanzadas

$$Accuracy = \frac{\text{Numero de predicciones correctas}}{\text{Numero total de predicciones hechas}}$$


Descripción: En terminología neuronal, la precisión representa las relaciones entre los números y predicciones correctas dentro del análisis del modelo y el número total de muestras.

Dentro de la optimización de los algoritmos, esta función evaluará la solución lo cual se conoce como función de objetivo. Este tipo de función se basa en maximizar o minimizar valores para la obtención de un porcentaje alto o bajo. En caso de las redes neuronales la idea de dicha solución aplicada es minimizar la tasa de error, cuya función pasaría a denominarse función de pérdida.

Dentro del procedimiento gráfico, se observa trazos distintos, divididos en grupos y colores. El color naranja hace referencia a la curva asociada al conjunto de datos de entrenamiento, mientras que las líneas azules hacen referencia a la muestra de validación de dicho modelo. El estado de las curvas transparentes representa la tendencia de curvas dispersas mencionadas anteriormente.


Para obtener una comparación entre modelos distintos, se debe establecer rangos de visualización de los ejes de ordenadas para cada curva; la gráfica de precisión se trabaja en un intervalo de [0.8], mientras que el nivel de pérdida es de [0, 0.4].

Gráfico 6. Gráfico de precisión de época del Modelo IA




Elaborado por: Las Investigadoras

Gráfico 7. Gráfico de pérdida de época del Modelo IA




Elaborado por: Las Investigadoras

Gráfico 8. Gráfico de disminución del error por época



Elaborado por: Las Investigadoras

Gráfico 9. Gráfico de exactitud cercano a uno



Elaborado por: Las Investigadoras

9.3.12. Resultado Obtenidos en la fase de pruebas en la aplicación Android

Seleccionado los modelos cuya tasa de precisión es de manera elevada, se debe implementar en la aplicación que supone la culminación del aplicativo final. En esta fase se procede a evaluar la calidad de la red neuronal desarrollada; pasada por el proceso de conversión y despliegue en el terminal móvil.

Tabla 10. Resultados del Clasificador implementado en Android

Argumentos	Precisión
“Fruto Sano”	95%
“Monilia”	98%
“Phytophthora”	92%

Elaborado por: Las Investigadoras

Descripción: La tabla de resultados del clasificador consiste en situar el dispositivo y ejecutar acciones para analizar la calidad del modelo y el tiempo de respuesta del mismo. Lo que se obtiene son los cálculos de cada elemento mediante su tasa de predicción en las imágenes clasificadas.

10. IMPACTO DEL PROYECTO.

El Proyecto de Investigación genera gran impacto tecnológico, consiste en el monitoreo del cultivo de cacao mediante la aplicación móvil, que permite la identificación del tipo de enfermedades y el porcentaje avanzado que se encuentra en la mazorca, de manera social este proyecto brindará a los agricultores una aplicación móvil que va a estar al alcance de todos ya sean grandes, medianos o pequeños productores.

El impacto ambiental que posee el proyecto es ayudar a la reducción de frascos de plásticos, saquillos y a la recuperación de la flora y fauna de los terrenos, mediante el uso adecuado y monitoreo del cacao. Además, de controlar estas enfermedades periódicamente con la aplicación móvil, se reducen los gastos en productos como el abono, pesticidas y la mano de obra.

11. PRESUPUESTO PARA LA PROPUESTA DEL PROYECTO

Tabla 11. Presupuesto del proyecto

RECURSOS			
	Cantidad	Precio U	Total
Tecnología			
Laptop	1	450,00	450,00
Samsung Galaxy J6	1	280,48	280,48
Internet	6 meses	20,00	120,00
Pendrive	1	15,00	15,00
Sub- total			865,48
Desarrollo del software			
Google Colab		0,00	0,00
Android Studio		00,00	00,00
Sub-total			00,00
Accesorios técnicos de especialización Agronómica			
Accesorios en la especialización Agronómica	1	500,00	500,00
Sub-total			500,00
Gastos Indirectos			
Transporte	30 días	2	150,00
Alimentación	30 días	2	75,00
Sub-total			225,00
TOTAL			1,590.48

Elaborado por: Las Investigadoras

12. CONCLUSIONES Y RECOMENDACIONES

Conclusiones

- Las plantaciones cacaoteras representan pérdidas que afectan de manera directa por la alta incidencia de enfermedades; especialmente en la fase de clasificación de la plantación, de tal manera que los frutos afectados por determinada enfermedad deben ser eliminados antes que se reproduzcan esporas en el ambiente, lo cual en este aspecto interviene el proceso de clasificación y predicción de enfermedades del cacao mediante la recopilación de datos (fotos) de las mazorcas saludable y enferma (Monilla y Phytophthora) a través de la investigación de campo para la obtención del DataSet y el desarrollo del plan modelo de la IA.
- Las técnicas de Deep Learning aplicadas en los modelos de clasificación son Data Augmentation que es la encargada de multiplicar los patrones mediante la reconstrucción por píxeles de las imágenes reales que contiene la data set, la técnica de convolución consiste en múltiples capas de filtros convolucionales y cada capa cumple una función de mapeo para extraer las características de la clasificación designada y la técnica Pooling que cumple la función de resumir las respuestas de las salidas cercanas y cuenta con dos características la primera reduce progresivamente el tamaño espacial de los datos y segundo, ayuda a obtener una representación invariable a una pequeña traslación de la entrada mediante la agrupación.
- Mediante los modelos de inteligencia artificial desarrollados e implementados en la aplicación móvil en Android Studio se logró evaluar el impacto; mayormente en los tiempos de respuesta óptimos, lo cual permitió afirmar con muestras seleccionadas los resultados de un acierto del 87% promedio por cada estado de enfermedad analizada.

Recomendaciones

- Es de importancia identificar los aspectos que intervienen en la clasificación de las enfermedades dentro del campo agrícola; esto permitirá que dentro del proceso del desarrollo software se establezcan parámetros a seguir en las técnicas implementadas de inteligencia artificial, manteniendo así un enfoque de la metodología aplicada a los entornos de desarrollo IA.
- Dentro del desarrollo de proyectos basados en inteligencia artificial lo cual representa un alto nivel y complejidad, se debe tener en cuenta las tecnologías adecuadas para que estas sean implementadas de mejor forma en el proceso de desarrollo.
- Para futuras investigaciones se recomienda entrenar las redes neuronales convolucionales para la recolección de imágenes mediante aprendizaje no supervisado, para evitar la inconsistencia de datos.

13. BIBLIOGRAFÍA

- Linea Agrícola. (2012). *Manejo fitosanitario del cultivo de cacao, (Theobroma cacao) Medidas para la temporada invernal*. Obtenido de <http://infocafes.com/portal/wp-content/uploads/2016/05/cartilla-cacao-ICA-final.pdf>
- Adobe Systems Incorporated. (2010). *CONCEPTOS DE IMPLEMENTACIÓN Y APROVISIONAMIENTO*. Adobe Systems Incorporated, 5.
- AGROPECUARIAS, I. N. (s.f.). *images/rubros/contenido/cacao/monilia.pdf*. Obtenido de <http://tecnologia.iniap.gob.ec>
- Al-Hiary, H. e. (2011). Fast and accurate detection and classification of plant diseases. *Computer Application*, 31-38.
- Amara, J., Bouaziz, B., & Algergawy, A. (2017). A deep learning-based approach for banana leaf diseases classification. in *Proceedings of the Datenbanksystemefür Business, Technologie und Web (BTW '17) Workshopband*.
- Android Studio. (18 de Noviembre de 2020). *Android Studio*. Obtenido de Android Studio: <https://developer.android.com/studio>
- Babu, M., & Rao, B. (2007). Leaves recognition using back propagation neural network-advice for pest and disease control on crops. *IndiaKisan*.
- Balledda, K. e. (2014). Agpest: An efficient rule-based expert system to prevent pest diseases of rice and wheat crops. *Intelligent Systems and Control*.
- Bashish, D., Braik, M., & Bani-Ahmad, S. (2011). Detection and classification of leaf diseases using K-means-based segmentation and Neuralnetworks-based classification. *Technology Journal*, 267-275.
- Biodiversity International. (2006). *Hacia la conservación y utilización de ladiversidad genética forestal en América Latina*. Colombia: Boletín de las Américas.
- Bisong, E. (2019). *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. Apress, Berkeley, CA, 95-64.
- Blanckaert, S. (2004). *Floristic composition, plant uses and management practices in homegardens*. Mexico.
- Boyd, D., & Sun, M. (1994). Prototyping an expert system for diagnosis of potato diseases. *Computers and Electronics in Agriculture*, 259-267.
- CATIE. (2011). *Centro Agronómico Tropical de Investigación y Enseñanza. Enfermedades del cacao en Centroamérica*. Obtenido de <http://www.mag.go.cr/bibliotecavirtual/H20-10877.PDF>
- Conway, G. (1987). *The properties of agroecosystems*:. Agric. Syst. 24.
- Dipakkumar, J. (2018). Plant Disease Identification using Artificial Intelligence: Machine Learning Approach. *International Journal of Innovative Research in Science, Engineering and Technology*, 11082-11084.

- Freesia, T. (2020). *Estadísticas del uso de sistemas operativos*. Obtenido de VENTRICS: <https://www.ventrics.com/estadisticas-uso-android-paises/>
- Guerra, F. &. (2005). (Theobroma cacao, Sterculiaceae. *THEOBROMA CACAO L. Un nuevo enfoque*.
- Hanson, A., Joy, A., & Francis, J. (2017). Plant Leaf Disease Detection using Deep Learning and Convolutional Neural Network. *International Journal of Engineering Science*, 5324-5328.
- Harjeet, K., Deepak, P., & Madhuri. (2019). Applications of Machine Learning In Plant Disease Detection. *Think India Journal*, 3100-3105.
- Heras, D. (2017). Clasificador de imágenes de frutas basado en inteligencia artificial Fruit image classifier based on artificial intelligence. *Killkana Técnica*.
- Huang, K. (2007). Application of artificial neural network for detecting Phalaenopsis seedling diseases using color and texture features. *Computers and Electronics in agriculture*, 3-11.
- Ismail, M., & Mustikasari. (2013). Intelligent system for tea leaf disease detection. *L IPSJ Technical*, 1-4.
- ITELLIGENT. (3 de Enero de 2018). *Deep learning & Convolutional Neuronal Network: qué es y en qué consiste*. Obtenido de ITELLIGENT: <https://itelligent.es/es/deep-learning-convolutional-neuronal-network-cnn-consiste/>
- Jiménez, A., Quiroz, M., Acevedo, O., & Salamanca, J. (2015). Crops diagnosis using digital image processing and precision agriculture technologies. *Scientific Journal INGE CUC*, 63-71.
- Juan, R. (2012). *Manejo fitosanitario del (Theobroma cacao L.)*. Colombia. Obtenido de <https://www.ica.gov.co>
- Keras Team. (18 de Noniembre de 2020). *Keras: the Python deep learning API*. Obtenido de <https://keras.io/?fbclid=IwAR1MRgTu1cqj7T3Ao5uN9yKRxKtgvPQzZi9TKe2rgWFhrTRUPRaNh3UpcFc>
- Khan, S. e. (2008). Dr. Wheat: a Web-based expert system for diagnosis of diseases and pests in Pakistani wheat. *World Congress on Engineering*.
- Martinez, J. (2018). *Estudio comparativo de modelos de machine learning para la detección de dianas microARN*. Obtenido de PDF: <http://openaccess.uoc.edu/webapps/o2/bitstream/10609/73565/6/jmartinezrodriguez9TFM0118memoria.pdf>
- Martínez, J., & De Guevara, L. (2017). *Fundamentos de programación en Java*. EM. Obtenido de <https://www.tesuva.edu.co/phocadownloadpap/Fundamentos%20de%20programacion%20en%20Java.pdf>

- Mena, M. (2020). *Android e iOS dominan el mercado de los smartphones*. Obtenido de ESTADISTA: <https://es.statista.com/grafico/18920/cuota-de-mercado-mundial-de-smartphones-por-sistema-operativo/>
- Motamayor, J. (2002). "*Cacao Domestication I: the origin of the cacao cultivated by*".
- Nagar, S. (2018). *Python*. Springer, Cham.
- Narendrakumar, A. (2018). Feature Extraction Methods for Time Series Functions using Machine Learning. *International Journal of Innovative Research in Science, Engineering and Technology*, 8661-8665.
- Porras, V. (2015). *Enfermedades del cacao*. IICA Biblioteca Venezuela.
- pothuganti, K. (2013). An Efficient Architecture for Lifting Based 3D-Discrete Wavelet Transform. *International Journal of Engineering Research & Technology (IJERT)*, 2278-018.
- Premier Salud. (2016). *mitos-verdades-acerca-del-chocolate.html*. Obtenido de <https://www.premiersalud24.com>
- Productor, E. (2017). *elproductor.com*. Obtenido de <https://elproductor.com/2017/04/control-de-plagas-y-enfermedades-del-cacao/>
- Project Jupyter. (18 de 2020). *JupyterLab*. Obtenido de Jupyter.org website: <https://jupyter.org/?fbclid=IwAR02i-sRZKgEII75U1eBOyqxScox1qjuY8d0HiTJIVKmMHji24fh7TnJdhQ>
- Ramiro, A. (18 de Noviembre de 2018). *Introduccion al Machine Learning*. Obtenido de ResearchGate: https://www.researchgate.net/publication/338518560_INTRODUCCION_AL_MACHINE_LEARNING
- RICA, A. C. (Julio de 2018). *canacacao.org*. Obtenido de <http://canacacao.org/documentos/cosecha-extraccion-y-transporte/>
- Rich, E., Knight, K., Calero, P., G, A., & Bodega, F. (1994). *Inteligencia Artificial*. McGraw-Hill.
- Rupavatharam, S., Kennepohl, A., Kummer, B., & Parimi, V. (2018). Diagnóstico automatizado de enfermedades de las plantas utilizando una innovadora aplicación para Android (Plantix) para agricultores en el estado indio de Andhra Pradesh. *Vicrisat*.
- Saillog LTD. (2019). *Aplicación Agrio*. Obtenido de *agrio.app*: <https://agrio.app/>
- Sarma, S., Singh, K., & Singh, A. (2010). An Expert System for diagnosis of diseases in Rice Plant. *International Journal of Artificial Intelligence*, 26-31.
- SICACAO. (2015). *antecedentes-e-importancia-del-cacao*. Obtenido de <http://sicacao.info>
- TensorFlow. (Noviembre de 18 de 2020). *TensorFlow*. Obtenido de <https://www.tensorflow.org/?hl=es-419&fbclid=IwAR136NvB1DtDf2KHPr7tWmz53gfZMbZhyyZZz5WdLkFqoMKD6IrnRxO2Xk>

- Toala, A., Borjas, R., Alvarado, L., Castro, V., & Otiniano, J. (2019). Control cultural, biológico y químico de *Moniliophthora roreri* y *Phytophthora* spp en *Theobroma cacao* CCN-51. *Scientia Agropecuaria*.
- Trival, T., Patel, J., & Bhatt, C. (2013). Weather based plant diseases forecasting using fuzzy logic. *NUiCONE*.
- Universidad Técnica de Machala. (2015). *Enfermedades del cacao*. Machala: UTMACH.
- Zhang, L., Dabipi, I., & Brown, W. (2018). Internet of Things Applications for Agriculture. Internet Of Things. *onlinelibrary*, 14-20.

14. ANEXOS

Anexo 1. Curriculum Vitae Docente tutor MSc. Bajaña Johnny Xavier



CURRICULUM VITAE

1.DATOS PERSONALES

NOMBRE COMPLETO: Johnny Xavier Bajaña
Zajia ÚMERO DE CELULAR: 593-996179534
E-MAIL: Johnny.bajana@utc.edu.ec
jbajana@correo.ugr.es

2. ESTUDIOS REALIZADOS

CUARTO NIVEL: Universidad Técnica Estatal de Quevedo
TERCER NIVEL: Universidad Técnica Estatal de Quevedo

3.TÍTULOS

POSTGRADO: Magister en Conectividad y Redes de Ordenadores
PREGRADO: Ingeniero en Sistemas

4.CURSOS Y SEMINARIOS DE CAPACITACIÓN

2020

- **Introducción a la Seguridad Cibernética**, Cisco Networking Academy, Universidad Técnica de Cotopaxi Extensión La Maná.
- **“I Seminario Internacional de calidad en la Educación Superior”**, Universidad Técnica de Cotopaxi, 20 horas.
- **I Congreso Internacional de Investigación, Innovación y Gestión del Conocimiento – CINGEC 2020**, Universidad Técnica de Babahoyo, 40 horas.
- **“III Congreso Internacional de Computación e Innovación Tecnológica – CINCIT 2020”**, Universidad José María Arguedas - PERÚ, 60 horas.

- **II Congreso Macroregional en Ingeniería de Sistemas y Ciencias de la Computación e Informática**, UNAS, Facultad de Ingeniería en Informática y Sistemas – PERÚ.
- **JORNADAS DE INVESTIGADORES EN FORMACIÓN - FOMENTANDO LA INTERDISCIPLINARIEDAD - JIFFI –SPECIAL ISSUE** - Escuela Internacional de Posgrado de la Universidad de Granada.
- 2do Congreso Internacional de Desarrollo Universitario – CIDU 2020, Universidad Técnica Estatal de Quevedo, 40 horas.

5. PONENCIAS

2020

- **Ponente de II Congreso Internacional de Sociedad y Tecnología de la Información en la Educación Superior**, COMPAS, UNIVERSIDAD DE ORIENTE
- **Ponente de I Congreso Internacional de Investigación, Innovación y Gestión del Conocimiento – CININGEC 2020**, UNIVERSIDAD TÉCNICA DE BABAHOYO, 40 horas.

6. ARTÍCULOS CIENTÍFICOS PUBLICADOS

- **MATERIALES AUTÉNTICOS EN EL APRENDIZAJE DE LENGUAS EXTRANJERAS. UNA NECESIDAD EN LA UNIVERSIDAD ECUATORIANA ACTUAL:** Revista Didasc@lia: didáctica y Educación, ISSN 2224-2643. Centro de Estudios de Didáctica de la **Universidad de las Tunas** y el Centro de Estudios de Educación de la **Universidad de Ciencias Pedagógicas de Granma**, Cuba.
- **ECOSISTEMA DEL EMPRENDIMIENTO EN LA UNIVERSIDAD CONTEMPORÁNEA:** Revista Didasc@lia: didáctica y Educación, ISSN 2224-2643. Centro de Estudios de Didáctica de la **Universidad de las Tunas** y el Centro de Estudios de Educación de la **Universidad de Ciencias Pedagógicas de Granma**, Cuba.
- **MATERIALES AUTÉNTICOS ORALES Y ESCRITOS EN EL PROCESO DE APRENDIZAJE DE INGLÉS DE LA CARRERA DE INGENIERÍA FORESTAL EN LA UNIVERSIDAD TÉCNICA ESTATAL DE QUEVEDO:**

Revista Didasc@lia: didáctica y Educación, ISSN 2224-2643. Centro de Estudios de Didáctica de la **Universidad de las Tunas** y el Centro de Estudios de Educación de la **Universidad de Ciencias Pedagógicas de Granma**, Cuba.

- **APLICACIÓN MÓVIL PARA APRENDIZAJE EN NIÑOS CON SÍNDROME DE DOWN**, Book of Proceedings, IV International Congress of Sciences, Technology, Innovation and Entrepreneurship, ISBN: 978-9978-364-38-3, **Universidad Estatal de Bolívar**, Ecuador.
- **ENTORNOS VIRTUALES DE APRENDIZAJE (EVA) EN EL DESARROLLO DEL VOCABULARIO CONTEXTUAL DEL INGLÉS EN EL ESTUDIANTADO DEL PRIMER NIVEL DE INGLÉS**, 5to. CONGRESO CIENTÍFICO INTERNACIONAL TECNOLOGÍA, UNIVERSIDAD Y SOCIEDAD, ISBN: 978-9942-960-32-0, Ecuador
- **THE USE OF GAMIFICATION TO ENHANCE THE ENGLISH AS A FOREIGN LANGUAGE**, Revista Polo del Conocimiento, ISBN 2550-682X, Ecuador
- **LA CALIDAD DEL PROCESO DE ENSEÑANZA EN LA CARRERA DE COMUNICACIÓN SOCIAL DE LA UNIVERSIDAD TÉCNICA DE BABAHOYO, EXTENSIÓN QUEVEDO**, Revista Dilemas Contemporáneos, ISBN 2007-7890, México
- **LA GEOMÁTICA COMO HERRAMIENTA PARA EL AUTOAPRENDIZAJE EN ESTUDIANTES DE BACHILLERATO**, Revista INFORMÁTICA Y SISTEMAS: REVISTA DE TECNOLOGÍAS DE LA INFORMÁTICA Y LAS COMUNICACIONES, ISBN 2550- 6730, Ecuador

7.LIBROS PUBLICADOS

- **Solución Geomática para escenarios locales basados en el estándar del consorcio de OPENGIS**, ISBN 978-9942-33-203-5, Coautor, 2020



CURRICULUM VITAE

INFORMACIÓN PERSONAL

Nombres y Apellidos: Maria Jose Bustamante Ochoa

Cédula de Identidad: 0550715361

Lugar y fecha de nacimiento: Cuenca, 18 de abril de 1996

Estado Civil: Soltera

Tipo de Sangre: O+

Domicilio: La Maná – Ciudadela las Orquídeas

Teléfonos: (03) 2696841

Celular: 0961544960

Correo electrónico: bustamantemariajose390@gmail.com

ESTUDIOS REALIZADOS

Primer Nivel: Néstor Mogollón López

Segundo Nivel: Unidad Educativa La Maná

Tercer Nivel: Universidad Técnica de Cotopaxi Extensión La Maná (Estudiante)

TITULOS

- Bachiller en Ciencias, 09 de marzo del 2016

IDIOMAS

- Español (nativo)
- Suficiencia en el idioma inglés

CURSOS DE CAPACITACIÓN

- Primera Jornada Científica Internacional de Informática – UTC La Maná 2016
Dictado: Universidad Técnica de Cotopaxi
Lugar y fecha: La Maná 06, 07 y 08 de Julio del 2016

Tiempo: 40 horas

- II Jornadas Informáticas- UTC La Maná
Dictado: Universidad Técnica de Cotopaxi
Lugar y fecha: La Maná 12 hasta el 14 de Julio del 2017
Tiempo: 40 horas
- III Congreso Internacional de Investigación Científica – UTC La Maná 2018
Dictado: Universidad Técnica de Cotopaxi
Lugar y fecha: La Maná 29 hasta el 31 de Enero del 2018
Tiempo: 40 horas
- III Jornadas Informáticas- UTC La Maná
Dictado: Universidad Técnica de Cotopaxi
Lugar y fecha: La Maná 10 hasta el 12 de Julio del 2018
Tiempo: 40 horas
- IV Congreso Internacional de Investigación Científica UTC- La Maná 2019
Dictado: Universidad Técnica de Cotopaxi
Lugar y fecha: La Maná 08 hasta el 10 de Mayo del 2019
Tiempo: 40 horas

CURRICULUM VITAE



INFORMACION PERSONAL

Nombres y Apellidos: María José García Peña
Cédula de Identidad: 2350835928
Nacionalidad: ecuatoriana
Lugar y fecha de nacimiento: Babahoyo 03/03/1995
Estado Civil: Soltera
Tipo de Sangre: 0+
Domicilio: La Concordia -Santo Domingo
Teléfonos: 0988094650
Correo electrónico: marybaby@hotmail.es

ESTUDIOS REALIZADOS

Primer Nivel: Escuela Fiscal Mixta “Manuela Saenz”
Segundo Nivel: Colegio Nacional Mixto “El CosmoPolita”
Tercer Nivel: Universidad Técnica de Cotopaxi “Extensión la Maná”

TITULOS

Bachiller Técnico en Comercio y Administración-Especialización Aplicaciones Informáticas.

IDIOMAS

Español (nativo)
Suficiencia en el Idioma Inglés

CURSOS REALIZADOS

CICAP: Operador Digitador de Computadoras
MICROSOFT OFFICE SPECIALIST:
Office Word 2013
Office Word Point 2013
Office Excel 2013

EXPERIENCIA LABORAL

GAD Municipio de Quinindé.

Cargo: auxiliar de Talento Humano (Practicas)

Tiempo: 3 meses

Corporación Nacional de Telecomunicaciones CNT EP “CNT” La Maná, Cotopaxi

Cargo: auxiliar departamento de Área Técnica (PRÁCTICA PRE -PROFESIONAL)

Tiempo: 1 Año 6 meses

Agro Comercio Joselito

Compra y venta de productos agrícolas Maracuyá, Cacao, Café, Tagua

Cargo: auxiliar de Contabilidad

Tiempo: 1 AÑO (Negocio Familiar).

CURSOS DE CAPACITACIÓN

Ponente 1ra Jornada Científica Estudiantil

Dictado: Universidad Técnica de Cotopaxi

Lugar y fecha: La Maná 5 de Agosto del 2015

Tiempo: 40 horas

Primera Jornada Científica Internacional de Informática

Dictado: Universidad Técnica de Cotopaxi

Lugar y fecha: La Maná 6 y 8 de del 2016

Tiempo: 40 horas

II Congreso Internacional de Investigación Científica

Dictado: Universidad Técnica de Cotopaxi

Lugar y fecha: La Maná 6 y 8 de del 2016

Tiempo: 40 horas

REFERENCIAS PERSONALES

ABG. Malena Moreno 0993249158

ING. Sandra Jacho 0981034675

ING. Jesús Raúl García 0997638383

REFERENCIAS LABORALES

LCDA. ELOISA ROJAS

TELF. 02 3790346

Anexo 4. Formato de la entrevista Aplicada



UNIVERSIDAD TÉCNICA DE COTOPAXI
EXTENSIÓN - LA MANÁ

Entrevistadores: Bustamante Ochoa María José y García Peña María José

Entrevistada: Ing. Bustamante Mayra Alejandra

Cargo: Técnica Agraria especialista

Lugar: La Maná

1.- ¿Qué enfermedades del cacao son más comunes en el Ecuador?

.....
.....
.....

2.- ¿Cuánto afecta a la producción del cacao estas enfermedades?

.....
.....
.....

3.- ¿Qué enfermedades del cacao son comunes en la zona de La Maná?

.....
.....
.....

4.- ¿Qué proceso se debe de hacer para la recolección de muestras de las enfermedades?

.....
.....
.....

5.- ¿Qué muestreo se emplea para la recolección de los datos?

.....
.....
.....

Anexo 5. Formato de la encuesta realizada a los agricultores cacaotero de La Maná



UNIVERSIDAD TÉCNICA DE COTOPAXI
EXTENSIÓN - LA MANÁ

ENCUESTA DIRIGIDA A LOS AGRICULTORES CACAOTEROS
AGROECOLÓGICOS DEL CANTÓN LA MANÁ

Instrucciones:

En los siguientes enunciados responda según su criterio y marque con una (X).

1.- ¿Cuáles son las enfermedades más comunes de cacao que afectan a su cultivo?

Monilia	<input type="checkbox"/>	Phytophthora	<input type="checkbox"/>
Escoba bruja	<input type="checkbox"/>	Mancha de agua	<input type="checkbox"/>
Mal del machete	<input type="checkbox"/>		

2.- ¿Usted sabe reconocer estas enfermedades en su cultivo?

Sí No

3.- ¿Cuál ha sido su experiencia con las aplicaciones móviles?

Buena Regular Mala

4.- ¿Conoce usted una aplicación móvil que identifique las enfermedades del cultivo de cacao?

Sí No

5.- ¿Considera usted que una aplicación móvil orientada al campo agrícola aportara al sector productivo cacaotero?

Sí No

6.- ¿Cree usted que las aplicaciones móviles dirigidas al campo agrícola permitirán reducir el tiempo utilizado por el agricultor para poder identificar una plaga o enfermedad en el cultivo del cacao?

Sí

No

7.- ¿Cree usted que las aplicaciones móviles incrementaran los niveles de información que se obtienen acerca de la plaga o enfermedad identificada; en sectores de producción agrícola?

Sí

No

TABULACIÓN DE DATOS DE LA ENTREVISTA


1.- ¿Cuáles son las enfermedades más comunes de cacao que afectan a su cultivo?

Tabla 12. ¿Cuáles son las enfermedades más comunes de cacao que afectan a su cultivo?

Detalle	Frecuencia
Monilia	88
Phytophthora	88
Escoba bruja	55
Mancha de agua	20
Mal del machete	32

Elaborado por: Las Investigadoras

Gráfico 10. ¿Cuáles son las enfermedades más comunes de cacao que afectan a su cultivo?



Fuente: Encuesta

Análisis e interpretación: De acuerdo con la población encuestada dan como resultado dos enfermedades que el 100% de la población indican que se dan en sus cultivos, quedando la Monilia y Phytophthora en primer y segundo lugar, en el tercer puesto se encuentra la enfermedad de la Escoba bruja, en cuarto lugar, Mancha de agua y en el quinto lugar está el Mal del machete. Tras analizar el resultado obtenido del 100% de la población encuestada dan como resultado que las enfermedades que más afectan al cultivo del cacao son la Monilia y

Phytophthora siendo estas enfermedades las que más afectan en la producción del cacao para los agricultores. Esto determina la importancia del estudio de estas dos enfermedades en primera instancia para el desarrollo de la aplicación móvil con IA.


2.- ¿Usted sabe reconocer estas enfermedades en su cultivo?

Tabla 13. ¿Usted sabe reconocer estas enfermedades en su cultivo?

Detalle	Frecuencia	Porcentaje
Si	23	26%
No	65	74%
TOTAL	88	100%

Elaborado por: Las Investigadoras

Gráfico 11. ¿Usted sabe reconocer estas enfermedades en su cultivo?



Fuente: Encuesta

Análisis e interpretación: Del 100% de la población encuestada el 74% no saben reconocer las enfermedades que se presentan en sus cultivos mientras que el 26% si las reconocen. Tras conocer los resultados obtenidos refleja que la mayoría de la población desconocen contra que enfermedades están tratando, lo que determina la importancia de una aplicación móvil en donde pueda reconocer la enfermedad que padece el cacao, específicamente de la enfermedad reflejada en la mazorca o fruto.

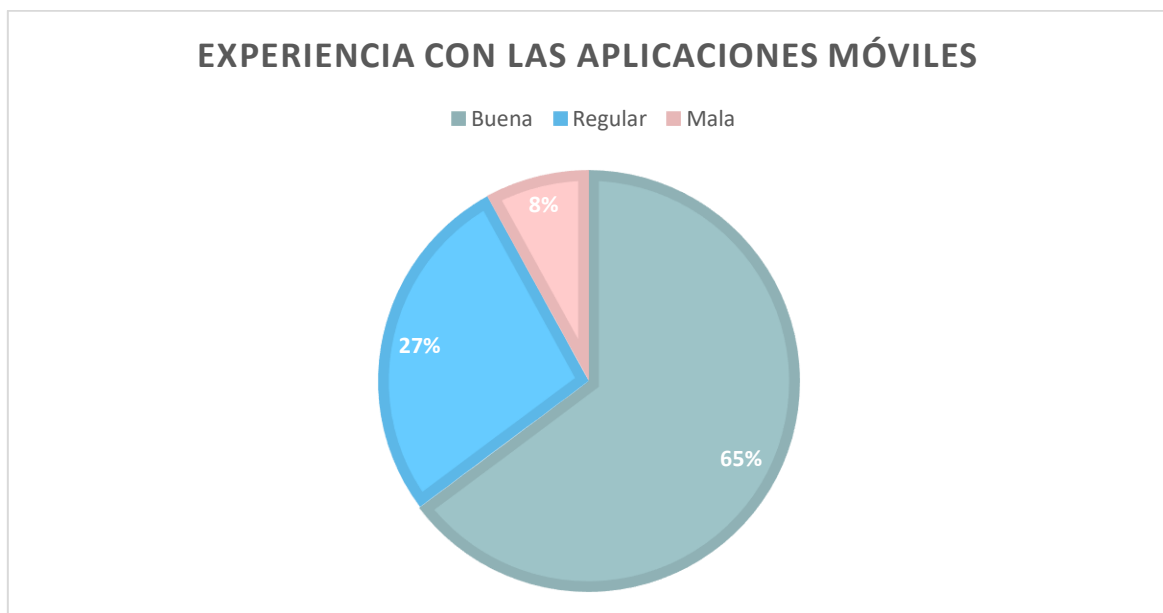
3.- ¿Cuál ha sido su experiencia con las aplicaciones móviles?

Tabla 14. ¿Cuál ha sido su experiencia con las aplicaciones móviles?

Detalle	Frecuencia	Porcentaje
Buena	57	65%
Regular	24	27%
Mala	7	8%
TOTAL	88	100%

Elaborado por: Las Investigadoras

Gráfico 12. ¿Cuál ha sido su experiencia con las aplicaciones móviles?



Fuente: Encuesta

Análisis e interpretación: De acuerdo con los resultados obtenidos de las encuestas realizadas el 65% de la población ha tenido buenas experiencias en el uso de las aplicaciones móviles, mientras que el 27% indican sus experiencias como regular, y el 8% de los encuestados indican sus experiencias como mala. Tras conocer el análisis se determina que la mayoría de la población encuestada han tenido buenas y regulares experiencias con el uso de aplicaciones móviles, dando como resultado favorable la implementación de una aplicación móvil con un modelo de inteligencia artificial que ayude al reconocimiento de enfermedades que se presentan en el cacao.


4.- ¿Conoce usted una aplicación móvil que identifique las enfermedades del cultivo de cacao?

Tabla 15. ¿Conoce usted una aplicación móvil que identifique las enfermedades del cultivo de cacao?

Detalle	Frecuencia	Porcentaje
Si	0	0%
No	88	100%
TOTAL	88	100%

Elaborado por: Las Investigadoras

Gráfico 13. ¿Conoce usted una aplicación móvil que identifique las enfermedades del cultivo de cacao?



Fuente: Encuesta

Análisis e interpretación: El 100% de la población que corresponde a 88 de encuestados que pertenecen al sector agrícola indican que no conocen ninguna aplicación móvil que se dedique al servicio de identificar enfermedades del cacao. Tras conocer los resultados del desconocimiento de aplicaciones móviles por parte de los encuestados da como efecto la importancia de este proyecto debido a su fusión de IA en una aplicación móvil que permite reconocer las enfermedades y la precisión con las que arroja su respuesta.

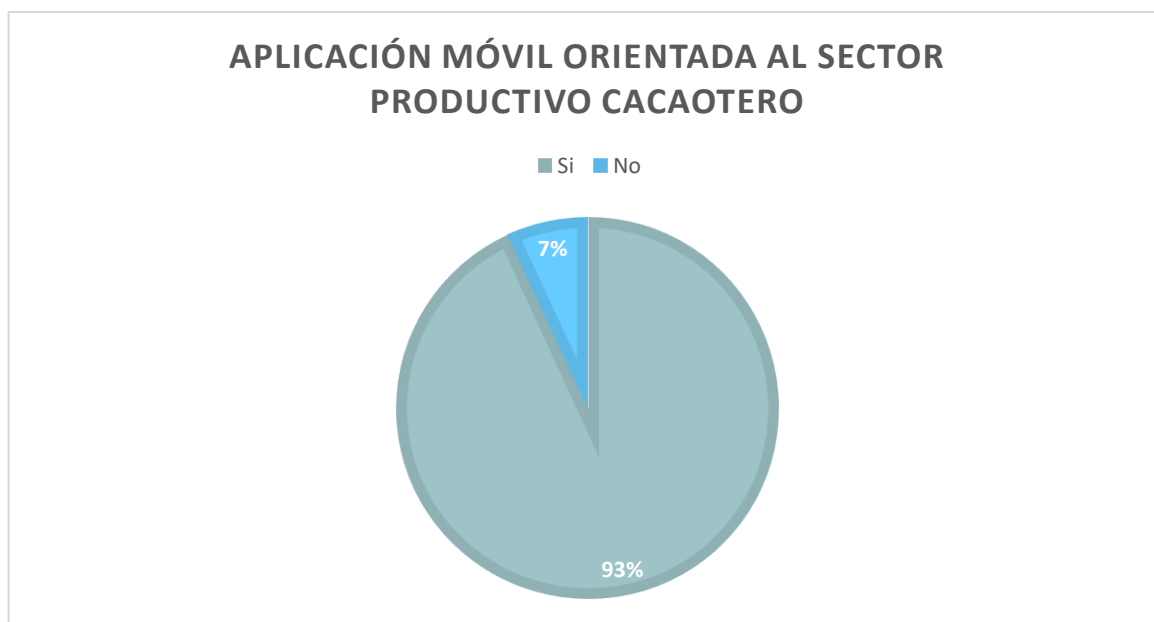
5.- ¿Considera usted que una aplicación móvil orientada al campo agrícola aportara al sector productivo cacaoero?

Tabla 16. ¿Considera usted que una aplicación móvil orientada al campo agrícola aportara al sector productivo cacaoero?

Detalle	Frecuencia	Porcentaje
Si	82	93%
No	6	7%
TOTAL	88	100%

Elaborado por: Las Investigadoras

Gráfico 14. ¿Considera usted que una aplicación móvil orientada al campo agrícola aportara al sector productivo cacaoero?



Fuente: Encuesta

Análisis e interpretación: De acuerdo con los encuestados el 93% de la población total indicaron que una aplicación móvil orientada al campo agrícola si aportada al sector cacaoero en la productividad mientras que el 7% de la población indicaron que no aportaría de nada una aplicación móvil en este campo agrícola. Tras conocer los resultados obtenidos la mayoría de la población encuestada que representa un 93% está de acuerdo que una aplicación móvil aportaría de mucho a este sector, dando como resultado la importancia de acogida de la aplicación por parte de los agricultores.


6.- ¿Cree usted que las aplicaciones móviles dirigidas al campo agrícola permitirán reducir el tiempo utilizado por el agricultor para poder identificar una plaga o enfermedad en el cultivo del cacao?

Tabla 17. ¿Cree usted que las aplicaciones móviles dirigidas al campo agrícola permitirán reducir el tiempo utilizado por el agricultor para poder identificar una plaga o enfermedad en el cultivo del cacao?

Detalle	Frecuencia	Porcentaje
Si	85	97%
No	3	3%
TOTAL	88	100%

Elaborado por: Las Investigadoras

Gráfico 15. ¿Cree usted que las aplicaciones móviles dirigidas al campo agrícola permitirán reducir el tiempo utilizado por el agricultor para poder identificar una plaga o enfermedad en el cultivo del cacao?



Fuente: Encuesta

Análisis e interpretación: El 97% de la población encuestada indicaron que, si están de acuerdo con que una aplicación móvil dirigida al sector agrícola reduciría el tiempo de identificación de enfermedades o plagas por parte de los agricultores, mientras que el 3% restante del 100% de la población indicaron que no. Tras conocer los resultados el 97% de la población que vendrían siendo 85 agricultores indicaron óptimos resultados.


7.- ¿Cree usted que las aplicaciones móviles incrementarían los niveles de información que se obtienen acerca de la plaga o enfermedad identificada; en sectores de producción agrícola?

Tabla 18. ¿Cree usted que las aplicaciones móviles incrementarían los niveles de información que se obtienen acerca de la plaga o enfermedad identificada; en sectores de producción agrícola?

Detalle	Frecuencia	Porcentaje
Si	85	
No	3	
TOTAL	88	100%

Elaborado por: Las Investigadoras

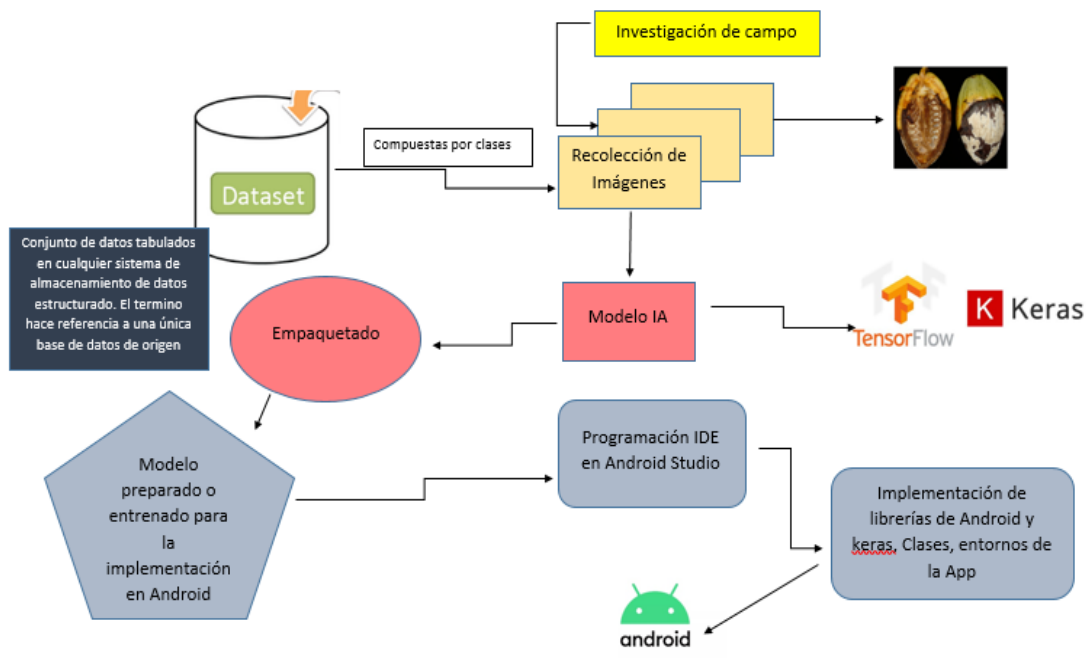
Gráfico 16. ¿Cree usted que las aplicaciones móviles incrementarían los niveles de información que se obtienen acerca de la plaga o enfermedad identificada; en sectores de producción agrícola?



Fuente: Encuesta

Análisis e interpretación: Del 100% de los encuestados el 97% están de acuerdo que por medio de una aplicación móvil si se incrementa los niveles de información que se obtiene de las enfermedades identificadas en los sectores agrícolas y el 3% de la población indican que no. Tras conocer los resultados el 97% de la población encuestada indican que están de acuerdo que por medio de las aplicaciones móviles si se puede obtener más información acerca de las diferentes enfermedades que padecen el cultivo del cacao. Dando como resultado la importancia de la implementación de la aplicación móvil debido a que fortalece el conocimiento de los agricultores a parte de facilitarles la detección de enfermedades.

Anexo 7. Arquitectura de desarrollo del proyecto de Investigación



Descripción: Arquitectura de desarrollo empleadas en el proyecto de Investigación

Anexo 8. Socialización de las actividades a realizar en el campus Sasha Wiwa UTC




Descripción: Socialización al director de la carrera de Agronomía de la UTC Ext-La Maná y a docentes del proyecto con tema "Implementación de modelos Machine Learning aplicados al estudio de enfermedades del *Theobroma cacao* para huertas agroecológicas del Cantón La Maná, Provincia de Cotopaxi", en el campus Sasha Wiwa UTC.

Anexo 9. Técnica de la Observación paso numero 1



Descripción: Recolección de datos y muestras en las fincas del ing. Estrella, ing. Raúl Través, el señor Bryan Cañizares, ing. Lara y el señor Adrián Calero para el estudio técnico y datasets.

Anexo 10. Técnica de la Observación paso numero 2



Descripción: Aislamiento del tejido infectado o enfermo, pasa por el proceso de observación directa de Cámara húmeda, luego se prepara las cajas Petri con lacas para la observación de los tejidos enfermos, *Phytophthora* y *Monilia*.

REPORTE TÉCNICO DE ENFERMEDADES (CCN51)

Cultivo de cacao

El cultivo de cacao es uno de los principales en la industria a nivel mundial; originario de las Américas, está distribuido desde América Central, el Caribe, México y el centro Norte de Sudamérica. Actualmente también se cultiva en África y algunos países asiáticos como Malasia e Indonesia. La alta demanda de la industria chocolatera hace que este cultivo sea un componente importante en las fincas de los pequeños y medianos productores, especialmente en las Américas. El cultivo es reconocido como importante para la actividad económica, social y desarrollo de la mayoría de familias de agricultores, en algunos casos siendo la base para el desarrollo local.

El cacao está afectado por algunas enfermedades, suficientemente impactantes económicamente promoviendo el fomento de nuevas tecnologías, para tratar de mermar la incidencia de estas enfermedades. Cuando el agricultor no lleva un buen manejo agronómico del cultivo las plagas y enfermedades empiezan a manifestarse con síntomas (la manifestación del ataque de la enfermedad en tejidos de la planta), causando pérdida parcial o total de la cosecha. Para poder implementar métodos de control, es importante la identificación de enfermedades en la mazorca.

Generalmente, la respuesta de las plantas es con características especiales para cada agente patógeno, son los síntomas que estas presentan, por lo tanto, en primer lugar, es conveniente realizar recorrido del campo, por un técnico con algún nivel de conocimiento de las enfermedades, que le permite identificar aquellas con las que este más familiarizado. Un técnico no especialista, debe conocer y dominar ciertas metodologías que le permitan provocar la aparición de signos (estos corresponden a manifestaciones del patógeno, que se produce bajo condiciones apropiadas sobre los síntomas).

Dada la importancia antes mencionada, el presente informe técnico, está dando el inicio para el proyecto de investigación **"IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL *Theobroma cacao* PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE**

COTOPAXI'. Se planteó los siguientes objetivos: (a) aplicar metodologías de diagnóstico en mazorcas jóvenes de cacao a través de los síntomas/signos en mazorcas; y (b) identificar la(s) enfermedades en mazorcas que están afectándolas. A continuación, se presenta de manera esquemática el proceso que se realizó para dar cumplimiento a los objetivos planteados.

Metodología

Obtención de muestras en campo

Se realizó recorrido de forma aleatoria en lotes de cacao de las fincas. Debido a que todavía no está bien implementada la época lluviosa, se colectaron mazorcas con los síntomas y signos de enfermedad, así como también un grupo de mazorcas (pepinillos de 4 a 10cm) en diferentes estadios en las que no se tenía clara la enfermedad pues los síntomas no eran muy definidos y no se observaban signos sobre ellas.

Todo el material recolectado se las guardo en fundas de papel para posterior observación en el laboratorio.

Tratamiento en laboratorio de las muestras:

Un primer examen visual, utilizando una lupa, cuidadosamente se la examina para establecer la sintomatología inicial, necesaria para el análisis, lo que permitió separar aquellas mazorcas con signos varios en la superficie (esporulación, micelio, cuerpos fructíferos u otra característica), lo que permitió determinación del agente y finalmente se las uso para aislarlo en medio de cultivo. Se requiere un microscopio para la confirmación de la estructura del hongo y realizar un diagnóstico adecuado de la enfermedad.

Posteriormente se aplicó la técnica de “cámara húmeda” para provocar la formación de signos sobre las manchas que permita la observación directa en microscopio e identificar al patógeno.

- ✓ Las muestras se lavaron con agua de jabón, posteriormente se la enjuago con agua destilada estéril, se las desinfecto con alcohol, se dejaron en reposo hasta que el alcohol se evapore.

- ✓ En una funda estéril se colocó un pedazo de algodón estéril empapado en agua destilada estéril, cada mazorca enferma se colocó dentro de la funda sobre una caja Petri estéril para que no tenga contacto con el agua, finalmente, se selló la funda con grapas.
- ✓ Se dejó incubar a temperatura ambiente por 48 – 72 horas, para su posterior observación.



Desinfección de muestras.



Cámara húmeda.

Observación e identificación de enfermedades:


Tanto las muestras que tenían presencia de signos/síntomas de hongos, (esporas, micelio, exudados), que correspondían a las características morfológicas, que se encontró en la literatura especializada permitió reportar los siguientes resultados que confirman la enfermedad de la mazorca.

Resultados

Mediante la técnica de observación directa en “cámara húmeda” las mazorcas recolectadas en el campo con signos/síntomas de enfermedades, que son característica morfológica correspondieron al 100 % a Monilla, positivo para el agente causal denominado *Moniliophthora roreri*.



Mazorca infectada de Monilla.




Conidios de *Moniliophthora roreri*.

Otras mazorcas, presentaron esporulación y exudados correspondientes en un 100 % de las muestras al agente causal denominado *Phytophthora palmivora*.



Mazorca con signos de la enfermedad.



Conidias de *Phytophthora palmivora*.

Con la identificación de la enfermedad, mediante la técnica directa (cámara húmeda) y la observación de las muestras en microscopio, se verificó que las imágenes tomadas, para el almacenamiento de información, que requiere la aplicación corresponden al 100% de cada enfermedad.

Mayra Bustamante

Ing. Agrom. Bustamante Mayra Alejandra
Técnico Agraria

Anexo 12. Red Neuronal Convolutacional

RED NEURONAL CONVOLUCIONAL (MODELO DEEP LEARNING)

Diagnóstico de enfermedades del cacao via clasificación de imágenes aplicando Transfer Learning.*

Desarrollado por: **Maria Jose Bustamante Y Maria Jose Garcia.**

Proyecto de Bioinformatica UTC.

Descripción: Celda De Presentación

Anexo 13. Inicio.

```
INICIO

Seteando Tensorflow 1.x:

[ ] %tensorflow_version 1.x

Montando Google Drive:

[ ] from google.colab import drive
drive.mount('/content/drive')

Drive already mounted at /content/drive; to attempt to forcibly remount, call drive.mount("/content/drive", force_remount=True).
```

Descripción: Celda De Presentación

Anexo 14. Visualizando Imagen de dataset

Visualizando imágenes del dataset:

```
[ ] import os
import shutil
import glob
import numpy as np
from random import randrange

from keras.preprocessing import image
import matplotlib.pyplot as plt

# Folder del proyecto
project_folder = "/content/drive/MyDrive/Cacao-rx-proyecto"

files_train_monilla = glob.glob(project_folder+"/dataset/train/monilla/*.jpg")
files_test_monilla = glob.glob(project_folder+"/dataset/test/monilla/*.jpg")

files_train_normal = glob.glob(project_folder+"/dataset/train/normal/*.jpg")
files_test_normal = glob.glob(project_folder+"/dataset/test/normal/*.jpg")

# Obteniendo imágenes al azar de cada folder
file_train_monilla = files_train_monilla[randrange(len(files_train_monilla))]
image_train_monilla = image.load_img(file_train_monilla)
```

Descripción: Codificación para la obtención de los datasets alojados en la nube.

Anexo 15. Visualizando imágenes



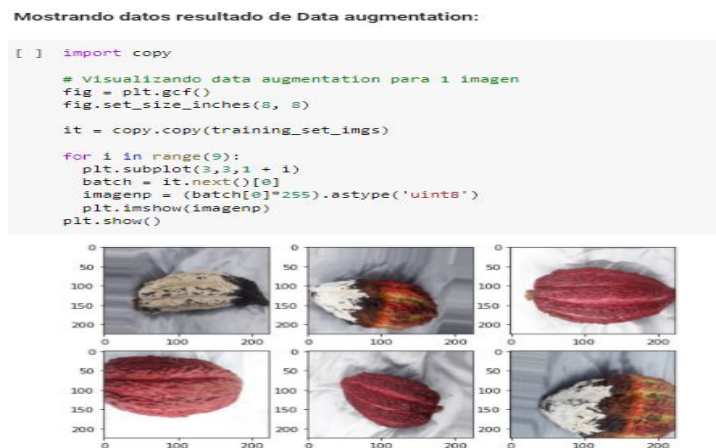
Descripción: *Obtención de imágenes de los datasets.*

Anexo 16. Pre procesamiento de datos



Descripción: *Codificación para el procesamiento de los datos en la IA.*

Anexo 17. Resultados de Data augmentation



Descripción: *Codificación para la obtención resultados de la Data Augmentation.*

Anexo 18. Carga de dataset TEST sin aplicar data argumentation

Cargar dataset TEST sin aplicar Data Augmentation:

```
[ ] # Data Normalization
datagen_test = ImageDataGenerator(rescale=1./255.)

# Leer imagenes del folder dataset/train
testing_set_imgs = datagen_test.flow_from_directory(project_folder+"/dataset/test",
                                                    target_size = (img_width, img_height),
                                                    class_mode = 'binary',
                                                    classes = ['normal','monilla'],
                                                    batch_size = batch_size,
                                                    shuffle=False)

# Mostrando resultados
num_imgs_testing = len(testing_set_imgs.filesnames)

print("\n")
print("Núm. de imgs TEST:", num_imgs_testing)
print("Classes:", testing_set_imgs.class_indices)
print("Núm. classes [0]:", np.sum(testing_set_imgs.labels == 0, axis=0))
print("Núm. classes [1]:", np.sum(testing_set_imgs.labels == 1, axis=0))

Found 1234 images belonging to 2 classes.

Núm. de imgs TEST: 1234
Classes: {'normal': 0, 'monilla': 1}
Núm. Classes [0]: 364
Núm. Classes [1]: 870
```

Descripción: Carga de los Datasets sin aplicar Data Augmentation.

Anexo 19. Construcción de la Red Neuronal Artificial

SECCIÓN II - CONSTRUYENDO LA RED NEURONAL ARTIFICIAL (CNN) - ARQUITECTURA

Cargar Modelo pre-entrenado DenseNet:

```
[ ] # DenseNet https://keras.io/api/applications/densenet/
# https://towardsdatascience.com/paper-review-densenet-densely-connected-convolutional-networks-acf9665dfefb
from keras.applications import DenseNet201
# Resnet https://keras.io/api/applications/resnet/
# from keras.applications import Resnet152V2

# Cargando modelo DenseNet
# Definir nombre de la instancia
pretrained_model = DenseNet201(weights='imagenet', include_top=False, input_shape=(img_width, img_height, 3))

pretrained_model.summary()
```

WARNING:tensorflow:From /tensorflow-1.15.2/python3.6/tensorflow_core/python/ops/resource_variable_ops.py:1698: calling BaseResourceVariable.__init__ (from tensorflow.python.ops.resource_variable_ops) with constraint arguments is deprecated. Instructions for updating:
If using keras pass its "constraint" arguments to layers.
WARNING:tensorflow:From /tensorflow-1.15.2/python3.6/keras/backend/tensorflow_backend.py:4878: The name tf.nn.max_pool is deprecated. Please use tf.nn.max_pool_v2 instead.
WARNING:tensorflow:From /tensorflow-1.15.2/python3.6/keras/backend/tensorflow_backend.py:4874: The name tf.nn.avg_pool is deprecated. Please use tf.nn.avg_pool_v2 instead.

Downloading data from https://github.com/keras-team/keras/blob/master/keras/applications/releases/download/densenet/densenet201_weights_tf_dim_ordering_tf_kernels_notop.h5
745421177402308 [*****] - 65 905/516p
Model: "densenet201"

Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	(None, 224, 224, 3)	0	
zero_padding2d_1 (ZeroPadding2D)	(None, 230, 230, 3)	0	input_1[0][0]
conv1/conv (Conv2D)	(None, 112, 112, 64)	9408	zero_padding2d_1[0][0]
conv1/bn (BatchNormalization)	(None, 112, 112, 64)	256	conv1/conv[0][0]
conv1/relu (Activation)	(None, 112, 112, 64)	0	conv1/bn[0][0]
zero_padding2d_2 (ZeroPadding2D)	(None, 114, 114, 64)	0	conv1/relu[0][0]
pool1 (MaxPooling2D)	(None, 56, 56, 64)	0	zero_padding2d_2[0][0]
conv2_block1_0_bn (BatchNormal1)	(None, 56, 56, 64)	256	pool1[0][0]
conv2_block1_0_relu (Activation)	(None, 56, 56, 64)	0	conv2_block1_0_bn[0][0]
conv2_block1_1_conv (Conv2D)	(None, 56, 56, 128)	8192	conv2_block1_0_relu[0][0]
conv2_block1_1_bn (BatchNormal1)	(None, 56, 56, 128)	512	conv2_block1_1_conv[0][0]
conv2_block1_1_relu (Activation)	(None, 56, 56, 128)	0	conv2_block1_1_bn[0][0]
conv2_block1_2_conv (Conv2D)	(None, 56, 56, 32)	36864	conv2_block1_1_relu[0][0]

Descripción: Construcción de la red neuronal artificial.

Anexo 20. Congelar los params en el Feature Extractor

Congelar (freeze) los params en el Feature Extractor:

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

pretrained_model.summary()
```

Model: "densenet201"

Layer (type)	Output Shape	Param #	Connected to
input_1 (InputLayer)	(None, 224, 224, 3)	0	
zero_padding2d_1 (ZeroPadding2D)	(None, 230, 230, 3)	0	input_1[0][0]
conv1/conv (Conv2D)	(None, 112, 112, 64)	9408	zero_padding2d_1[0][0]
conv1/bn (BatchNormalization)	(None, 112, 112, 64)	256	conv1/conv[0][0]
conv1/relu (Activation)	(None, 112, 112, 64)	0	conv1/bn[0][0]
zero_padding2d_2 (ZeroPadding2D)	(None, 114, 114, 64)	0	conv1/relu[0][0]
pool1 (MaxPooling2D)	(None, 56, 56, 64)	0	zero_padding2d_2[0][0]
conv2_block1_0_bn (BatchNormal1)	(None, 56, 56, 64)	256	pool1[0][0]
conv2_block1_0_relu (Activation)	(None, 56, 56, 64)	0	conv2_block1_0_bn[0][0]
conv2_block1_1_conv (Conv2D)	(None, 56, 56, 128)	8192	conv2_block1_0_relu[0][0]
conv2_block1_1_bn (BatchNormal1)	(None, 56, 56, 128)	512	conv2_block1_1_conv[0][0]
conv2_block1_1_relu (Activation)	(None, 56, 56, 128)	0	conv2_block1_1_bn[0][0]
conv2_block1_2_conv (Conv2D)	(None, 56, 56, 32)	36864	conv2_block1_1_relu[0][0]

Descripción: Extracción del modelo DenseNet Pre-Entrenados.

Anexo 21. Agregado el clasificador propio

Agregando el clasificador propio:

```
[ ] # Modelo de clasificacion propio
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import GlobalAveragePooling2D
from keras.layers import Flatten
from keras.layers import Dropout

# Definiendo una Red Neuronal vacia
model = Sequential()

# Agregando la parte convolucional (base)
model.add(pretrained_model) # Modelo base

# Clasificador propio
model.add(GlobalAveragePooling2D()) # GlobalAveragePooling2D https://adventuresinmachinelearning.com/global-average-pooling-convolutional-neural-networks/
model.add(Dense(1000, activation='relu'))
model.add(Dropout(rate=0.2))
model.add(Dense(1, activation='sigmoid'))

print("Arquitectura final:")
model.summary()

Arquitectura final:
Model: "sequential_1"
-----
Layer (type)                Output Shape              Param #
-----
densenet201 (Model)         (None, 7, 7, 1920)       18321984
-----
global_average_pooling2d_1 ( (None, 1920)              0
-----
```

Descripción: Preparación del clasificador de imágenes.

Anexo 22. Entrenando la Red Neuronal Artificial

▼ SECCIÓN III - ENTRENANDO LA RED NEURONAL ARTIFICIAL (CNN)

Compilar la Red Neuronal Convolucional:

```
from keras.optimizers import SGD
from keras.optimizers import Adam

opt = SGD(lr=0.008, momentum=0.9)
# opt = Adam(lr=0.008, beta_1=0.9, beta_2=0.999)

# COMPILANDO la Red Neuronal Convolucional
model.compile(optimizer=opt, loss='binary_crossentropy', metrics=['accuracy'])
```

Descripción: *Importación de librerías para el entrenamiento de la red neuronal.*

Anexo 23. Entrenando la Red Neuronal Convolucional

Entrenar la Red Neuronal convolucional:

```
[ ] %time

epochs=20

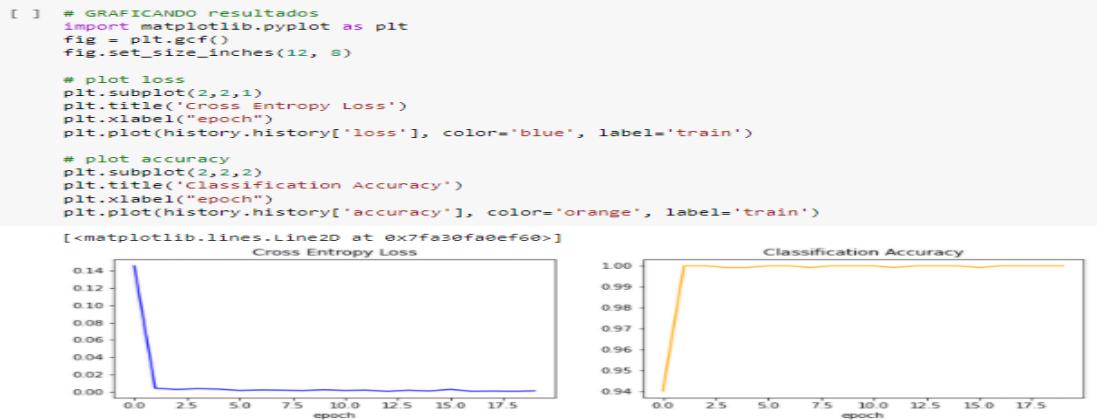
# Entrenar
history = model.fit_generator(training_set_imgs,
                             epochs=epochs,
                             steps_per_epoch=np.ceil(num_imgs_training/batch_size),
                             validation_data=testing_set_imgs,
                             validation_steps=np.ceil(num_imgs_testing/batch_size))

WARNING:tensorflow:From /tensorflow-1.15.2/python3.6/keras/backend/tensorflow_backend.py:422: The name tf.global_variables is deprecated. Please use tf.compat_v
Epoch 1/20
/tensorflow-1.15.2/python3.6/keras/utils/data_utils.py:616: UserWarning: The input 19 could not be retrieved. It could be because a worker has died.
UserWarning)
1/31 [.....] - ETA: 28:33 - loss: 0.7436 - accuracy: 0.4500/tensorflow-1.15.2/python3.6/keras/utils/data_utils.py:616: UserWarning:
UserWarning)
2/31 [>.....] - ETA: 22:44 - loss: 0.6238 - accuracy: 0.6250/tensorflow-1.15.2/python3.6/keras/utils/data_utils.py:616: UserWarning:
UserWarning)
3/31 [=>.....] - ETA: 20:29 - loss: 0.6261 - accuracy: 0.6500/tensorflow-1.15.2/python3.6/keras/utils/data_utils.py:616: UserWarning:
UserWarning)
4/31 [==>.....] - ETA: 19:29 - loss: 0.6332 - accuracy: 0.6562/tensorflow-1.15.2/python3.6/keras/utils/data_utils.py:616: UserWarning:
UserWarning)
5/31 [===>.....] - ETA: 18:45 - loss: 0.6078 - accuracy: 0.6650/tensorflow-1.15.2/python3.6/keras/utils/data_utils.py:616: UserWarning:
UserWarning)
```

Descripción: *Steps de entrenamiento de la red neuronal.*

Anexo 24. Grafica del resultado de entrenamiento

Graficar resultados del entrenamiento:



Descripción: Gráficos de los resultados de entrenamiento de la red neuronal.

Anexo 25. Evaluación de la Red Neuronal Artificial

SECCIÓN IV - EVALUACIÓN DE LA RED NEURONAL ARTIFICIAL (CNN)

Evaluación via 'evaluate_generator':

```
[ ] # Accuracy del Test (Usar este valor como referencial solamente https://github.com/keras-team/keras/issues/6499)
eval = model.evaluate_generator(testing_set_imgs, steps=np.ceil(num_imgs_testing/batch_size))

print('\nvalidación en test:')
print("Loss: {:.4}".format(eval[0]))
print("Accuracy: {:.2%}".format(eval[1]))
```

Evaluación via 'predict_generator' y Matriz de Confusión:

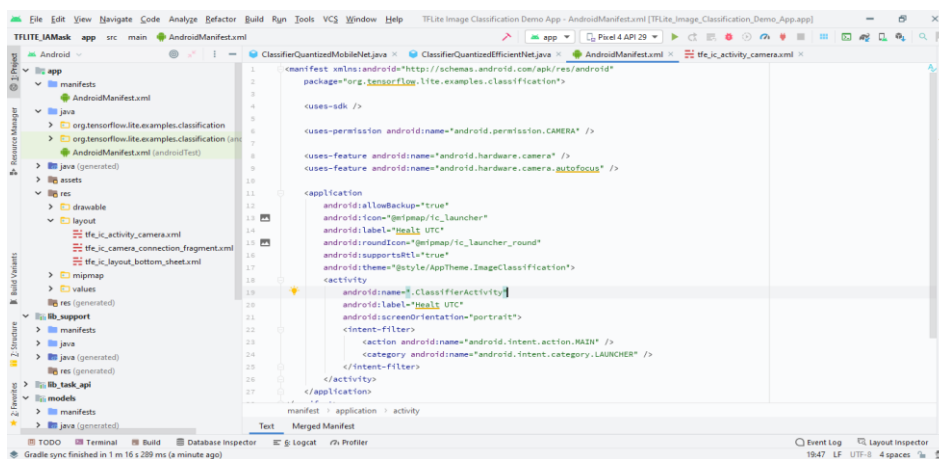
```
[ ] # Matriz de Confusión
from sklearn.metrics import classification_report
from sklearn.metrics import confusion_matrix
from sklearn.metrics import roc_auc_score

THRESHOLD=0.5
testing_set_imgs.reset() #batch_index=0

Y_pred = model.predict_generator(testing_set_imgs, steps=np.ceil(num_imgs_testing/batch_size))
y_pred = np.where(Y_pred >= THRESHOLD, 1, 0)
# print(y_pred)
# print(y_pred)
```

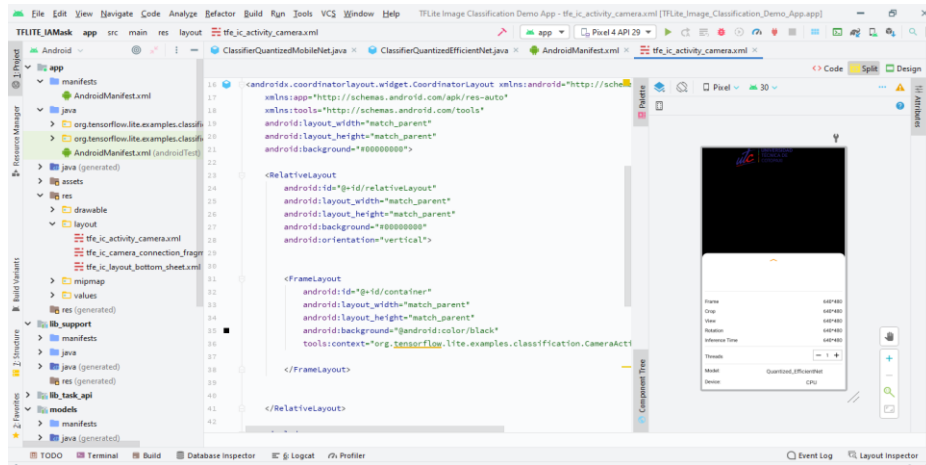
Descripción: Evaluación de resultados de los modelos entrenamos de la IA.

Anexo 26. Interfaz del archivo manifest en Android Studio



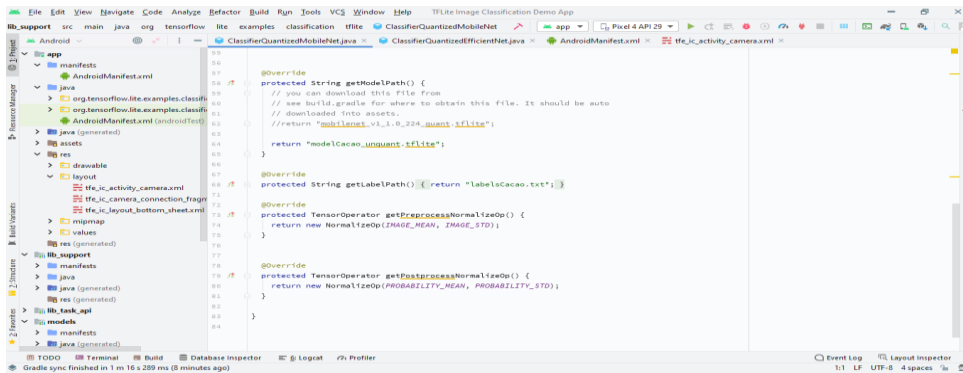
Descripción: Configuración del archivo manifest en la IDE de Android Studio.

Anexo 27. Interfaz y código de la aplicación móvil en Android Studio



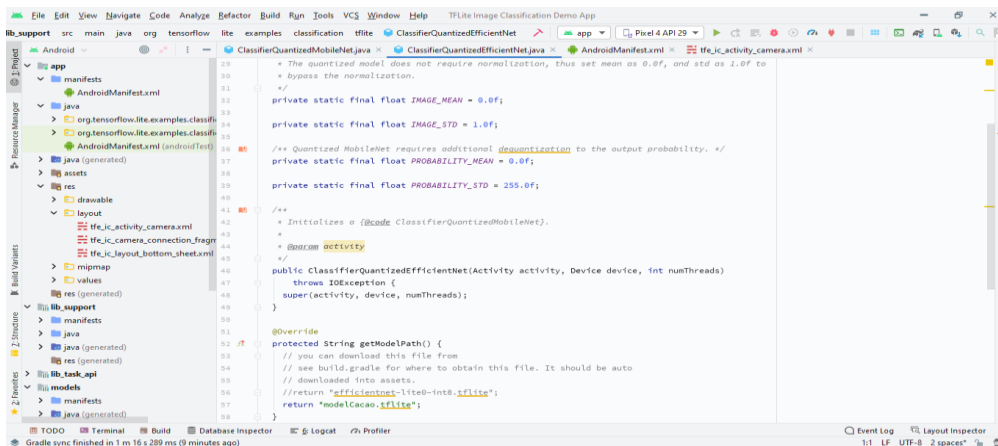
Descripción: *Maquetación del layout de la cámara de tipo xml*

Anexo 28. Implementación del clasificador MobilNet.Java de las imágenes en Android Studio



Descripción: *Implementación del archivo clasificador de imágenes en la clase MobilNet.Java.*

Anexo 29. Implementación del clasificador EfficientNet.Java de las imágenes en Android Studio



Descripción: *Implementación del archivo clasificador de imágenes tipo TFLITE en la clase EfficientNet.Java.*

Anexo 30. Código de los métodos de la cámara Activity

```

118 // ** A {@link Handler} for running tasks in the background. */
119 private Handler backgroundHandler;
120 // **
121 // ** A {@link TextureView.SurfaceTextureListener} handles several lifecycle events on a {@link
122 // ** TextureView}.
123 private final TextureView.SurfaceTextureListener surfaceTextureListener =
124     new TextureView.SurfaceTextureListener() {
125         @Override
126         public void onSurfaceTextureAvailable(
127             final SurfaceTexture texture, final int width, final int height) {
128             openCamera(width, height);
129         }
130         @Override
131         public void onSurfaceTextureSizeChanged(
132             final SurfaceTexture texture, final int width, final int height) {
133             configureTransform(width, height);
134         }
135         @Override
136         public boolean onSurfaceTextureDestroyed(final SurfaceTexture texture) { return true; }
137         @Override
138         public void onSurfaceTextureUpdated(final SurfaceTexture texture) {}
139     };
140 // ** An {@link ImageReader} that handles preview frame capture. */
141 private ImageReader previewReader;
142 // ** A {@link CaptureRequest.Builder} for the camera preview */
143 private CaptureRequest.Builder previewRequestBuilder;

```

Descripción: Métodos del fragment de la cámara activity.

Anexo 31. Librerías adicionales en Gradle de Android Studio

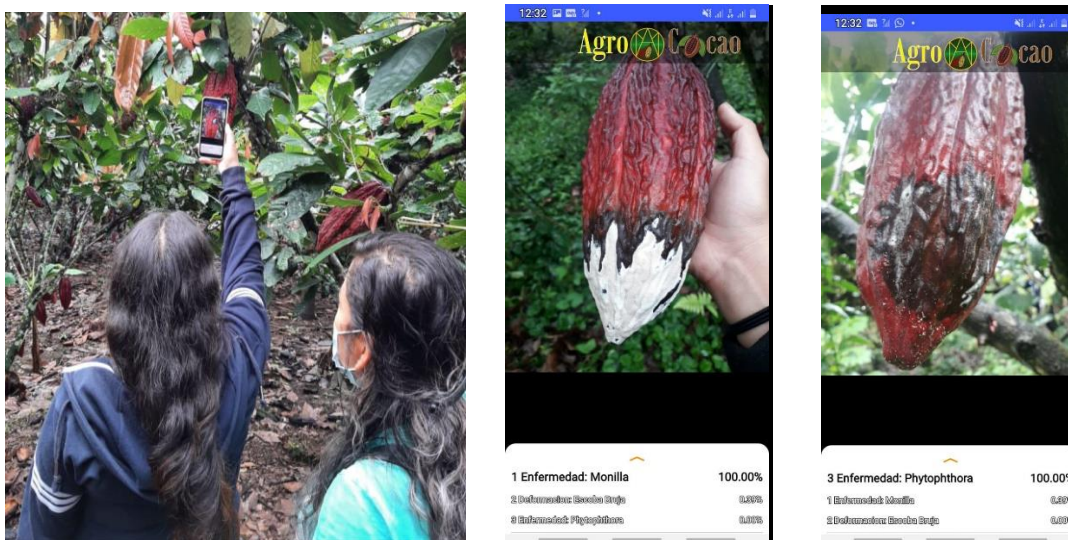
```

dependencies {
    implementation fileTree(dir: 'libs', include: ['*.jar'])
    supportImplementation project(':lib_support')
    testImplementation project(':lib_test_only')
    implementation 'androidx.appcompat:appcompat:1.0.0'
    implementation 'androidx.coordinatorlayout:coordinatorlayout:1.0.0'
    implementation 'com.google.android.material:material:1.0.0'
    implementation 'org.tensorflow:tensorflow-lite:2.3.0'
    implementation 'org.tensorflow:tensorflow-lite-gpu:2.3.0'
    androidTestImplementation 'androidx.test:ext-junit:1.1.1'
    androidTestImplementation 'com.google.truth:truth:1.0.1'
    androidTestImplementation 'androidx.test:runner:1.2.0'
    androidTestImplementation 'androidx.test:rules:1.1.0'
}

```

Descripción: Importación de dependencias en el Gradle de Android Studio.

Anexo 32. Pruebas de la aplicación móvil en el campo



Descripción: etapa de prueba de la aplicación móvil con datos reales y generación de buenos resultados sobre la enfermedad de la Monilia y Phytophthora.



UNIVERSIDAD TÉCNICA DE COTOPAXI

**FACULTAD DE CIENCIAS DE LA INGENIERIA Y APLICADAS
CIYA**

INGENIERÍA EN INFORMÁTICA Y SISTEMAS COMPUTACIONALES

**MANUAL DE USUARIO DEL APLICATIVO MOVIL DEL PROYECTO
DENOMINADO AGROCACAO**

Versión 1.0

AUTORAS:

Bustamante Ochoa María José

García Peña María José

TUTOR:

MSc. Bajaña Zajia Johnny Xavier

LA MANÁ – ECUADOR

MARZO 2021

MANUAL DE USUARIO

Objetivo

Otorgar el soporte necesario a los usuarios del aplicativo, teniendo el control de sus funcionalidades.

Requerimientos del sistema

- Sistemas Android Versión 6.0 en adelante
- Mínimo 4Gb De RAM

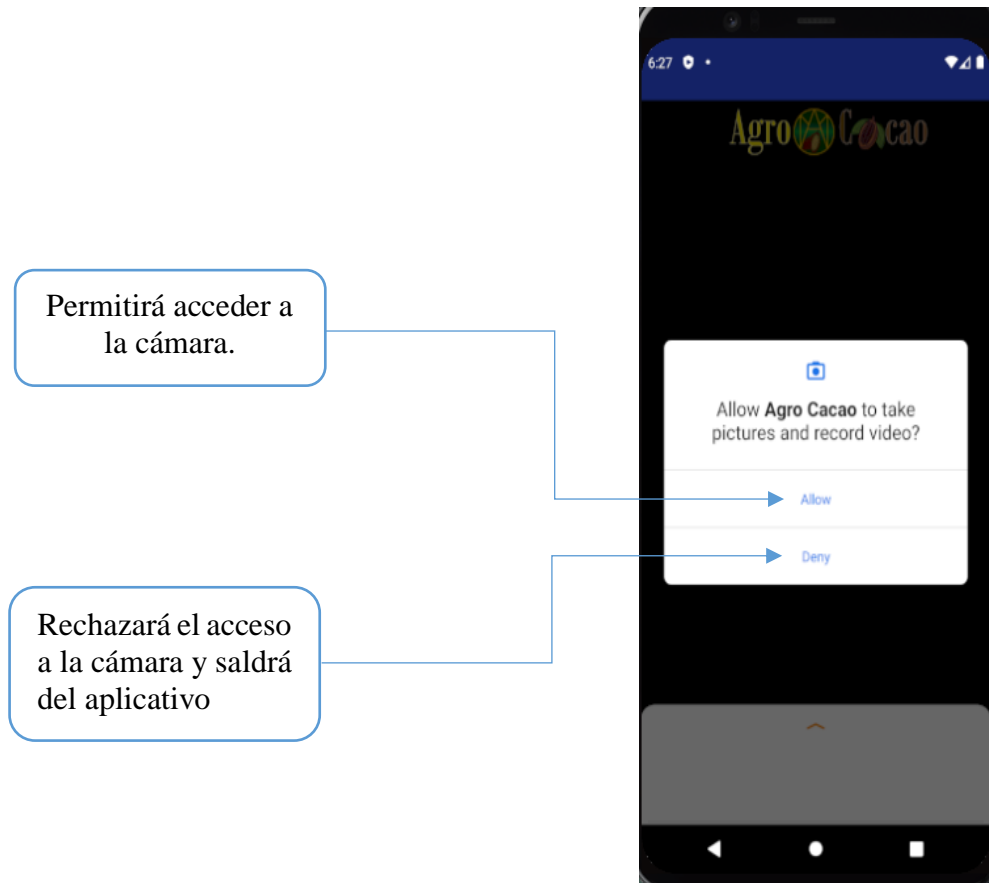
Opciones del aplicativo

El presente manual de usuario contempla la secuencia de uso de la siguiente manera:

1. Frame.
2. Crop.
3. View.
4. Rotation.
5. Threads.
6. Model.
7. Device.

Ingreso al aplicativo y acceder a permisos de cámara

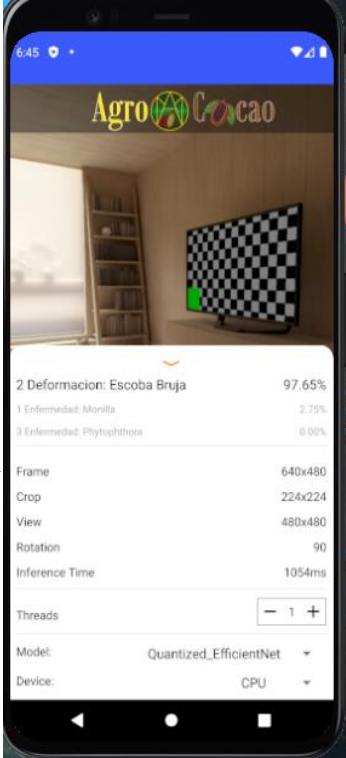
La presente pantalla muestra la solicitud de permiso al acceso de la cámara del móvil, en caso de ser denegada la aplicación procede a cerrarse de manera automática.



Dentro del cálculo de resultados de la clasificación de enfermedades, también se encuentra con apartados de configuración cual son los siguientes:

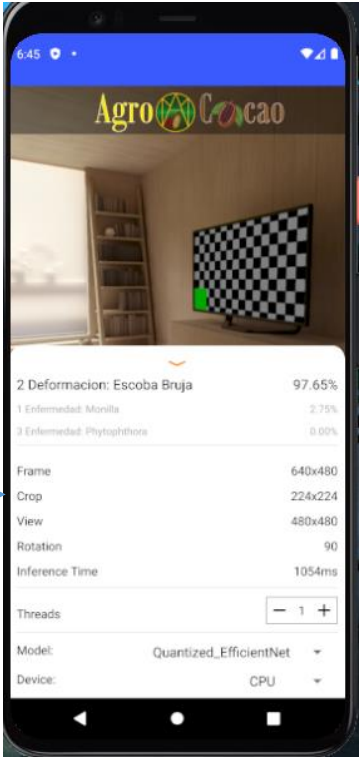
Frame: Desliza una ventana de tamaño `frame_length` sobre la dimensión del eje de la señal. Si `pad_end` es `True` (Verdadero), las posiciones de la ventana que sobrepasan el final de la dimensión del eje se rellenan con `pad_value` hasta que la ventana se mueve completamente más allá del final de la dimensión. De lo contrario, solo se generan las posiciones de ventana que se superponen completamente con la dimensión del eje.

Referencia del Frame
estática - automática.



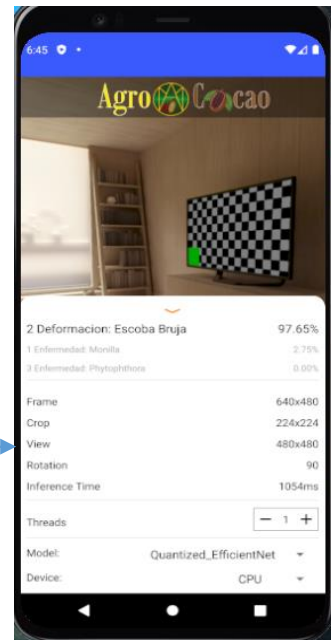
Crop: Extrae cultivos del tensor de imagen de entrada y los redimensiona mediante muestreo bilineal o muestreo de vecino más cercano (posiblemente con cambio de relación de aspecto) a un tamaño de salida común especificado.

Valores del tensor de
entrada Referencia
estática - automática.



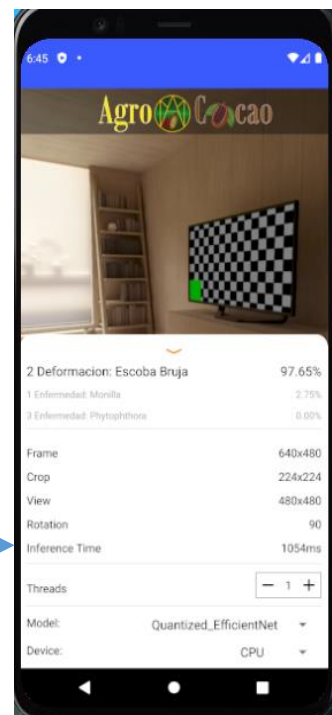
View: Renderización de imágenes por tensores.

Renderizado de capas con referencias automáticas bloqueadas



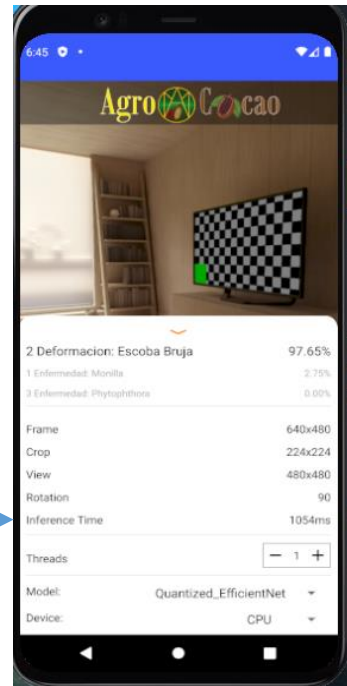
Interference time: Realiza operaciones matemáticas subyacentes que serán las mismas que se entrenaron los modelos, principalmente realizara operaciones de multiplicación de matrices para que los valores realicen las operaciones de suma y multiplicación subyacentes. Esto implicara si el gráfico contiene algunas estructuras de flujo de control más avanzadas que pueden influir en el tamaño real en función de los valores de ciertos tensores.

Operaciones de interferencias automáticas del clasificador de



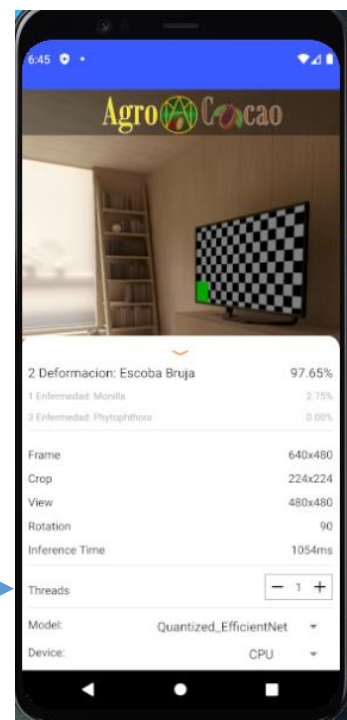
Rotation: Gira las imágenes en sentido antihorario por los ángulos pasados de tipo radianes.

Operaciones de giro constante por ángulos referenciados de manera automática



Threads: Obtiene el número de subprocesos utilizados para el paralelismo entre operaciones independientes

Al presionar la opción Threads, está solicitando al dispositivo activar los núcleos disponibles para el procesamiento y lectura de



Model: El modelo agrupa capas en un objeto con funciones de entrenamiento e inferencia.

Quantized Efficient net, permitirá realizar cálculos de manera instantánea.

Float EfficientNet permitirá realizar cálculos de manera reducida y tiempos de respuestas cortos

Quantized MobileNet permite realizar cálculos medidos en 0.1 v no representados en

Float MobileNet permite realizar cálculos medidos en 0.1; pero en este caso será de manera reducida y menos

The screenshot shows the AggroCacao app interface. At the top, there's a header with the logo and a camera view of a room. Below the camera, there's a list of items with their classification probabilities: '2 Deformacion: Escoba Bruja' (76.86%), '1 Enfermedad: Monilla' (22.35%), and '0 Fruta Saludable' (1.57%). A settings menu is open, showing options for 'Frame', 'Crop', 'View', 'Rotation', 'Inference Time', 'Threads', 'Model', and 'Device'. The 'Model' dropdown is set to 'Quantized_EfficientNet' and 'Device' is set to 'CPU'.

Device: Especifica el dispositivo para operaciones creadas / ejecutadas en este contexto.

Permite realizar cálculos mediante el hardware del procesador del móvil teniendo en cuenta la elevación de la

Permite utilizar todos los núcleos de procesamiento grafico del GPU para así liberar trabajo al CPU al momento de

NNAPI tiene como objetivo a realizar los cálculos que sobrecargan el dispositivo

The screenshot shows the AggroCacao app interface. At the top, there's a header with the logo and a camera view of a room. Below the camera, there's a list of items with their classification probabilities: '2 Deformacion: Escoba Bruja' (76.86%), '1 Enfermedad: Monilla' (22.35%), and '0 Fruta Saludable' (1.57%). A settings menu is open, showing options for 'Frame', 'Crop', 'View', 'Rotation', 'Inference Time', 'Threads', 'Model', and 'Device'. The 'Model' dropdown is set to 'Quantized_EfficientNet' and 'Device' is set to 'CPU'.

15. CERTIFICADO DE REPORTE DE LA HERRAMIENTA DE PREVENCIÓN DE COINCIDENCIA Y/O PLAGIO ACADÉMICO



Document Information

Analyzed document	PDF - BUSTAMANTE MARIA - GARCIA MARIA.pdf (D97756071)
Submitted	3/9/2021 5:44:00 PM
Submitted by	
Submitter email	jaime.cajas@utc.edu.ec
Similarity	4%
Analysis address	jaime.cajas.utc@analysis.arkund.com

Sources included in the report

W	URL: http://190.15.136.145/bitstream/42000/1104/1/TTC21.pdf Fetched: 1/10/2021 4:32:59 PM		3
W	URL: https://itelligent.es/es/deep-learning-convolutional-neuronal-network-cnn-consiste/ Fetched: 3/9/2021 5:45:00 PM		5
W	URL: https://elproductor.com/2017/04/control-de-plagas-y-enfermedades-del-cacao/ Fetched: 3/9/2021 5:45:00 PM		5
W	URL: http://www.mag.go.cr/bibliotecavirtual/H20-10877.PDF Fetched: 3/9/2021 5:45:00 PM		8
W	URL: http://infocafes.com/portal/wp-content/uploads/2016/05/cartilla-cacao-ICA-final.pdf Fetched: 3/9/2021 5:45:00 PM		7
W	URL: https://1library.co/document/qvlmvlry-learning-artificial-identificacion-administr... Fetched: 2/11/2021 9:12:04 AM		4
SA	B2.592_20192_PEC 2: Evolución trabajo final y memoria_12556911.txt Document B2.592_20192_PEC 2: Evolución trabajo final y memoria_12556911.txt (D73268443)		1
SA	Tesis_Final_Choloquiga_Reyes.pdf Document Tesis_Final_Choloquiga_Reyes.pdf (D62420150)		2
W	URL: http://bibliotecadigital.udea.edu.co/bitstream/10495/17662/1/MontoyaDanieL_2020_Fp... Fetched: 2/28/2021 5:05:28 PM		1
W	URL: https://es.statista.com/grafico/18920/cuota-de-mercado-mundial-de-smartphones-por-... Fetched: 3/9/2021 5:45:00 PM		1

Entire Document

UNIVERSIDAD TÉCNICA DE COTOPAXI FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS CARRERA DE INGENIERÍA EN INFORMÁTICA Y SISTEMAS COMPUTACIONALES PROYECTO DE INVESTIGACIÓN Proyecto de Investigación presentado previo a la obtención del Título de Ingeniería en Informática y Sistemas Computacionales. Autoras: Bustamante Ochoa Maria Jose García Peña María José Tutor: Ing. MSc. Bajaña Zajia Johnny Xavier LA MANÁ - ECUADOR MARZO - 2021 "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL Theobroma cacao PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI"

ii DECLARACIÓN DE AUTORÍA Nosotras, Bustamante Ochoa Maria Jose con C.I. No: 055071536-1 y García Peña María José con C.I. No: 235083592-8, declaramos ser autoras del presente proyecto de investigación: "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL Theobroma cacao PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI", siendo el MSc. Bajaña Zajia Johnny Xavier, tutor del presente trabajo; y eximo expresamente a la Universidad Técnica de Cotopaxi y a sus representantes legales de posibles reclamos o acciones legales. Además, certifico que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo, son de nuestra exclusiva responsabilidad. Atentamente, Bustamante Ochoa Maria Jose García Peña María José C.I: 055071536-1 C.I:235083592-8

iii AVAL DEL TUTOR DE PROYECTO DE INVESTIGACIÓN En calidad de tutor del trabajo de Investigación sobre el título: "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL Theobroma cacao PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI", de Bustamante Ochoa Maria Jose y García Peña María José de la carrera Ingeniería en Informática y Sistemas Computacionales, considero que dicho Informe Investigativo cumple con los requerimientos metodológicos y aportes científico-técnicos suficientes para ser sometidos a la evaluación del Tribunal de Validación de Proyecto que el Honorable Consejo Académico de la Facultad Académica de Ciencias de la Ingeniería y Aplicadas de la Universidad Técnica de Cotopaxi designe, para su correspondiente estudio y calificación. La Maná, Marzo de 2021 Ing. MSc. Bajaña Zajia Johnny Xavier CI: 120482711-5 TUTOR

iv APROBACIÓN DEL TRIBUNAL DE TITULACIÓN En calidad de Tribunal de Lectores, aprueban el presente informe de investigación de acuerdo a las disposiciones reglamentarias emitidas por la Universidad Técnica de Cotopaxi, y por la Facultad de CIENCIAS DE LA INGENIERÍA Y APLICADAS; por cuanto a las postulantes BUSTAMANTE OCHOA MARIA JOSE Y GARCÍA PEÑA MARÍA JOSÉ con el título de proyecto de Investigación: "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL Theobroma cacao PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI", han considerado las recomendaciones emitidas oportunamente y reúne los méritos suficientes para ser sometido al acto de sustentación del proyecto. Por lo antes expuesto, se autoriza realizar los empastados correspondientes, según la normativa institucional. La Maná, Marzo del 2021 Para constancia firman: Ing. MSc. Córdova Vaca Alba Marisol CI:180409377-9 LECTOR 3 (SECRETARIA)

v AGRADECIMIENTO Quiero expresar mi más sincero agradecimiento a Dios, por estar cuidándome en cada momento de mi vida, guiándome por el camino del bien y brindándome la sabiduría para realizar cada actividad. Y por último mi más sentido y profundo agradecimiento en especial a mi amada familia Bustamante Ochoa, quienes son el pilar fundamental en mi vida, gracias por su apoyo en esta larga y ardua experiencia universitaria. A mis padres José David y Cecibel Angélica por cada esfuerzo que realizaron para culminar mi formación universitaria y enseñarme que todo lo que me proponga lo puedo lograr, a mis hermanas Mayra Alejandra, Vanessa Estefania y Leylis Eliana por su paciencia, dedicación y amor ... por ellos gracias familia. Bustamante M. Gracias a Dios por permitirme tener y disfrutar de mi familia, siempre protegiéndome y por estar conmigo en cada paso que doy, por fortalecer mi corazón e iluminar mi mente y por haber puesto en mi camino a aquellas personas que han sido mi soporte y compañía durante todo mi trayecto de vida. A mis padres y familiares por su apoyo incondicional en los buenos y malos momentos que he pasado, gracias por haberme cuidado y ayudado en toda mi formación profesional y vida. Peña M.

vi DEDICATORIA Mi proyecto de investigación lo dedico llena de amor, esperanza y mucho sacrificio a mis seres amados, los cuales han sido la inspiración para culminar con mucho éxito y regocijo. A Dios por guiarme y cuidarme, a mi padre José David Bustamante Chichandi por su sacrificio, confianza, esfuerzo y esmero siendo el pilar fundamental en mi formación profesional, a mi madre Cecibel Angélica Ochoa Montiel por su amor, paciencia y la motivación en cada actividad que realice, y a mis hermanas Mayra Alejandra Bustamante Ochoa por su esfuerzo, cuidado y confianza, Vanessa

Estefanía Bustamante Ochoa y Leylis Eliana Bustamante Ochoa por ser consideradas, tenerme y el amor que me brindan. Por su esfuerzo y sacrificio familia este proyecto es por ustedes!!!. Bustamante M. Le dedico primeramente mi trabajo a mis padres que siempre me apoyaron incondicionalmente en la parte moral y económica para poder llegar a ser un profesional de la Patria. A la Universidad Técnica de Cotopaxi en conjunto con todo su equipo de colaboradores, en especial a los docentes de la carrera de Ingeniería en Informática y Sistemas Computacionales, por guiarnos hacia una educación de excelencia. Peña M.

vii UNIVERSIDAD TÉCNICA DE COTOPAXI FACULTAD DE CIENCIAS DE LA INGENIERÍA Y APLICADAS TÍTULO: "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL Theobroma cacao PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI". Autoras: Bustamante Ochoa María José García Peña María José RESUMEN En la actualidad los procesos Machine Learning aplicados en el campo de la agricultura está teniendo un gran éxito en diversos aspectos, estos incluyen la detección de diversas enfermedades de las plantas dentro del sector agrícola, para lograr esta precisión se requiere contar con métodos rápidos y eficaces de detección y evaluación de enfermedades de los frutos. Existe una gran variedad de microorganismos que causan enfermedades al cultivo del Theobroma cacao L., siendo que los hongos se constituyen como unos de los principales grupos, existe una cantidad de 8000 especies de hongos que producen variedades de enfermedades en el fruto, lo cual pueden reproducirse con mayor intensidad cuando existe una gran concentración de humedad. El presente proyecto tiene como objetivo determinar las enfermedades y el porcentaje de precisión en la mazorca de cacao, mediante una aplicación móvil que contiene modelos de inteligencia artificial de tipo Deep Learning. Gracias al desarrollo de esta aplicación móvil se contribuye con el agricultor que no tiene cognición de las enfermedades que afectan al cultivo de cacao, los profesionales agrícolas realizan pruebas eficientes mediante cámaras húmedas y por microscopio para identificar que patógenos infecciosos está afectando al fruto. Palabras claves: Machine Learning, Deep Learning, Modelos, Enfermedades, Theobroma Cacao L.

viii TECHNICAL UNIVERSITY OF COTOPAXI FACULTY OF ENGINEERING AND APPLIED SCIENCES TITLE: "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL Theobroma cacao PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI". Authors: Bustamante Ochoa María José García Peña María José ABSTRACT Nowadays, Machine Learning processes applied in the field of agriculture are having great success in various aspects, these include the detection of various plant diseases within the agricultural sector, to achieve this accuracy is required to have fast and effective methods of detection and evaluation of fruit diseases. There is a great variety of microorganisms that cause diseases to the crop of Theobroma cacao L., and fungi are one of the main groups, there are 8000 species of fungi that produce varieties of diseases in the fruit, which can reproduce more intensely when there is a high concentration of moisture. This project aims to determine the diseases and the percentage of accuracy in the cocoa pod, using a mobile application that contains artificial intelligence models of Deep Learning type. Thanks to the development of this mobile application contributes to the farmer who has no cognition of the diseases that affect the cacao crop, agricultural professionals perform efficient tests using wet cameras and microscopy to identify which infectious pathogens are affecting the fruit. Keywords: Machine Learning, Deep Learning, Models, Diseases, Theobroma Cacao.

ix AVAL DE TRADUCCIÓN En calidad de Docente del Centro Cultural de Idiomas de la Universidad Técnica de Cotopaxi, Extensión La Maná; en forma legal CERTIFICO que: La traducción de la descripción del Proyecto de Investigación al Idioma Inglés presentado por las señoritas: Bustamante Ochoa María José y García Peña María José cuyo título "IMPLEMENTACIÓN DE MODELOS MACHINE LEARNING APLICADOS AL ESTUDIO DE ENFERMEDADES DEL Theobroma cacao PARA HUERTAS AGROECOLÓGICAS DEL CANTÓN LA MANÁ, PROVINCIA DE COTOPAXI"; lo realizó bajo mi supervisión y cumple con una correcta estructura gramatical del Idioma. Es todo cuanto puedo certificar en honor a la verdad y autorizo al peticionario hacer uso del presente certificado de la manera ética que estimare conveniente. La Maná, febrero del 2021 Mg. Ramón Amores Sebastián Fernando CI: 050301668-5 COORDINADOR CENTRO CULTURAL DE IDIOMAS UTC LA MANÁ

x ÍNDICE Contenido DECLARACIÓN DE