



**ESCUELA SUPERIOR POLITÉCNICA AGROPECUARIA DE MANABÍ  
MANUEL FÉLIX LÓPEZ**

**CARRERA DE INFORMÁTICA**

**TRABAJO DE TITULACIÓN PREVIA LA OBTENCIÓN DEL TÍTULO DE  
INGENIERO EN INFORMÁTICA**

**MODALIDAD: SISTEMATIZACIÓN DE EXPERIENCIAS**

**TEMA:**

**APLICACIÓN MÓVIL DE DETECCIÓN Y CLASIFICACIÓN DE “LA  
ROYA” EN HOJAS DE CAFÉ ROBUSTA MEDIANTE  
APRENDIZAJE AUTOMÁTICO**

**AUTORES:**

**KEVIN DANIEL CUSME ZAMBRANO  
ANGÉLICA MARÍA LOOR PINARGOTE**

**TUTOR**

**DR. INF. JORGE ANTONIO PÁRRAGA ÁLAVA**

**CALCETA, DICIEMBRE 2019**

## **DERECHOS DE AUTORÍA**

KEVIN DANIEL CUSME ZAMBRANO Y ANGÉLICA MARÍA LOOR PINARGOTE, declaramos bajo juramento que el trabajo aquí descrito es de nuestra autoría, que no ha sido previamente presentado para ningún grado o calificación profesional, y que hemos consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración cedemos los derechos de propiedad intelectual a la Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López, según lo establecido por la Ley de Propiedad Intelectual y su reglamento.

.....

**KEVIN D. CUSME ZAMBRANO**

.....

**ÁNGELICA M. LOOR PINARGOTE**

## CERTIFICACIÓN DEL TUTOR

**DR. INF. JORGE ANTONIO PÁRRAGA ÁLAVA** certifica haber tutelado el proyecto **APLICACIÓN MÓVIL DE DETECCIÓN Y CLASIFICACIÓN DE “LA ROYA” EN HOJAS DE CAFÉ ROBUSTA MEDIANTE APRENDIZAJE AUTOMÁTICO**, que ha sido desarrollada por **KEVIN DANIEL CUSME ZAMBRANO Y ANGÉLICA MARÍA LOOR PINARGOTE**, previa la obtención del título de Ingeniero en Informática, de acuerdo al **REGLAMENTO PARA LA ELABORACIÓN DE TRABAJO DE TITULACIÓN DE LA UNIDAD DE TITULACIÓN ESPECIAL** de la Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López.

.....  
**DR. INF. JORGE ANTONIO PÁRRAGA ÁLAVA**

## **APROBACIÓN DEL TRIBUNAL**

Los suscritos integrantes del tribunal correspondiente, declaramos que hemos **APROBADO** el trabajo de titulación **APLICACIÓN MÓVIL DE DETECCIÓN Y CLASIFICACIÓN DE “LA ROYA” EN HOJAS DE CAFÉ ROBUSTA MEDIANTE APRENDIZAJE AUTOMÁTICO**, que ha sido propuesta, desarrollada por **KEVIN DANIEL CUSME ZAMBRANO Y ANGÉLICA MARÍA LOOR PINARGOTE**, previa la obtención del título de Ingeniero en Informática, de acuerdo al **REGLAMENTO PARA LA ELABORACIÓN DE TRABAJO DE TITULACIÓN** de la Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López.

.....  
ING. ÁNGEL A. VÉLEZ MERO, MGS

**MIEMBRO**

.....  
ING. ALFONSO T. LOOR VERA, MGS

**MIEMBRO**

.....  
ING. LUIS C. CEDEÑO VALAREZO, MGS

**PRESIDENTE**

## **AGRADECIMIENTO**

A la Escuela Superior Politécnica Agropecuaria de Manabí- Manuel Félix López, que nos brindó la oportunidad de contar con una educación superior de calidad la cual nos ayudó a forjarnos como profesionales en el transcurso de este camino,

A el Dr. Inf. Jorge Párraga Álava, quien nos guió y nos motivó a no decaer a lo largo de la elaboración y ejecución de este trabajo de titulación,

A el Ing. Luis Ortega, director encargado de la Carrera de Computación por la ayuda, tiempo y apoyo prestado,

A el grupo de investigadores del SISCOM de la Carrera de Computación y al grupo de investigadores del FITOGEN de la carrera de agrícola de la ESPAM-MFL liderado por el Ing. Luis Duicela, Mgs,

A la Ing. Jessica Morales Carrillo por ser guía en el último semestre de estudio de la carrera, y

A los docentes, que durante el trascurso de la carrera nos impartieron conocimientos significativos, consejos, amistad y tiempo para atender nuestras dudas suscitadas a través de todo este largo camino.

**LOS AUTORES**

## **DEDICATORIA**

Dedico este trabajo de titulación a mis padres Luis Loor e Isabel Pinargote por ser mi fortaleza y mi apoyo incondicional durante mi proceso de formación académica, por todos los consejos y paciencia que me han tenido, por ser quienes me han inculcado buenos valores y darme no solo apoyo moral sino también económico.

A mis hermanos Jefferson, Kevin y en especial a mi hermana Liceth por brindarme su apoyo moral y estar en los momentos que más la necesitaba.

A mi abuela Leticia Mendoza por ser una de las personas más importante en mi vida.

A mis tíos que de una u otra forma me dieron su apoyo económico.

**ANGÉLICA M. LOOR PINARGOTE**

## **DEDICATORIA**

Al haber culminado un ciclo de estudios de pregrado lleno de muchos obstáculos, momentos difíciles y de noches eternas de no dormir, es necesario dedicar tan prestigioso trabajo de titulación donde mi madre Mercedes Zambrano fue artífice principal de este logro quien también me apoyó desde los inicios hasta este momento, no tan solo de manera monetaria si no con su apoyo incondicional y constancia día tras día para no decaer jamás,

A mi padre Estalin Ibarra y hermano Michael Ibarra por el incansable apoyo para nunca desmayar,

A Dios por bendecir mi camino y a mi abuela Juana Muñoz por los consejos impartido y crianza, y

A mis demás familiares que de una manera u otra me brindaron apoyo moral.

**KEVIN D. CUSME ZAMBRANO**

## CONTENIDO GENERAL

DERECHOS DE AUTORÍA	ii
CERTIFICACIÓN DEL TUTOR	iii
APROBACIÓN DEL TRIBUNAL	iv
AGRADECIMIENTO	v
DEDICATORIA	vi
DEDICATORIA	vii
CONTENIDO GENERAL	viii
CONTENIDO DE CUADROS Y FIGURAS	x
RESUMEN	xi
PALABRAS CLAVE	xi
ABSTRACT	xii
KEY WORDS	xii
CAPÍTULO I. ANTECEDENTES	1
1.1. Descripción de la institución.	1
1.2. Descripción de la intervención.	3
1.3. Objetivos	5
1.3.1. Objetivo general	5
1.3.2. Objetivos específicos	5
CAPÍTULO II. DESARROLLO METODOLÓGICO DE LA INTERVENCIÓN	6
2.1. Obtención de imágenes de la hoja de café robusta.	6
2.2. Implementación de algoritmos de detección y clasificación para comprobar áreas sanas e infectadas en las hojas de café robusta.	7
2.3. Desarrollo la interfaz de usuario y el código fuente de la aplicación móvil.	9
2.3.1. Metodología de desarrollo ágil xp	9

diseño	10
codificación	11
2.4. Implementación de la aplicación móvil de detección y clasificación de “la roya”.	12
2.4.1. Pruebas	12
2.4.2. Validación de los resultados	13
CAPÍTULO III. DESCRIPCIÓN DE LA EXPERIENCIA	15
3.1. Obtención de imágenes de la hoja de café robusta	15
3.2. Implementación de algoritmos de detección y clasificación para comprobar áreas sanas e infectadas en las hojas de café robusta	17
3.3. Desarrollo la interfaz de usuario y el código fuente de la aplicación móvil	27
3.3.1. Diseño	27
3.3.2. Codificación	29
3.4. Implementación de la aplicación móvil de detección y clasificación de “la roya”.	30
3.4.1. Pruebas	30
3.4.2. Validación de los resultados	30
CAPÍTULO IV. CONCLUSIONES Y RECOMENDACIONES	32
4.1. Conclusiones	32
4.2. Recomendaciones	33
BIBLIOGRAFÍA	34
ANEXOS	39

## CONTENIDO DE CUADROS Y FIGURAS

<b>Gráfico 3.1.1</b> Total de hojas procesadas en LabelBox. ....	16
<b>Gráfico 3.2.2</b> Tipos de redes neuronales artificiales encontrada con los criterios de búsqueda de la revisión bibliográfica .....	21
<b>Gráfico 3.2.3</b> Red neuronal artificial convolucional y rangos por porcentaje de efectividad del algoritmo	21
<b>Gráfico 3.2.4</b> Separación del conjunto de datos de entrenamiento y de pruebas.....	25
<b>Gráfico 3.2.5</b> Distribución por cantidad de imágenes del total del conjunto de datos. ....	26
<b>Foto 3.1.2</b> Pre procesamiento de las imágenes en la herramienta LabelBox detectando una hoja sana y clasificándola.....	15
<b>Foto 3.1.3</b> Pre procesamiento de las imágenes en la herramienta LabelBox detectando una hoja infectada y clasificándola. ....	16
<b>Figura 2.1.1</b> Modelos de reconocimiento de imágenes pre entrenados. ....	8
<b>Figura 2.3.2</b> Fases de la metodología XP (Extreme Programming).....	10
<b>Ecuación 2.4.2.1</b> Formula para calcular la exactitud (Accuracy).....	13
<b>Ecuación 2.4.2.2</b> Formula para calcular la exactitud (Accuracy) con el reemplazo de sus valores. ....	13
<b>Ecuación 3.4.3</b> Formula de exactitud (Accuracy) implementada en los valores obtenidos de la iteración 11.....	31
<b>Ilustración 3.2.1</b> Esquema del modelo de clasificación InceptionV3. ....	25
<b>Ilustración 3.3.1.2</b> Diseño de la aplicación móvil de detección y clasificación de "la roya". ....	28
<b>Ilustración 3.2.2.3</b> Interfaz de la aplicación móvil de detección y clasificación de "la roya". ....	29
<b>Tabla 2.4.2.1</b> Modelo de matriz de confusión para determinar la exactitud (Accuracy) .....	14
<b>Tabla 2.1</b> Tabla de resumen de la revisión bibliográfica .....	18
<b>Tabla 3.4.2.1</b> Iteraciones y su porcentaje de exactitud obtenidas en la validación del conjunto de datos. 31	
<b>Tabla 3.4.2.2</b> Iteraciones y su porcentaje de exactitud obtenidas en la validación del conjunto de datos. 31	

## CONTENIDO DE ANEXOS

<b>Anexo 1</b> Conjunto de datos de las imágenes obtenidas en las parcelas del CIIDEA en la ESPAM MFL..	41
<b>Anexo 2</b> Tabla de resumen de la revisión bibliográfica. ....	60
<b>Anexo 3</b> Ejecución de las iteraciones en Python. ....	62
<b>Anexo 4</b> Certificación del SISCOM en cumplimiento de la sistematización de la experiencia.....	64

## **RESUMEN**

Manabí al ser una provincia dotada de recursos naturales y al ser la agricultura una de las actividades de mayor importancia se busca dar soluciones optimizadas con mirada hacia la agricultura y las tendencias tecnológicas actuales. El propósito de este trabajo de titulación fue desarrollar una aplicación móvil basada en aprendizaje automático que permitiera automatizar la detección y clasificación de “la roya” en las hojas de café robusta. La obtención de imágenes se realizó en las parcelas de la Ciudad de Investigación e Innovación y Desarrollo Agropecuario (CIIDEA) donde se encontraban plantaciones de café robusta, una vez obtenido imágenes se realizó el debido procesamiento de las mismas el cual implicaba determinar cuándo una hoja estaba infectada y cuando no. Se procedió a la revisión bibliográfica para determinar el algoritmo de aprendizaje automático más factible a implementar. Con estos datos se procede a desarrollar la aplicación móvil utilizando la metodología de desarrollo Programación Extrema, empleando técnicas de aprendizaje automático, lo que permitió detectar este hongo en las hojas de café robusta. Estos resultados pueden ayudar a las áreas que involucran el estudio de este tipo de investigación como el proyecto de caracterización de dicha enfermedad en los cultivos de café, además, el desarrollo de la aplicación e implementación del algoritmo brindó un 95% de efectividad en la detección de “la roya”.

## **PALABRAS CLAVE**

Café robusta, aprendizaje automático, Roya, aplicación móvil

## **ABSTRACT**

Manabí being a province endowed with natural resources and being agriculture one of the most important activities, seeks to provide optimized solutions with a view to agriculture and current technological trends. The purpose of this titling work was to develop a mobile application based on machine learning that would automate the detection and classification of "Roya" on robust coffee leaves. The images were obtained in the plots of the Agricultural Research and Innovation and Development City (CIIDEA) where robust coffee plantations were located, once images were obtained, the correct processing was carried out that involved determining when a leaf was infected and when not. The literature review was carried out to determine the most feasible machine-learning algorithm to be implemented. With this data, the mobile application is developed using the Extreme Programming development methodology, using machine-learning techniques, which allowed detecting this fungus in the robust coffee leaves. These results can help the areas that involve the study of this type of research, such as the project to characterize said disease in coffee crops, in addition, the development of the application and implementation of the algorithm provided a 97% detection effectiveness of "Roya".

## **KEY WORDS**

Robust coffee, machine learning, Roya, mobile application

# **CAPÍTULO I. ANTECEDENTES**

## **1.1. DESCRIPCIÓN DE LA INSTITUCIÓN.**

Manabí es una provincia rica en variados recursos, los habitantes del cantón Bolívar han dirigido su mirada a la tierra, pródiga desde siempre y, en ese contexto, se han identificado con la agricultura y la ganadería. Ello exigía, en Calceta, la presencia de un centro de educación superior en las áreas agrícola y pecuaria, de manera que la población estudiantil, con dificultad para trasladarse a universidades fuera de la zona, pudiera alcanzar un título académico, a fin de servir más tarde, no solo al cantón, sino a toda la región. Las gestiones, un largo recorrido, empezaron en el Congreso Nacional y luego en otras instancias desde 1995. Se crea así el INSTITUTO TECNOLÓGICO SUPERIOR AGROPECUARIO DE MANABÍ, ITSAM, mediante Ley N°. 116, publicada en el R.O. N°. 935, el 29 de abril de 1996.

Tres años después, el Congreso Nacional expidió la Ley Reformativa que transformaba el Instituto Tecnológico Superior Agropecuario de Manabí, ITSAM, en ESCUELA SUPERIOR POLITÉCNICA AGROPECUARIA DE MANABÍ, ESPAM, cuya Ley 99-25 fue publicada en el R.O. el 30 de abril de 1999. La Escuela Superior Politécnica Agropecuaria de Manabí nace como persona jurídica de derecho público, autónoma, que se rige por la Constitución Política del Estado, Ley de Educación Superior, su Estatuto Orgánico y Reglamentos, para preparar a la juventud ecuatoriana y convertirla en profesionales, conforme lo exigen los recursos naturales de su entorno. La ESPAM inicia sus labores con las carreras de Agroindustria, Medio Ambiente, Agrícola y Pecuaria. Posteriormente, mediante un estudio de mercado, se crea la carrera de Informática, emprendiendo así, un riguroso programa de fortalecimiento académico, con el fin de formar profesionales idóneos que ejecuten proyectos sustentables, generadores de fuentes de trabajo.

Ante la demanda de nuevas carreras, los directivos de la ESPAM, no han escatimado esfuerzos para incrementar otras, de tipo empresarial. Es así como desde el año 2003 funcionan dos nuevos programas: Administración Pública y Administración de Empresas, los que se cumplen en horarios nocturnos, al igual

que la Carrera de Informática. A partir del año 2007 y, producto de un estudio, los estudiantes tienen una nueva opción: Ingeniería en Turismo. Con ello se busca potenciar a la población manabita, ávida de lograr una profesión acorde con sus aspiraciones (Escuela Superior Politécnica Agropecuaria de Manabí, 2018).

La ESPAM MFL, mediante la Coordinación General de investigación realiza trabajos mancomunados por el aporte de la universidad a la ciencia. La planificación estratégica de la ESPAM MFL 2017-2021 plantea en el subsistema de investigación como objetivo estratégico “fortalecer el sistema de gestión de la investigación para que se contribuya al desarrollo de la zona 4 y el país”, y como objetivo específico establece “ejecutar investigaciones que contribuyan al desarrollo de la zona 4 y del país”.

El grupo SISCO se rige bajo el “Reglamento para la conformación de Grupos de Investigación” de la ESPAM MFL, el cual indica en su artículo primero “establecer las normas de cumplimiento para las líneas de investigación que presentan temas agrupados de estudios científicos que se fundamentan en tradición investigativa, de donde se originan programas y proyectos cuyos resultados guarden afinidades entre sí”.

Con las referencias previamente mencionados y la creación del grupo de investigación “Sistemas Computacionales” (SISCO) que tiene como objetivo “contribuir al sector agro-productivo y de servicios con soluciones computacionales, que aporten al desarrollo tecnológico y al entorno social” para mejorar los procesos investigativos en esta área. Este grupo de investigación contempla principalmente los siguientes campos: Aprendizaje automático y asistido, visión por computador, minería de datos, robótica (Inteligencia artificial), optimización de procesos, sistemas distribuidos (ESPAM MFL (Escuela Superior Politécnica Agropecuaria de Manabí), 2018).

## **1.2. DESCRIPCIÓN DE LA INTERVENCIÓN.**

El uso de dispositivos móviles se encuentra en uno de sus puntos máximos superando ya los 3 millones de aplicaciones (Antonio, Hernández, Lisette, Martínez, & Muñiz, 2014), debido a que en la actualidad el desarrollo de aplicaciones ha revolucionado la operatividad de los mismos (Yang, Jia, & Wang, 2015), también desempeñan papel fundamental para el desarrollo económico de los países del mundo, así como lo hacen para la enseñanza y aprendizaje móvil en esencia (Y. Zhang & Hu, 2019), las aplicaciones móviles también van ganando mayor aceptación en empresas y organizaciones del mundo (Ahmed & Ibrahim, 2015).

La agricultura es una actividad de gran importancia estratégica, base fundamental para el desarrollo auto suficiente y la riqueza de las naciones (Redolfi, 2018). En Latinoamérica fue una de las primeras tareas de la economía, tras la colonización de algunos sus países en Brasil comenzaron a cultivar caña de azúcar y luego la producción de café (Katkamwar, Kumar, & Kalaskar, 2013). Según datos de la Organización de las Naciones Unidas para la Alimentación y la Agricultura, (2016) entre el 30 y el 40% de la producción agrícola anual se pierde debido a plagas y enfermedades. Por lo tanto, la adopción de prácticas agrícolas modernas y el uso de las tendencias tecnológicas con mira a disciplinas como la robótica, la visión por computadora y el aprendizaje de máquina a las técnicas agropecuarias resulta necesario tener una nueva mirada sobre la agricultura y las técnicas utilizadas (Pinto, Rossato, Coronel, & Schuh, 2018).

Con todos estos antecedentes se buscan soluciones con varias técnicas de inteligencia artificial para analizar variables del entorno agrícola para saber su relación con los problemas específicos que traen a las plantaciones (Lasso, Thamada, Meira, & Corrales, 2015). Se describen distintas investigaciones que presentan alternativas innovadoras con aprendizaje automático; empezando con aplicaciones informáticas que permitan el escaneo de plagas o daño en sus cultivos utilizando aprendizaje automático en Ecuador, permitiendo a que los agricultores puedan tener acceso a tecnología que ayudan a la producción de su materia prima sin hacer una gran inversión económica (Andrade Vera, 2018)

Por ejemplo, para la identificación de *Huanglongbing* (HLB) en las hojas de cultivos de cítricos con diferentes niveles de eficiencia, donde se las desarrollan con un sensor de visión utilizando una cámara monocroma, LED de alta potencia y filtros polarizadores para identificar la concentración de almidón en las hojas, síntoma característico del HLB, con esta configuración lograron una precisión de detección oscila entre 95.5 % y 98.5 % (Berger, Preussler, & Agostini, 2018). Así como para la detección de la cenicienta (*Sphaerotheca pannosa*) en las hojas de la rosa se desarrollan aplicaciones basadas en aprendizaje automático que permitan identificar mediante la configuración de las imágenes tomadas la concentración de almidón en las rosas principal característica de la cenicienta empleadas en los invernaderos, tomando como punto de la ejecución del muestreo la etapa antes del cosechado de las rosas (Velázquez-López, Sasaki, Nakano, Mejía-Muñoz, & Romanchik Kriuchkova, 2011).

Según la Comisión pastoral de movilidad humana, (2013), "la roya" es una enfermedad causada por un hongo fitoparásito del café, con el nombre científico de *hemileia vastatrix*, es una enfermedad terrible que no se elimina por lo que los productores de café deben aprender a convivir con ella y aprender a reducir sus efectos; el hongo se ha convertido en una gran preocupación para los agricultores que siembran el café robusta por esto, también, se la considera de las enfermedades del café la que más afecta a la economía (Rodríguez, Girón, Corrales, & Corrales, 2018), este hongo el cual se encuentra en su mayor frecuencia a temperaturas altas generalmente en temporada de invierno (Martins, Soares, Medeiros, Santos, & Pozza, 2015).

Este trabajo de titulación estará vinculado y tributará al grupo de investigación "SISCOM" de la carrera de computación en uno de sus proyectos denominado "Caracterización de la roya en cultivo de café robusta mediante técnicas avanzadas de inteligencia computacional" al dejar a disponibilidad del grupo, los resultados que se obtendrán de la creación de la "Aplicación móvil de detección y clasificación de "la roya" en hojas de café robusta mediante aprendizaje automático". Estos resultados podrán ser usados en las distintas áreas que involucran el estudio de este tipo de investigación tal como el proyecto de caracterización de dicha enfermedad en los cultivos de café.

## **1.3. OBJETIVOS**

### **1.3.1. OBJETIVO GENERAL**

Desarrollar una aplicación móvil basada aprendizaje automático para la detección y clasificación de “la roya”, en los cultivos de café robusta, con el fin de automatizar la detección de la enfermedad.

### **1.3.2. OBJETIVOS ESPECÍFICOS**

- Obtener imágenes de las hojas de café robusta disponibles en las parcelas agrícolas.
- Implementar algoritmos de detección y clasificación automática para reconocer áreas sanas e infectadas en las hojas de café robusta.
- Desarrollar la aplicación móvil que permita la detección y clasificación de “la roya” basada en técnicas de aprendizaje automático.
- Implementación de la aplicación móvil de detección y clasificación de “la roya”.

## **CAPÍTULO II. DESARROLLO METODOLÓGICO DE LA INTERVENCIÓN**

Para la ejecución de este trabajo de titulación se lo realizó por medio de los objetivos, donde en cada uno se desarrollaron distintas actividades para llevar a cabo la realización del trabajo de titulación. En cada actividad de los objetivos se hace uso de técnicas y métodos. Además, en la parte de desarrollo de la aplicación se utilizó la metodología XP con las fases de diseño, codificación y pruebas (Borja, 2013).

### **2.1. OBTENCIÓN DE IMÁGENES DE LA HOJA DE CAFÉ ROBUSTA.**

Se realizó una visita de campo a las parcelas de café ubicadas en la Ciudad de Investigación e Innovación y Desarrollo Agropecuario (CIIDEA) de la ESPAM MFL, además, se hizo una entrevista informal no estructurada al Ing. Luis Duicela, Mgs de la carrera de Ingeniería Agrícola quien pertenece al grupo FITOGEN de dicha carrera quien proporcionó el croquis donde están ubicadas las plantas de café robusta y sus hojas. La parcela usada en esta investigación está formada por un conjunto de 480 plantas de café robusta donde disponibles existen 390 plantas de donde se realizó la toma de imágenes a sus hojas y 90 plantas restantes que no estuvieron a disposición de esta investigación. Este conversatorio también permitió determinar el método de detección que los agricultores utilizan para poder detectar la presencia o no de “la roya”, utilizando el método de determinar la presencia de roya según lo indica la Organización de las Naciones Unidas para la Alimentación y la Agricultura, (2016).

Luego se hizo la captura de imagen de las hojas, usando cámaras de teléfonos con resolución de al menos 2 megapíxeles, además todas las fotos fueron tomadas a una distancia de 20 a 30 cm. En total se tomaron 556 fotos de 390 plantas sembradas, de las cuales para cada planta se capturó entre hojas sanas y de hojas infectadas para ambos casos se tomó del haz y envés respectivamente (Parraga-Alava, Cusme, Loor, & Santander, 2019). También al obtener una cantidad grande de datos en este caso las imágenes obtenidas en

las parcelas de café robusta, en el renombrado se utilizó la herramienta para renombrar conjuntos de datos por lotes Bulk Rename Utility (Bulk Rename Utility, 2013).

Para el procesamiento de las imágenes obtenidas se lo realizó utilizando la herramienta de procesamiento de datos LabelBox para crear el dataset, este procesamiento de imágenes consistió en crear anotaciones/ etiquetado sobre las hojas, estas anotaciones tuvieron como objetivo determinar el estado de las hojas entre sanas e infectas de “la roya” (Organización de la Naciones Unidas para la Alimentación y la Agricultura, 2016). Dejando las imágenes listas para entrar a la validación del algoritmo de aprendizaje automático que como uno de sus objetivos tiene estudiar y desarrollar modelos computacionales de procesos de aprendizaje capaces de mejorar su desempeño con la práctica e ir aprendiendo (Mitchell, Carbonell, & Michalski, 1986)

## **2.2. IMPLEMENTACIÓN DE ALGORITMOS DE DETECCIÓN Y CLASIFICACIÓN PARA COMPROBAR ÁREAS SANAS E INFECTADAS EN LAS HOJAS DE CAFÉ ROBUSTA.**

Fue necesario realizar una revisión bibliográfica en la que se buscó información en repositorios científicos como Springer Link, Scielo, entre otros en los cuales se escogieron revistas desde el año 2010 hasta la actualidad que contengan información importante sobre redes neuronales artificiales utilizadas en la detección y clasificación de enfermedades o plagas en las plantas. Además, toda la información que se investigó resumida en un cuadro comparativo en el que se especificaba el tema de la investigación, año, red neuronal utilizada, descripción de los artículos científicos, porcentaje de efectividad del algoritmo y enfermedad o plaga que trataba la investigación.

Esto nos llevó a la conclusión de utilizar una red neuronal convolucional ya que generalmente se utilizan en el reconocimiento de patrones en imágenes además se hizo uso de la arquitectura de la red pre-entrenada InceptionV3 ya que esta arquitectura toma menos tiempo de operación por segundo. El lenguaje de programación que utilizamos para la creación del algoritmo fue Python en el que se utilizó la librería TensorFlow, el cual nos permitió identificar las hojas sanas e infectadas. Con esta librería se llevó a cabo varias tareas o procesos como la



inmediatamente después de una capa de convolución para añadir no linealidad a los datos que provienen de la capa convolucional, la capa de Pooling se empleó para reducir información espacial, consiguiendo reducir sobreajuste (overfitting) en la red y algo de invarianza a la traslación todo esto ayudó para el procesamiento de las imágenes de acuerdo con el esquema de los procesos que emplea las redes neuronales convolucionales (Picazo, O., y Baumela, 2018), obteniendo como resultados la imagen procesada con el hongo detectado.

## **2.3. DESARROLLO LA INTERFAZ DE USUARIO Y EL CÓDIGO FUENTE DE LA APLICACIÓN MÓVIL.**

### **2.3.1. METODOLOGÍA DE DESARROLLO ÁGIL XP**

XP es una metodología ágil centrada en potenciar las relaciones interpersonales como clave para el éxito en desarrollo de software, promoviendo el trabajo en equipo, preocupándose por el aprendizaje de los programadores, y propiciando un buen clima de trabajo. buen clima de trabajo. XP se basa en realimentación continua entre el cliente y el equipo de desarrollo, comunicación fluida entre todos los participantes, simplicidad en las soluciones implementadas y coraje para enfrentar los cambios. XP se define como especialmente adecuada para proyectos con requisitos imprecisos y muy cambiantes (Kim et al., 2012).

Por lo antes mencionado se hará uso de esta metodología para el desarrollo de la aplicación móvil de detección y clasificación de “la roya”, cuyo cliente fue el grupo de investigadores del SISCO que participan en el proyecto CGI-ESPAMMFL CUP 383713, a continuación, se detallarán las fases que comprende esta metodología de desarrollo de software.

A continuación, se detallarán las fases que tienen la metodología de desarrollo XP:

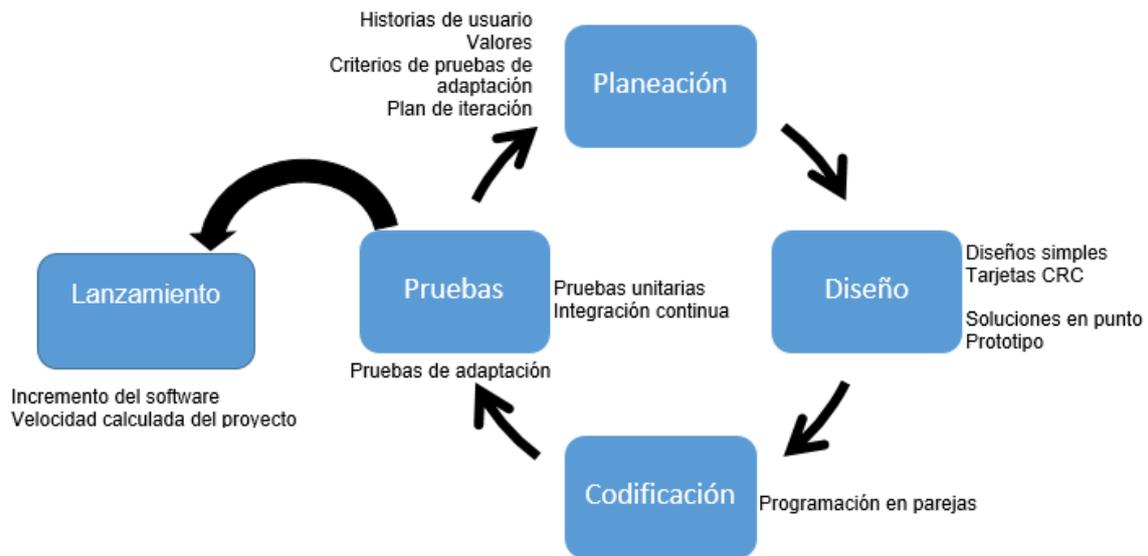


Figura 2.3.2 Fases de la metodología XP (Extreme Programming).

## DISEÑO

- **Diseños simples:** La metodología X.P sugiere que hay que conseguir diseños simples y sencillos. Hay que procurar hacerlo todo lo menos complicado posible para conseguir un diseño fácilmente entendible e impleméntable que a la larga costará menos tiempo y esfuerzo desarrollar.
- **Glosarios de términos:** Usar glosarios de términos y una correcta especificación de los nombres de métodos y clases ayudará a comprender el diseño y facilitará sus posteriores ampliaciones y la reutilización del código.
- **Riesgos:** Si surgen problemas potenciales durante el diseño, X.P sugiere utilizar una pareja de desarrolladores para que investiguen y reduzcan al máximo el riesgo que supone ese problema.
- **Funcionalidad extra:** Nunca se debe añadir funcionalidad extra al programa, aunque se piense que en un futuro será utilizada. Sólo el 10% de la misma es utilizada, lo que implica que el desarrollo de funcionalidad extra es un desperdicio de tiempo y recursos.
- **Re factorizar:** Re factorizar es mejorar y modificar la estructura y codificación de códigos ya creados sin alterar su funcionalidad. Re factorizar supone revisar de nuevo estos códigos para procurar optimizar su funcionamiento. Es muy común rehusar códigos ya creados que contienen funcionalidades que no serán usadas y diseños obsoletos. Esto es un error porque puede generar código completamente inestable y muy mal diseñado; por

este motivo, es necesario re factorizar cuando se va a utilizar código ya creado (Borja, 2013).

## **CODIFICACIÓN**

Como ya se dijo en la introducción, el cliente es una parte más del equipo de desarrollo; su presencia es indispensable en las distintas fases de X.P. A la hora de codificar una historia de usuario su presencia es aún más necesaria. No olvidemos que los clientes son los que crean las historias de usuario y negocian los tiempos en los que serán implementadas. Antes del desarrollo de cada historia de usuario el cliente debe especificar detalladamente lo que ésta hará y también tendrá que estar presente cuando se realicen los test que verifiquen que la historia implementada cumple la funcionalidad especificada.

La codificación debe hacerse ateniendo a estándares de codificación ya creados. Programar bajo estándares mantiene el código consistente y facilita su comprensión y escalabilidad. Crear test que prueben el funcionamiento de los distintos códigos implementados nos ayudará a desarrollar dicho código. Crear estos test antes nos ayuda a saber qué es exactamente lo que tiene que hacer el código a implementar y sabremos que una vez implementado pasará dichos test sin problemas ya que dicho código ha sido diseñado para ese fin. Se puede dividir la funcionalidad que debe cumplir una tarea a programar en pequeñas unidades, de esta forma se crearán primero los test para cada unidad y a continuación se desarrollará dicha unidad, así poco a poco conseguiremos un desarrollo que cumpla todos los requisitos especificados.

Como ya se comentó anteriormente, X.P opta por la programación en pareja ya que permite un código más eficiente y con una gran calidad. X.P sugiere un modelo de trabajo usando repositorios de código dónde las parejas de programadores publican cada poca hora sus códigos implementados y corregidos junto a los test que deben pasar. De esta forma el resto de programadores que necesiten códigos ajenos trabajarán siempre con las últimas versiones. Para mantener un código consistente, publicar un código en un repositorio es una acción exclusiva para cada pareja de programadores. X.P también propone un modelo de desarrollo colectivo en el que todos los programadores están implicados en todas las tareas; cualquiera puede modificar

o ampliar una clase o método de otro programador si es necesario y subirla al repositorio de código. El permitir al resto de los programadores modificar códigos que no son suyos no supone ningún riesgo ya que para que un código pueda ser publicado en el repositorio tiene que pasar los test de funcionamiento definidos para el mismo.

La optimización del código siempre se debe dejar para el final. Hay que hacer que funcione y que sea correcto, más tarde se puede optimizar. X.P afirma que la mayoría de los proyectos que necesiten más tiempo extra que el planificado para ser finalizados no podrán ser terminados a tiempo se haga lo que se haga, aunque se añadan más desarrolladores y se incrementen los recursos. La solución que plantea X.P es realizar un nuevo "Release plan" para concretar los nuevos tiempos de publicación y de velocidad del proyecto. A la hora de codificar no seguimos la regla de X.P que aconseja crear test de funcionamiento con entornos de desarrollo antes de programar. Nuestros test los obtendremos de la especificación de requisitos ya que en ella se especifican las pruebas que deben pasar las distintas funcionalidades del programa, procurando codificar pensando en las pruebas que debe pasar cada funcionalidad (Borja, 2013).

## **2.4. IMPLEMENTACIÓN DE LA APLICACIÓN MÓVIL DE DETECCIÓN Y CLASIFICACIÓN DE “LA ROYA”.**

### **2.4.1. PRUEBAS**

Uno de los pilares de la metodología X.P es el uso de test para comprobar el funcionamiento de los códigos que vayamos implementando.

El uso de los test en X.P es el siguiente:

Se deben crear las aplicaciones que realizarán los test con un entorno de desarrollo específico para test.

Hay que someter a test las distintas clases del sistema omitiendo los métodos más triviales.

- Se deben crear los test que pasarán los códigos antes de implementarlos; en el apartado anterior se explicó la importancia de crear antes los test que el código.

Un punto importante es crear test que no tengan ninguna dependencia del código que en un futuro evaluará. Hay que crear los test abstrayéndose del futuro código, de esta forma aseguraremos la independencia del test respecto al código que evalúa. Como se comentó anteriormente los distintos test se deben subir al repositorio de código acompañados del código que verifican. Ningún código puede ser publicado en el repositorio sin que haya pasado su test de funcionamiento, de esta forma, aseguramos el uso colectivo del código (explicado en el apartado anterior). El uso de los test es adecuado para observar la refactorización. Los test permiten verificar que un cambio en la estructura de un código no tiene por qué cambiar su funcionamiento.

Test de aceptación. Los test mencionados anteriormente sirven para evaluar las distintas tareas en las que ha sido dividida una historia de usuario. Para asegurar el funcionamiento final de una determinada historia de usuario se deben crear "Test de aceptación"; estos test son creados y usados por los clientes para comprobar que las distintas historias de usuario cumplen su cometido (Borja, 2013).

## 2.4.2. VALIDACIÓN DE LOS RESULTADOS

En este trabajo se validó el algoritmo con la métrica de exactitud (accuracy) ya que esta es una métrica para evaluar modelos de clasificación. Informalmente, la exactitud es la fracción de predicciones que el modelo realizó correctamente. Formalmente, la exactitud tiene la siguiente definición (Developers, 2019):

$$Exactitud = \frac{\text{número de predicciones correctas}}{\text{número total de predicciones}}$$

**Ecuación 2.4.2.1** Formula para calcular la exactitud (Accuracy).  
Fuente: (Developers, 2019)

En la clasificación binaria, la exactitud también se puede calcular en términos de positivos y negativos de la siguiente manera:

$$Exactitud = \frac{VP + VN}{VP + VN + FN + FP}$$

**Ecuación 2.4.2.2** Formula para calcular la exactitud (Accuracy) con el reemplazo de sus valores.  
Fuente: (Developers, 2019)

Donde VP (Verdaderos Positivos): cantidad de positivos que fueron clasificados correctamente como positivos por el modelo, VN (Verdaderos negativos): cantidad de negativos que fueron clasificados correctamente como negativos por el modelo, FP (Falsos positivos): cantidad de negativos que fueron clasificados incorrectamente como positivos por el modelo y FN (Falsos negativos): cantidad de positivos que fueron clasificados incorrectamente como negativos por el modelo.

Esta métrica se la llevo a una matriz de confusión que nos permitió visualizar mediante una tabla de contingencia la distribución de errores cometidos por el clasificador. Esta matriz de confusión para el caso de dos clases tiene la siguiente apariencia, como se puede apreciar en la Tabla.

**Tabla 2.4.2.1** Modelo de matriz de confusión para determinar la exactitud (Accuracy)

MATRIZ DE CONFUSIÓN		CLASE PREDICHA	
		POSITIVO	NEGATIVO
CLASE REAL	POSITIVO	VP	FN
	NEGATIVO	FP	VN

Fuente: Los autores.

## CAPÍTULO III. DESCRIPCIÓN DE LA EXPERIENCIA

### 3.1. OBTENCIÓN DE IMÁGENES DE LA HOJA DE CAFÉ ROBUSTA

Al realizar la visita de campo a la Ciudad de Investigación e Innovación y Desarrollo Agropecuario (CIIDEA) de la ESPAM MFL, donde se encontraron las parcelas de las plantas de café robusta mediante una entrevista informal no estructurada al Ing. Luis Duicela, Mgs miembro del grupo de investigación FITOGEN de la carrera de Agrícola, persona quien nos brindó los datos característicos de las plantas y las hojas de café robusta. También quien nos ayudó a visualizar la forma el cual los agricultores utilizan para la detección de “la roya”, los síntomas característicos que presentan las hojas y que se sustenta en el método de detección de “la roya” en el manual de la Organización de la Naciones Unidas para la Alimentación y la Agricultura, (2016)

Con base en el método de selección de las hojas de café robusta las parcelas del CIIDEA se obtuvieron un total de 390 plantas para la investigación donde se tomó fotos en el haz y en el envés de las hojas para ambos casos cuando presenta infección y cuando está sana, recopilando 556 fotos (**Anexo 1**), que se las sometieron a un proceso de renombrado en la aplicación Bulk Rename Utility (Bulk Rename Utility, 2013), que permitió renombrar archivos por lotes dejando el conjunto de datos (dataset) que se utilizó listo para el pre- procesamiento de las fotos obtenidas.



**Foto 3.1.1** Pre procesamiento de las imágenes en la herramienta LabelBox detectando una hoja sana y clasificándola.

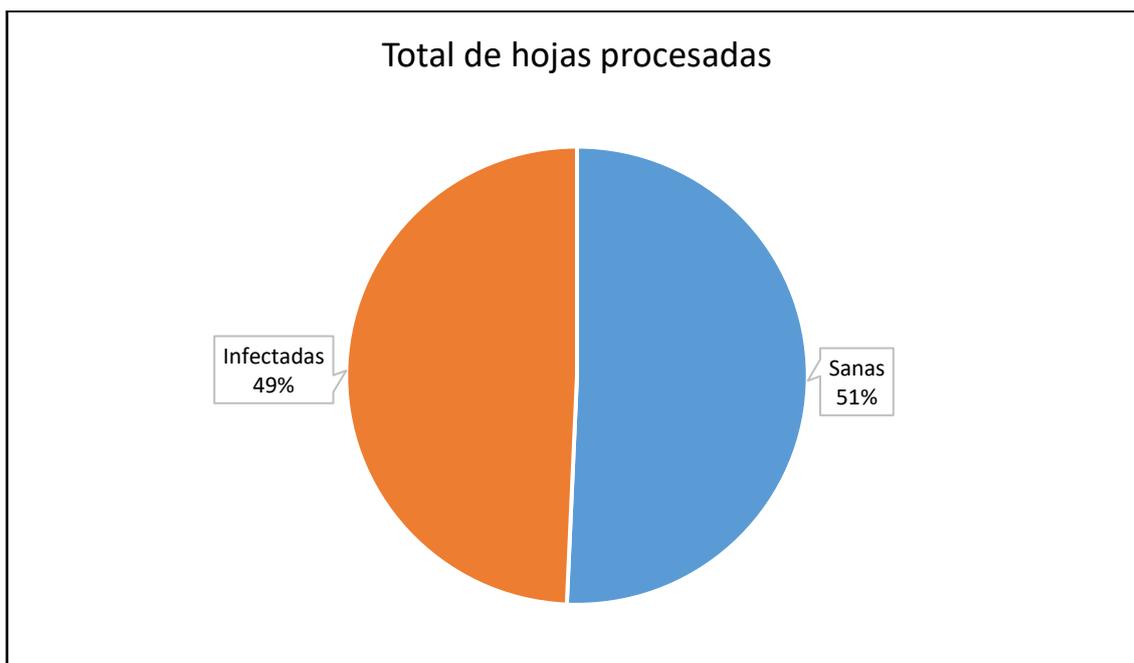
Fuente: Los autores.



**Foto 3.1.2** Pre procesamiento de las imágenes en la herramienta LabelBox detectando una hoja infectada y clasificándola.

Fuente: Los autores.

Teniendo las fotos renombradas de las parcelas de café en el CIIDEA utilizando la herramienta web LabelBox que se basa en crear un proceso de etiquetas y anotaciones, siendo este aplicado a seleccionar el contorno de las hojas en las imágenes cargada previamente a la herramienta desde la nube, anotando así la detección si las hojas se encontraron sanas [Foto 3.1.1] o infectadas [Foto 3.1.2] que estas hojas tenían según el manual de la Organización de la Naciones Unidas para la Alimentación y la Agricultura, (2016). Reflejando los siguientes resultados:



**Gráfico 3.1.1** Total de hojas procesadas en LabelBox.

Fuente: Los autores

### **3.2. IMPLEMENTACIÓN DE ALGORITMOS DE DETECCIÓN Y CLASIFICACIÓN PARA COMPROBAR ÁREAS SANAS E INFECTADAS EN LAS HOJAS DE CAFÉ ROBUSTA**

La tarea de revisar la bibliografía de investigación comprendió en identificación, selección, análisis crítico y descripción escrita de la información existente sobre el tema de interés. En general, se aconseja realizar una revisión bibliográfica en sí por varias razones importantes. Primero, en la fase de arranque del trabajo de titulación, enfocar la revisión bibliográfica realizada en un área de interés general contribuye a la formulación o aclaración del problema planteado. Segundo, la inspección detallada del trabajo previo familiarizará a los investigadores con lo que se ha hecho en el campo de estudio y disminuyen al mínimo la posibilidad de duplicación involuntaria. Tercero, la revisión proporcionó un contexto o marco conceptual para los investigadores y para la comunidad científica que facilita la acumulación de conocimientos. Cuarto, los investigadores se ubican en una mejor posición para evaluar la factibilidad de un estudio propuesto. Por último, la revisión fue útil para proporcionar sugerencias metodológicas que guíen la investigación. La información que se investigó fue resumida en un cuadro comparativo en el que se especificaba el tema de la investigación, año, red neuronal utilizada, descripción de los artículos científicos, porcentaje de efectividad del algoritmo y enfermedad o plaga que trataba la investigación.

Tabla 2.1 Tabla de resumen de la revisión bibliográfica

TABLA DE RESUMEN DE LA REVISIÓN BIBLIOGRAFICA						
N°	AÑO	TITULO	TIPO DE RED UTILIZADA	DESCRIPCIÓN DEL PAPER	PORCENTAJE DE EFECTIVIDAD DEL ALGORITMO	ENFERMEDAD/PLAGAS
1	2019	Image Recognition of Tea Leaf Diseases Based on Convolutional Neural Network (Sun, Mu, Xu, Cao, & Su, 2019).	Convolutional Neural Network	Este trabajo se centra en el reconocimiento de hojas enfermas de té, basada en la red neuronal convolucional, en el que se incluyen 7 enfermedades foliares, en este trabajo, las funciones de activación de la capa convolucional y la capa totalmente conectada es ReLU. La arquitectura de la red utilizada tiene 9 capas, que contiene 2 capas de convolución, 2 capas de agrupación, 2 capas de normalización de respuesta parcial, 2 capas de conexión completa y 1 capa de salida de clasificación.	93.75%	Enfermedades en hoja de té
2	2019	Investigating Input Protocols, Image Analysis, and Machine Learning Methods for an Intelligent Identification System of Fusarium Oxysporum Sp. in Soil Samples (B, Estuar, & Leon, 2019).	Convolutional Neural Network	Este artículo hace experimentos comparando dos métodos de aprendizaje en el que los resultados de los experimentos utilizan 64 × 64 entradas de imagen de tamaño 64 píxeles. Así mismo, se observaron los tiempos de procesamiento como 45.46min, y 15 s. Los experimentos con las entradas de imagen más pequeños de 32 × 32 dimensiones de 32 pixel, quedando demostrado que las imágenes con pequeñas resoluciones dan un mayor porcentaje de efectividad.	81,12%	Fusarium oxysporum Sp. en suelo
3	2018	Image-Based Tomato Leaves Diseases Detection Using Deep	Convolutional Neural Network	Esta red está compuesta por seis clases de las cuales cinco son las enfermedades y la hoja sana. El modelo usado consta de dos	99,84%	Enfermedad en hojas de tomate: mancha bacteriana, tizón

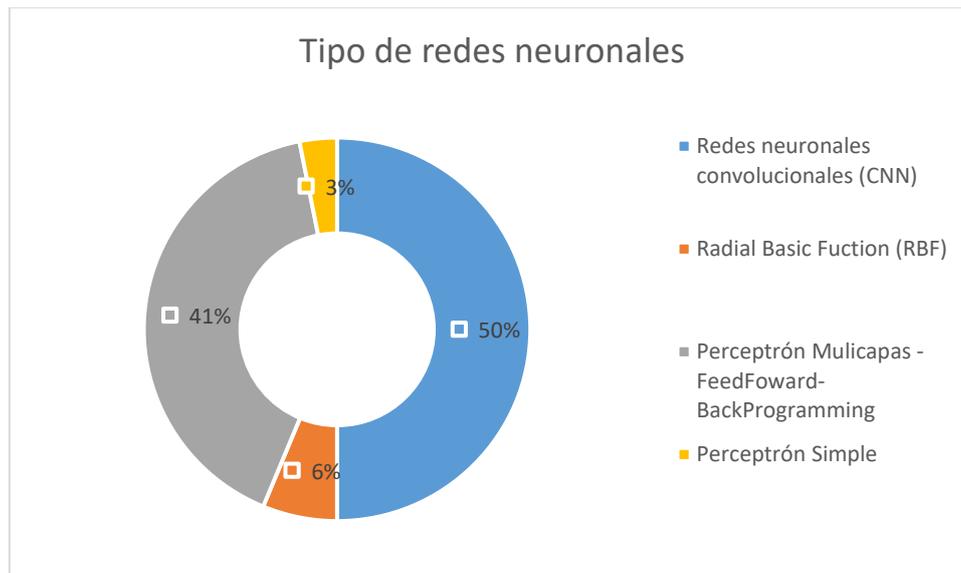
		Learning (Ashqar & Abu-naser, 2018).		partes: La primera parte del modelo (extracción de características), que es el mismo para el enfoque a todo color y en escala de grises, consta de 4 convoluciones, capas con función de activación relu, cada uno seguido por Max Pooling layer. La segunda parte después de la capa plana contiene dos capas densas para ambos enfoques, pero a todo color. El primero tiene 256 unidades ocultas, por otro lado, el enfoque de escala de grises tiene 128 unidades ocultas en la primera capa, se redujo el tamaño de la red de escala de grises para evitar el sobreajuste, la última capa tiene Softmax como activación y 6 salidas que representan las 6 clases.		temprano, Mancha Septorial, Molde foliar, Yellow Leaf Curl Virus.
4	2018	Identification of Maize Leaf Diseases Using Improved Deep Convolutional Neural Networks (X. Zhang, Qiao, Meng, Fan, & Zhang, 2018).	Convolutional Neural Network	La red contiene tres capas convolucionales, dos capas totalmente conectadas, y una capa de pérdida. Después de cada capa convolucional en el modelo, hay una capa puesta en común y una operación Relu. Además, esta investigación hace la comparación de la tasa de aprendizaje entre el modelo GoogLeNet y Cifar10. Para el modelo Cifar10 la tasa de aprendizaje de este modelo es fijo en 0,0002. Mientras que para el modelo GoogLeNet la tasa de aprendizaje es 0,001.	98,9%	Enfermedades en la hoja de maíz: Curvularia, mosaico enano, mancha de la hoja gris, tizón de la hoja del Norte, mancha marrón, punto redondo, óxido y tizón de la hoja del sur
5	2018	A Unified Matrix-Based Convolutional Neural Network for Fine-Grained Image Classification of Wheat Leaf Diseases (Lin et al., 2019).	Convolutional Neural Network	La clasificación de las enfermedades de los cultivos se ve afectada por varias interferencias visuales, entre ellas la falta de iluminación, el rocío y las fluctuaciones de los equipos. Para abordar este desafío, se	96.5%	Enfermedades de la hoja de trigo de invierno

---

propuso una red neuronal convolucional unificada (CNN) que denota la red neuronal convolucional basada en matriz (M-bCNN). Su sello distintivo es la matriz de núcleo convolucional, cuyas capas convolucionales se organizan paralelamente en forma de matriz y se integran con DropConnect, unidad lineal exponencial, normalización de la respuesta local, etc., para eliminar el gradiente excesivo y desvanecido.

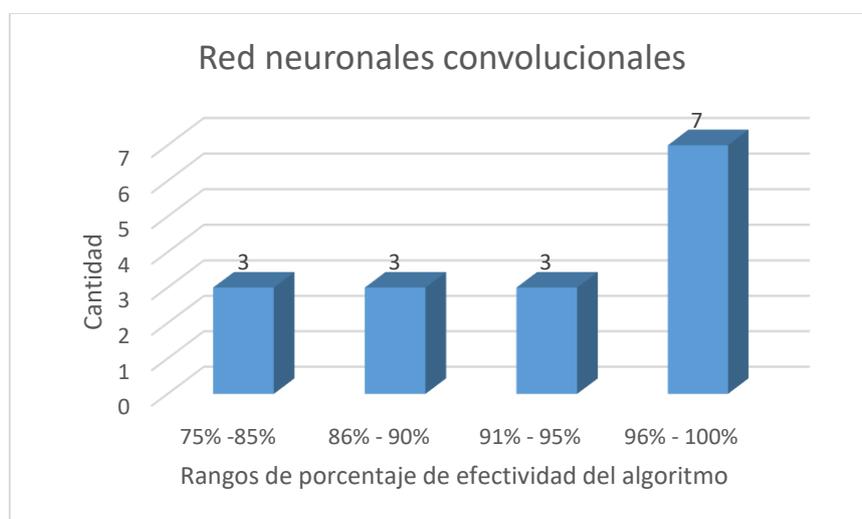
---

**Fuente:** Los autores



**Gráfico 3.2.2** Tipos de redes neuronales artificiales encontrada con los criterios de búsqueda de la revisión bibliográfica  
**Fuente:** Los autores

Utilizando los criterios de búsqueda planteado al inicio de la revisión bibliográfica se obtuvo como resultados el tipo de algoritmo encontrados en los artículos científicos (**Gráfico 3.2.2**), donde un 53% del total de los artículos científicos consultados fueron escritos e hicieron uso de las redes neuronales artificiales convolucionales (CNN), un 41% del total de los artículos científicos consultados usaron algoritmos como perceptrón multicapas, FeedFoward, BackProgramming, un 6% de total de los artículos científicos usaron algoritmos Radial Basic Fuction (RBF) y un 3% del total de los artículos científicos usaron el algoritmo perceptrón simple.



**Gráfico 3.2.3** Red neuronal artificial convolucional y rangos por porcentaje de efectividad del algoritmo  
**Fuente:** Los autores

Al ser las redes neuronales artificiales convolucionales el tipo de red neuronal con mayor porcentaje de artículos científicos donde se hace uso de esta red en la detección y clasificación de objetos, en el (Gráfico 3.2.3), se muestra la cantidad de artículos científicos encontrados y previamente revisados que hacen referencia a la detección de enfermedades y/o plagas en cultivos agrícolas (tomate, maíz, café, hojas de té, frutos cítricos, trigo, manzanas, rábano, melón, banano, plátano, en la soya, en rosas, etc).

Mostrando una clasificación por clases de los artículos científicos recopilados se observa que en el rango del 75% al 85% de efectividad hay 3 (tres) artículos científicos. En el estudio análisis de imágenes utilizando machine Learning para detectar *Fusarium oxysporum* (B et al., 2019), este es una especie de hongo causante de enfermedades en banano y plátano que comúnmente se presenta en los suelos donde se los cultivan. En este estudio, se obtuvo un 81,2% de efectividad utilizando las CNN, esta investigación. Otro artículo científico sobre la clasificación de enfermedades en las hojas de plátano utilizando CNN (Amara, Bouaziz, & Algergawy, 2017), obtuvo un 80% de efectividad y por último una investigación (Andrade Vera, 2018) que utilizaba una aplicación móvil para la detección y tratamiento de daños de los cultivos de la parroquia Taura del cantón Durán, obtuvo un 77,3% de efectividad en el algoritmo empleado, detectando enfermedades como: la roya del cafeto, el pulgón, cochinilla negra, el *oídio*, etc.

Se obtuvieron 3 (tres) artículos científicos que se muestra del 86% al 90% de efectividad donde estos artículos utilizando las redes neuronales convolucionales teniendo como resultados que en (Velázquez-López et al., 2011) la detección de cenicilla esporas blancas que afectan a las rosas en el haz de sus hojas la utilización de técnicas de aprendizaje automático tuvo un 89,95% de efectividad. En (Johannes et al., 2017) la detección de *Hemileia Vastatrix* Roya, Septoria y mancha canela en el trigo obtuvo un 90% de efectividad de la técnica de aprendizaje automático utilizada y en (Wang, Sun, & Wang, 2017) la detección del nivel de severidad de *Podredumbre* negra un hongo que afecta a la hoja de la manzana, teniendo un 90,4% de efectividad.

De la sub clasificación de las redes neuronales convolucionales se obtuvo el rango entre el 91% al 95% de efectividad encontrado 3 (tres) artículos científicos

que hacen reseña al objeto de estudio, en (Ha et al., 2017) la clasificación el marchitamiento del rábano por el hongo *Fusarium* utilizando vehículos aéreos no tripulados en esta investigación obtuvieron un 93,3% de efectividad en las técnicas de aprendizaje automático utilizadas, en (Sun et al., 2019) el reconocimiento de imágenes de hojas de té enfermas basándose en un modelo de convolución, un 93,75% de efectividad y por último en (Durmus, Gunes, & Kirci, 2017) la detección de enfermedades en las hojas del tomate utilizando también redes neuronales artificiales convolucionales un 95,6% de efectividad.

En la última sub clasificación de las redes neuronales convolucionales ubicadas en el rango de 96% al 100% de efectividad, se obtuvieron un total de 7 (siete) artículos científicos que hacen referencia al objeto de estudio y a la afectación de enfermedades o plagas en cultivo ejes fundamentales en la realización de esta revisión bibliográfica. Encontramos en (Sladojevic, Arsenovic, Anderla, Culibrk, & Stefanovic, 2016) el reconocimiento de plantas por imágenes de sus hojas utilizando CNN con el 96,3% de efectividad en la detectando 13 enfermedades en (pera, cereza y durazno, porosidad en el melocotón, moho polvoriento en el melocotón, *Taphrina deformans* o lepra en manzana y pera, *Erwinia amylovora* o fuego bacteriano en plantaciones de manzanas y peras, enfermedades en el café, entre otras), luego en (Lin et al., 2019) la clasificación de imágenes de grano fino de las enfermedades que afectan las hojas del trigo teniendo un 96,5% de efectividad en la red neuronal convolucional utilizada y en (Tan, Zhao, & Wu, 2016) la detección y alerta inteligente de lesiones en el melón un 97,5% de efectividad en utilizando CNN.

Posteriormente en este mismo rango encontramos un estudio de (Berger et al., 2018) la identificación de síntomas de *Huanglongbing* bacteria que se la encuentra en las hojas de frutos cítricos generalmente a el limón, la naranja y la mandarina con un 98,5% de efectividad, en (X. Zhang et al., 2018) la identificación de enfermedades como (curvularia, mosaico enano, mancha de la hoja gris, tizón de la hoja del Norte, mancha marrón, punto redondo, óxido y tizón de la hoja del sur) en las hojas de maíz utilizando redes neuronales

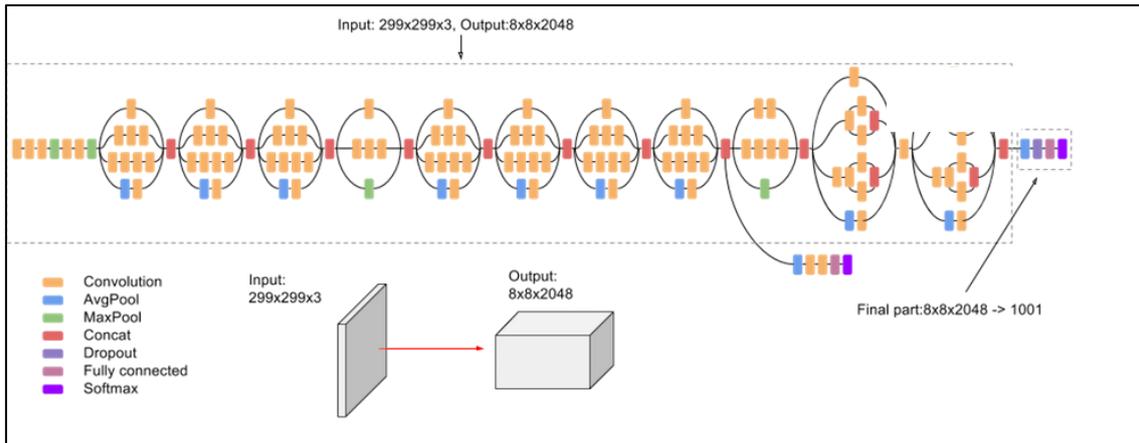
convolucionales mejoradas con 98,9% de efectividad. También en (Brahimi, Boukhalfa, & Moussaoui, 2017) la detección de nueve enfermedades en la hoja

de tomate (Mancha bacteriana, tizón temprano, moho foliar, mancha septoria, ácaros araña, mancha objetivo, virus del mosaico, virus del enrollamiento de la hoja amarilla), obteniendo un 99,18% de efectividad en la clasificación de enfermedades en el tomate utilizando redes neuronales profundas (CNN) y por último en (Ashqar & Abu-naser, 2018) la detección de enfermedades en las hojas de tomate tales como (mancha bacteriana, tizón temprano, mancha septorial, molde foliar, virus del enrollamiento de la hoja amarilla), obteniendo más alto porcentaje de efectividad con 99,84% utilizando redes neuronales convolucionales (CNN).

Los datos obtenidos de la revisión bibliográfica muestran que las redes neuronales artificiales específicamente las convolucionales son las más utilizadas para el procesamiento de imágenes de hojas para la detección de enfermedades y/o plagas en cultivos, siendo estas las de mayor porcentaje de efectividad en los artículos revisados, todo esto lleva a la conclusión de usar este tipo de red neuronal artificial en el trabajo de titulación propuesto para la detección y clasificación de “la roya” en hojas de café robusta.

En la implementación del algoritmo de este trabajo se utilizó la arquitectura de la red convolucional InceptionV3 en donde se clasifico en dos clases (sanas e infectadas), En InceptionV3 se utilizan capas convolucionales de tamaño 1x1 y 3x3 con su parámetro de salto en uno y dos. Adicionalmente se cuenta con una capa de pooling de valor máximo y una concatenación final de los filtros(Quintero, Merchán, Cornejo, & Galán, 2018).

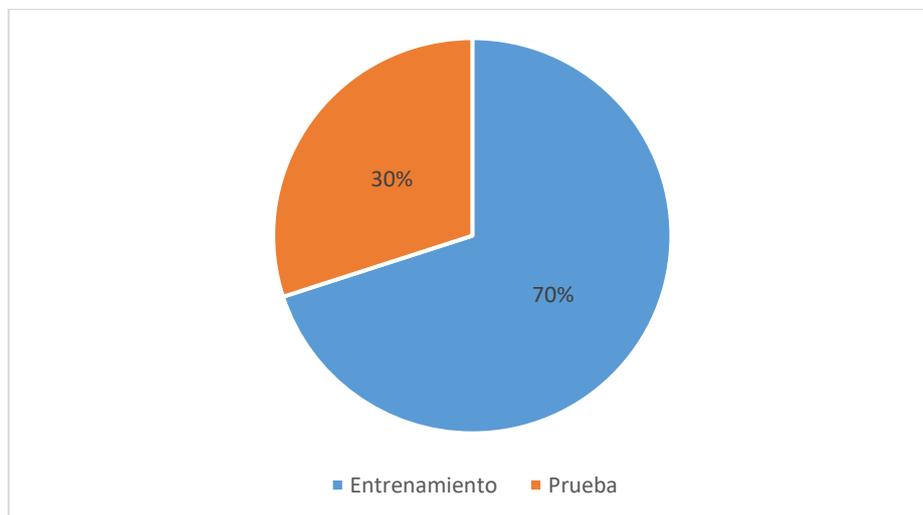
En Inception-v3 se hace uso de unos módulos llamados Inception. Estos actúan como múltiples filtros aplicados a un mismo valor de entrada mediante capas convolucionales y de pooling. Esto permite sacar provecho de la extracción de patrones que brindan diferentes tamaños en los filtros. Luego, el resultado de estos filtros es concatenado y utilizado como el valor de salida del módulo. Este modelo aumenta el número de parámetros entrenables y la computación requerida, pero mejora considerablemente la precisión(Quintero et al., 2018). En la Figura se muestra el esquema de entrenamiento y clasificación de Inception-v3.



**Ilustración 3.2.1** Esquema del modelo de clasificación InceptionV3.

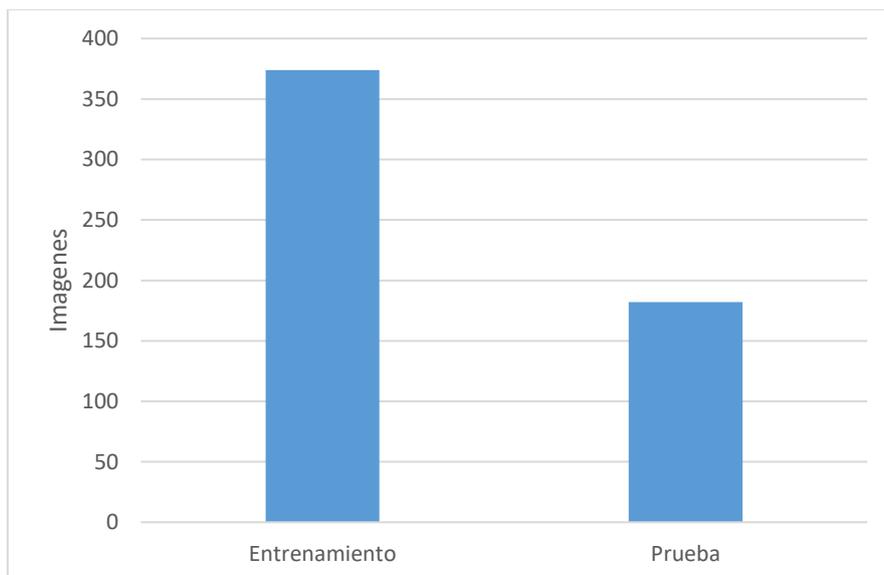
**Fuente:** (Google, 2019)

Para el entrenamiento del algoritmo se utilizó un conjunto de 565 imágenes tomadas en las parcelas de café robusta en CIIDEA, de las cuales las imágenes de entrenamiento fueron almacenadas para su uso, en carpetas organizadas es decir fueron agrupadas de acuerdo al estado de la hoja (sana e infectada) y divididas utilizando la proporción de 70% de entrenamiento y un 30% para prueba, además estas fueron tomadas en formato JPG, las imágenes cuentan con una dimensión final de 255x255 píxeles.



**Gráfico 3.2.4** Separación del conjunto de datos de entrenamiento y de pruebas.

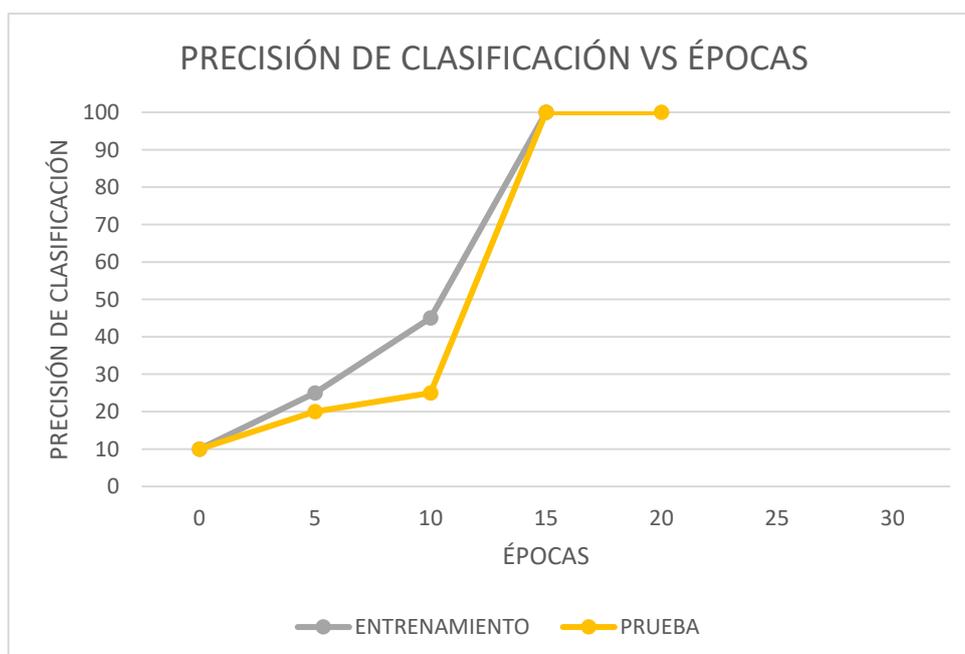
**Fuente:** Los autores.



**Gráfico 3.2.5** Distribución por cantidad de imágenes del total del conjunto de datos.

**Fuente:** Los autores.

Para la debida construcción del modelo se utilizó la librería Tensorflow, la cual permite aplicar funciones matemáticas para el procesado de los datos y el entrenamiento del modelo. Con la implementación de la arquitectura InceptionV3 y la transferencia de conocimiento de imágenes del conjunto de datos se logró identificar las hojas sanas e infectadas de las hojas de café robusta, con una precisión de 95% para el conjunto de entrenamiento.



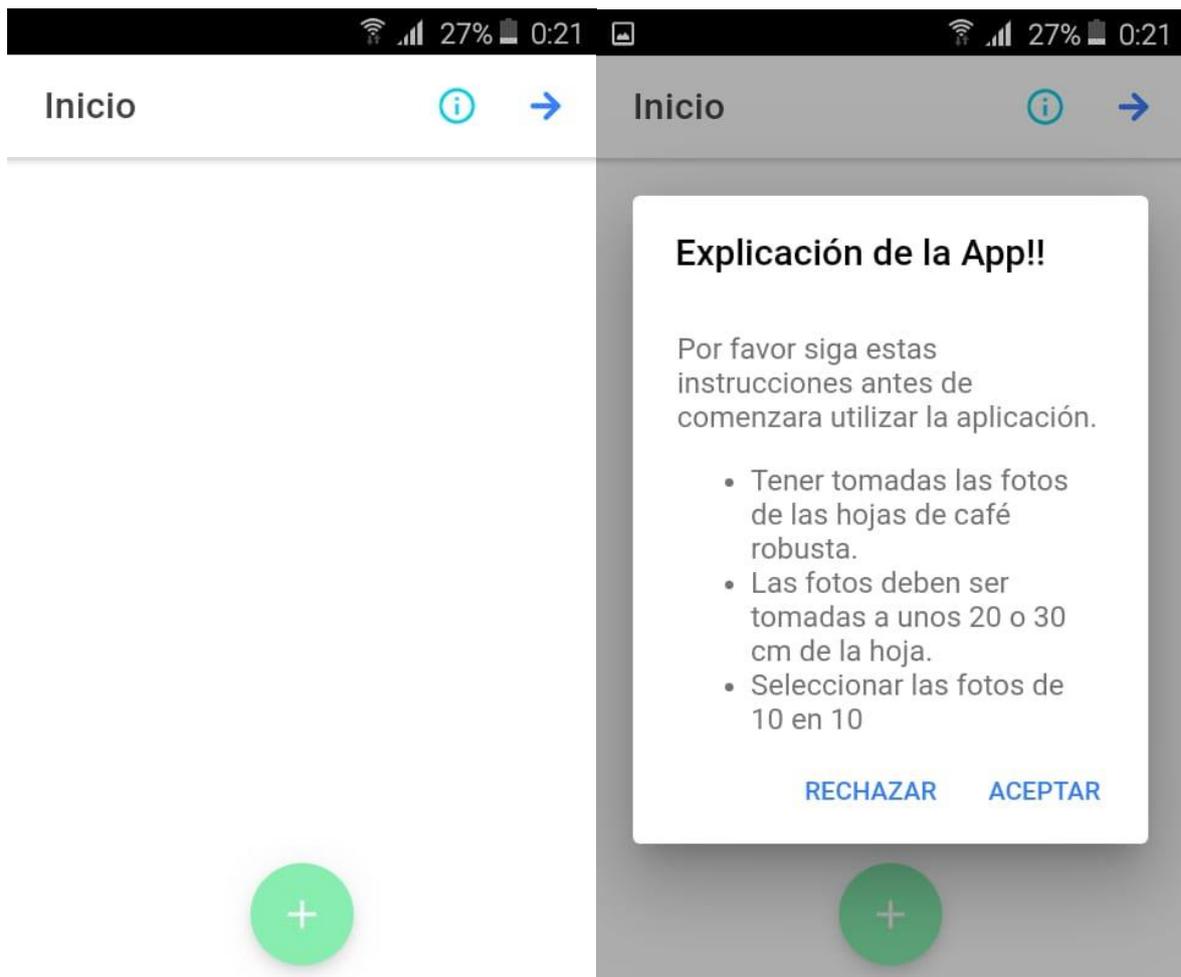
En el entrenamiento del algoritmo se pudo obtener valores superiores a 95% luego de ser entrenado en 20 épocas de 20 iteraciones. En la figura (precisión vs épocas) se observa la precisión de clasificación vs épocas del algoritmo en entrenamiento y prueba. Se muestra en gris los valores obtenidos a partir de las imágenes de entrenamiento y en naranja los resultados obtenidos para las imágenes de prueba. Se puede observar en el grafico que el algoritmo obtiene valores superiores a 95% en los dos casos luego de ser entrenado en 20 épocas de 20 iteraciones. En el caso de las imágenes de prueba se llega a un máximo de 90% luego de 20 épocas y en las imágenes entrenamiento se llega a un máximo de 98% después de 20 épocas de 20 iteraciones. Además, la gráfica muestra que en cierto punto la línea de entrenamiento cae, esto sucede debido a que las imágenes de prueba pueden sufrir sobre entrenamiento (overfitting) en el conjunto de imágenes.

### **3.3. DESARROLLO LA INTERFAZ DE USUARIO Y EL CÓDIGO FUENTE DE LA APLICACIÓN MÓVIL**

#### **3.3.1. DISEÑO**

En esta fase se considerarán propuestas de la metodología de desarrollo. Se realizará el diseño y modelado de la base de datos y de la interfaz de usuario de la aplicación. Se buscará que la misma sea una interfaz sencilla y entendible para el usuario ya que esta aplicación está orientada al área agrícola. En el modelo de la base de datos estarán reflejados los datos fenotípicos e imágenes para el desarrollo de la aplicación centrándose y apreciando el desarrollo orientado a objetos.

En este apartado se elaboró el diseño de la aplicación móvil en la que como primera vista muestra el inicio de la aplicación y las indicaciones que debe tener en cuenta los usuarios de la aplicación móvil.



**Ilustración 3.3.1.2** Diseño de la aplicación móvil de detección y clasificación de "la roya".  
**Fuente:** Los autores.

A continuación, una pantalla para cargar fotos o hacer una toma de la hoja de café para el procesamiento de la misma. Al presionar el botón carga de fotos la aplicación mandara al usuario a una vista donde estarán todas las fotos que ya estén cargadas en el teléfono, para el debido procesamiento de la foto seleccionada, por otro lado, al presionar el botón de toma de fotos, la aplicación dirigirá al usuario a la cámara del teléfono para la debida captura de la imagen en el cual la aplicación mostrara si la hoja está sana o infectada.

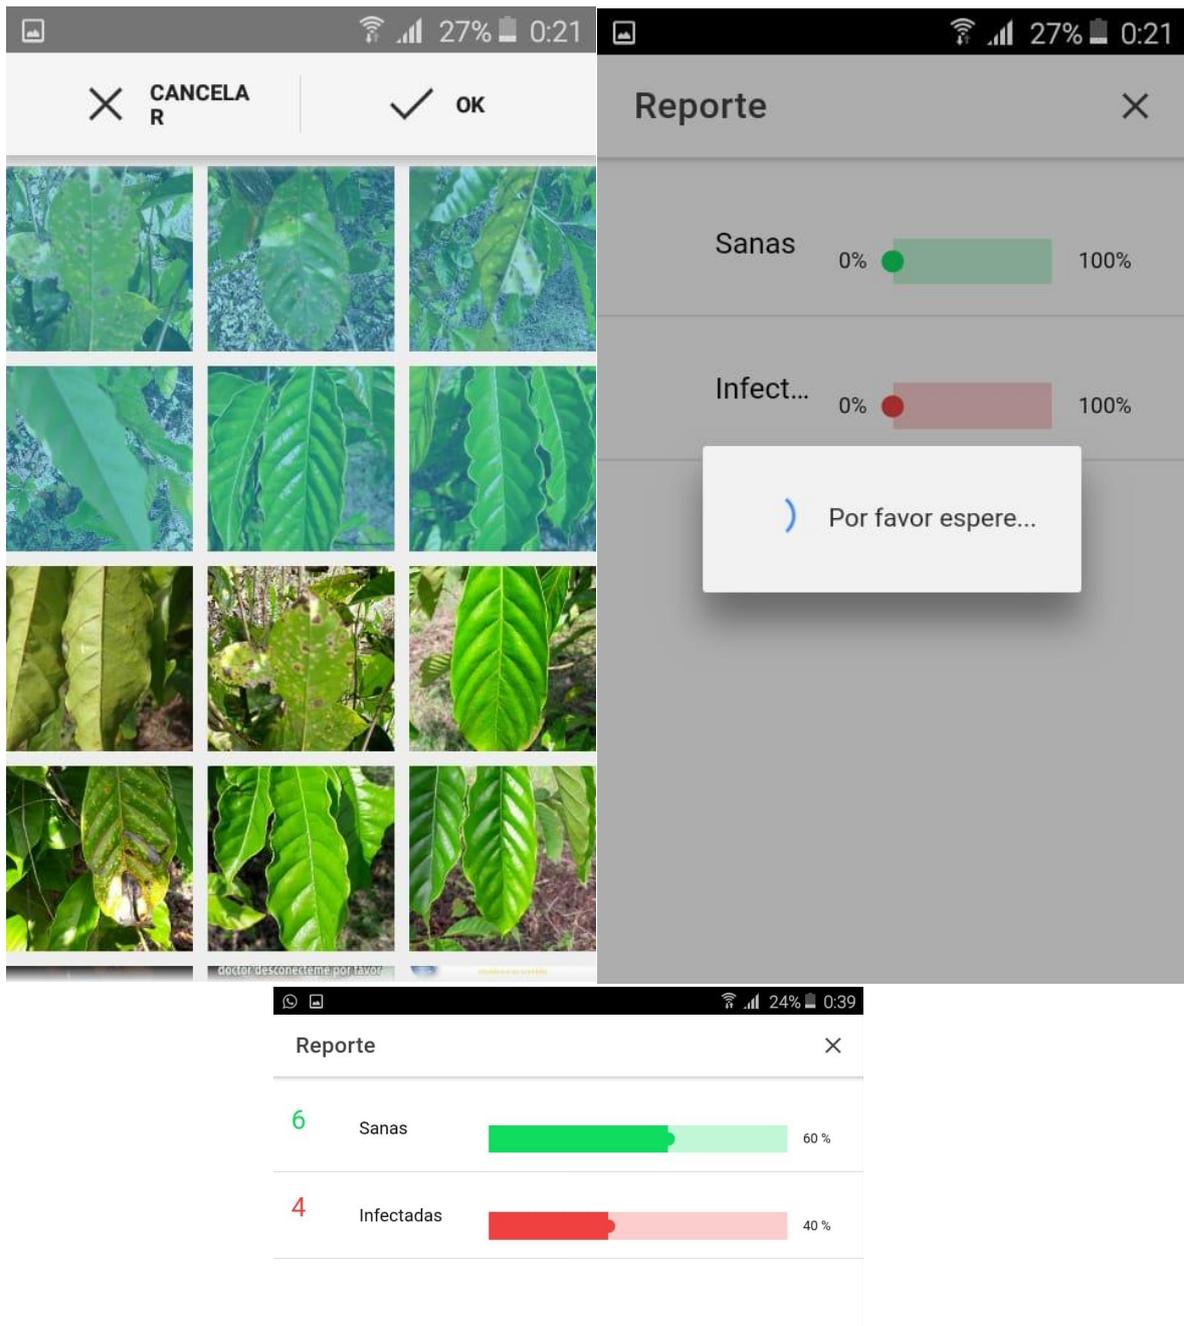


Ilustración 3.2.2.3 Interfaz de la aplicación móvil de detección y clasificación de "la roya".

Fuente: Los autores.

### 3.3.2. CODIFICACIÓN

En lo que corresponde a la fase de codificación en la metodología de desarrollo para la aplicación móvil de detección y clasificación de "la roya" se usó el lenguaje de programación Python para la parte del backend, además se integró la librería Tensorflow la cual permitió interactuar con el algoritmo de aprendizaje automático con el que se creó, entreno e implemento. En la parte del frontend, se usó el framework Ionic para la vista de la aplicación móvil, ya que Ionic es una

herramienta para crear aplicaciones híbridas, la cual tuvo la integración con el lenguaje de programación Python en conjunto con la librería de visión por computador Tensorflow.

### **3.4. IMPLEMENTACIÓN DE LA APLICACIÓN MÓVIL DE DETECCIÓN Y CLASIFICACIÓN DE “LA ROYA”.**

#### **3.4.1. PRUEBAS**

Al ser las funcionalidades de la aplicación no tan extensas, no se harán test que analicen partes de la misma, sino que las pruebas de funcionalidades generales que se realizarán para así poder determinar algún error y poder corregirlo a tiempo antes entregar la aplicación móvil, pruebas de funcionamiento las cuales deberá cumplir la aplicación como tal, el proceso de pruebas de funcionamiento se la hará cuando se tenga la integración de la misma es decir la interfaz de usuario en conjunto con la codificación e implementación del algoritmo de aprendizaje automático obteniendo los resultados esperados.

#### **3.4.2. VALIDACIÓN DE LOS RESULTADOS**

Para comprobar el correcto funcionamiento del algoritmo de clasificación se utilizará una porción del conjunto de datos, concretamente el conjunto de validación. El conjunto de validación contendrá imágenes de hojas de café extraídas de otras parcelas con similares características que las usadas en CIIDEA. Una vez culminado el modelo de clasificación de la roya, se llevarán a cabo pruebas y con los resultados de esta, se creará la matriz de confusión sobre la que se calcularán métricas de calidad de usadas en problemas de reconocimiento de patrones. Entre las métricas que se esperan consideran están: Sensibilidad, Especificidad, Precisión, Exactitud y F-measure. Con ellas, se busca cuantificar la capacidad obtenida por el algoritmo de clasificación para detectar la roya en hojas de café robusta.

Con las 20 iteraciones ejecutadas a partir del entrenamiento se realizó la respectiva evaluación de cada modelo en una matriz de confusión y calculando la métrica de evaluación de exactitud (accuracy), obteniendo valores de exactitud superiores a 87%, en la siguiente tabla se observa los modelos con su respectiva exactitud.

**Tabla 3.4.2.1** Iteraciones y su porcentaje de exactitud obtenidas en la validación del conjunto de datos.

ITERACIÓN	1	2	3	4	5	6	7	8	9	10
EXACTITUD	92%	87%	91%	91%	96%	94%	93%	93%	92%	92%

Fuente: Los autores.

**Tabla 3.4.2.2** Iteraciones y su porcentaje de exactitud obtenidas en la validación del conjunto de datos

ITERACIÓN	11	12	13	14	15	16	17	18	19	20
EXACTITUD	97%	93%	92%	92%	92%	94%	95%	95%	93%	92%

Fuente: Los autores.

Se puede observar que la exactitud más baja es de 87% en la iteración 2 y la más alta es de 97% en la iteración 11, por cada iteración se generó una matriz de confusión en la que se sacó los verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP) y falsos negativos (FN), con base en esto se calculó la exactitud (Accuracy) mediante la fórmula de la misma, a continuación, se muestra la matriz de confusión y el cálculo de exactitud para el modelo 11.

**Tabla 3.4.2.1.** Matriz de confusión implementada a los valores obtenidos en la validación del conjunto de datos de prueba.

MATRIZ DE CONFUSIÓN		CLASE PREDICHA	
		POSITIVO	NEGATIVO
CLASE REAL	POSITIVO	90	4
	NEGATIVO	2	86

Fuente: Los autores.

$$Exactitud = \frac{90 + 86}{90 + 86 + 2 + 4} = 0,97$$

**Ecuación 3.4.3** Formula de exactitud (Accuracy) implementada en los valores obtenidos de la iteración 11.

Fuente: Los autores.

Se puede observar que el algoritmo obtuvo 90 predicciones correctas de hojas sanas de 94 y 86 predicciones correctas con roya de 88 imágenes, esto quiere decir que este modelo es bueno en clasificar entre hojas sanas y con roya, además todo esto dio una exactitud de 97% siendo el porcentaje más alto entre el resto de modelos.

# CAPÍTULO IV. CONCLUSIONES Y RECOMENDACIONES

## 4.1. CONCLUSIONES

- Se obtuvo un 97% de efectividad en la detección y clasificación de “la roya” en las hojas de café robusta y donde de las iteraciones ejecutadas se obtuvo un promedio del 93% de efectividad.
- Se obtuvieron imágenes de las hojas de café robusta (sanas e infectadas) las mismas que fueron renombradas y procesadas, el renombramiento se lo realizó mediante Bulk Rename Utility y el pre procesamiento se lo efectuó utilizando la herramienta Labelbox, la conformación y la obtención de las imágenes permitió formar el conjunto de datos (dataset) que sirvió para entrenar el algoritmo.
- Se realizó la revisión bibliográfica en la que se buscó información relacionada con el presente trabajo, toda esta indagación permitió llegar a la conclusión de utilizar las redes neuronales convolucionales, ya que estas son aquellas que se usan mayormente en el procesamiento de imágenes.
- Para llevar a cabo el desarrollo de la aplicación móvil se hizo uso de la metodología ágil XP, tomando en cuenta tres de sus cuatro fases que son diseño, codificación y prueba, teniendo así un buen desarrollo y llegar a un producto de calidad de una manera eficiente, además entendible, agradable y eficaz para el usuario final.
- Al finalizar el desarrollo de la aplicación móvil fue necesario validar las entradas, corroborar el correcto funcionamiento de los procesos y comprobar las salidas que sean las esperadas por los usuarios, usando métricas de exactitud (accuracy) para evaluar el modelo de clasificación utilizado.

## 4.2. RECOMENDACIONES

- La obtención de imágenes es una parte fundamental para dar inicio a una aplicación basada en aprendizaje automático, además, es importante tener en cuenta la resolución de la imagen, es decir, que todas las imágenes tengan la misma resolución y distancia de captura para poder obtener una fotografía de buena calidad; también es necesario hacer uso de herramientas que faciliten el etiquetado y renombramiento de las imágenes.
- Elegir el tipo de red neuronal a utilizar es muy importante ya que es la red la cual va a permitir el buen procesamiento de las imágenes, además utilizar redes pre-entrenados es de gran ayuda ya que permitió ahorrar recursos a nivel computacional.
- Es fundamental tomar en cuenta una metodología de desarrollo ágil al momento de desarrollar un software, que permita llevar de manera organizada todo el proceso que requiere realizar este tipo de aplicación, además es importante ya que permite obtener un producto final de calidad.
- Es necesario la utilización de métricas (accuracy), para evaluar los modelos de clasificación utilizados, verificar que los datos ingresados y que los resultados obtenidos sean los esperados.

## BIBLIOGRAFÍA

- Ahmed, M., & Ibrahim, R. (2015). *A Comparative Study of Web Application Testing and Mobile Application Testing*. [https://doi.org/10.1007/978-3-319-07674-4\\_48](https://doi.org/10.1007/978-3-319-07674-4_48)
- Al Bashish, D., Braik, M., & Bani-Ahmad, S. (2010). A framework for detection and classification of plant leaf and stem diseases. *Proceedings of the 2010 International Conference on Signal and Image Processing, ICSIP 2010*, 113–118. <https://doi.org/10.1109/ICSIP.2010.5697452>
- Amara, J., Bouaziz, B., & Algergawy, A. (2017). A Deep Learning-based Approach for Banana Leaf Diseases Classification. *Btw*, 79–88.
- Andrade Vera, J. A. (2018). *Aplicación móvil para la detección y tratamiento de daños de los cultivos de la parroquia Taura del cantón Durán, mediante el uso de software de análisis de imagen basado en técnicas de machine learning*. (Universidad Católica de Santiago de Guayaquil). Retrieved from <http://repositorio.ucsg.edu.ec/handle/3317/11769>
- Antonio, J., Hernández, E., Lissette, K., Martinez, S., & Muñiz, A. J. (2014). *Sistema de Control Agrícola*. 1–10.
- Asefpour Vakilian, K., & Massah, J. (2013). An artificial neural network approach to identify fungal diseases of cucumber (*Cucumis sativus* L.) plants using digital image processing. *Archives of Phytopathology and Plant Protection*, 46(13), 1580–1588. <https://doi.org/10.1080/03235408.2013.772321>
- Ashqar, B. A. M., & Abu-naser, S. S. (2018). *Image-Based Tomato Leaves Diseases Detection Using Deep Learning*. 2(12), 10–16.
- B, A. D. C., Estuar, M. R. E., & Leon, M. M. De. (2019). *Intelligent Systems and Applications* (Vol. 869). <https://doi.org/10.1007/978-3-030-01057-7>
- Berger, J., Preussler, C., & Agostini, J. P. (2018). *Identificación de síntomas de Huanglongbing en hojas de cítricos mediante técnicas de deep learning*. 90–103. Retrieved from <http://47jaiio.sadio.org.ar/sites/default/files/CAI-12.pdf>
- Borja, Y. (2013). *Metodología Ágil de Desarrollo de Software – XP*. 10. <https://doi.org/10.1103/PhysRevB.74.214409>
- Brahimi, M., Boukhalifa, K., & Moussaoui, A. (2017). Deep Learning for Tomato Diseases: Classification and Symptoms Visualization. *Applied Artificial Intelligence*, 31(4), 299–315. <https://doi.org/10.1080/08839514.2017.1315516>
- Bulk Rename Utility. (2013). Introducción. Retrieved from [https://www.bulkrenameutility.co.uk/Main\\_Intro.php](https://www.bulkrenameutility.co.uk/Main_Intro.php)
- Canziani, A., Culurciello, E., & Paszke, A. (2017). *An Analysis of Deep Neural Network Models for Practical Applications*. 1–7.

- Comision pastoral de movilidad humana. (2013). *La roya del café*. (2), 1–24.
- Developers, G. (2019). *Clasi cación : Exactitud*. 90–91.
- Durmus, H., Gunes, E. O., & Kirci, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. *2017 6th International Conference on Agro-Geoinformatics, Agro-Geoinformatics 2017*.  
<https://doi.org/10.1109/Agro-Geoinformatics.2017.8047016>
- Escuela Superior Politécnica Agropecuaria de Manabí, E. M. (2018). Historia, Misión y Visión de la Universidad. Retrieved from [www.espam.edu.ec](http://www.espam.edu.ec)
- ESPAM MFL (Escuela Superior Politécnica Agropecuaria de Manabí). (2018). *Reglamento para la conformación de Grupos de Investigación*. Calceta.
- Galvis, J. P. . (2017). *Evaluación de un método de Aprendizaje Supervisado para la detección de las enfermedades, Antracnosis y Phytophthora Infestans en cultivos de fruta de Risaralda (Doctoral dissertation, Universidad Tecnológica de Pereira)*.
- Google. (2019). Guía avanzada de Inception v3 para Cloud TPU. Retrieved from <https://cloud.google.com/tpu/docs/inception-v3-advanced?hl=es-419>
- Guiné, R. P. F., Barroca, M. J., Gonçalves, F. J., Alves, M., Oliveira, S., & Mendes, M. (2015). Artificial neural network modelling of the antioxidant activity and phenolic compounds of bananas submitted to different drying treatments. *Food Chemistry*, *168*, 454–459.  
<https://doi.org/10.1016/j.foodchem.2014.07.094>
- Ha, J. G., Moon, H., Kwak, J. T., Hassan, S. I., Dang, M., Lee, O. N., & Park, H. Y. (2017). Deep convolutional neural network for classifying Fusarium wilt of radish from unmanned aerial vehicles. *Journal of Applied Remote Sensing*, *11*(04), 1. <https://doi.org/10.1117/1.jrs.11.042621>
- Ishak, S., Rahiman, M. H. F., Kanafiah, S. N. A. M., & Saad, H. (2015). Leaf disease classification using artificial neural network. *Jurnal Teknologi*, *77*(17), 109–114. <https://doi.org/10.11113/jt.v77.6463>
- Johannes, A., Picon, A., Alvarez-Gila, A., Echazarra, J., Rodriguez-Vaamonde, S., Navajas, A. D., & Ortiz-Barredo, A. (2017). Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case. *Computers and Electronics in Agriculture*, *138*, 200–209.  
<https://doi.org/10.1016/j.compag.2017.04.013>
- Katkamwar, N., Kumar, B., & Kalaskar, K. (2013). *an Expert System Approach for Improvement of Agriculture Decision*. *5*(1), 8–12.
- Kim, K. B. W. R., Choi, J. S., Kim, D. H., Sunwoo, C., Jung, S. A., Kim, H. J., ... Ahn, D. H. (2012). Effect of autoclave and microwave treatments on quality of bread. *Journal of the Korean Society of Food Science and Nutrition*, *41*(5), 681–686. <https://doi.org/10.3746/jkfn.2012.41.5.681>
- Lasso, E., Thamada, T. T., Meira, C. A. A., & Corrales, J. C. (2015). *Graph Patterns as Representation of Rules Extracted from Decision Trees for Coffee Rust Detection*. [https://doi.org/10.1007/978-3-319-24129-6\\_35](https://doi.org/10.1007/978-3-319-24129-6_35)

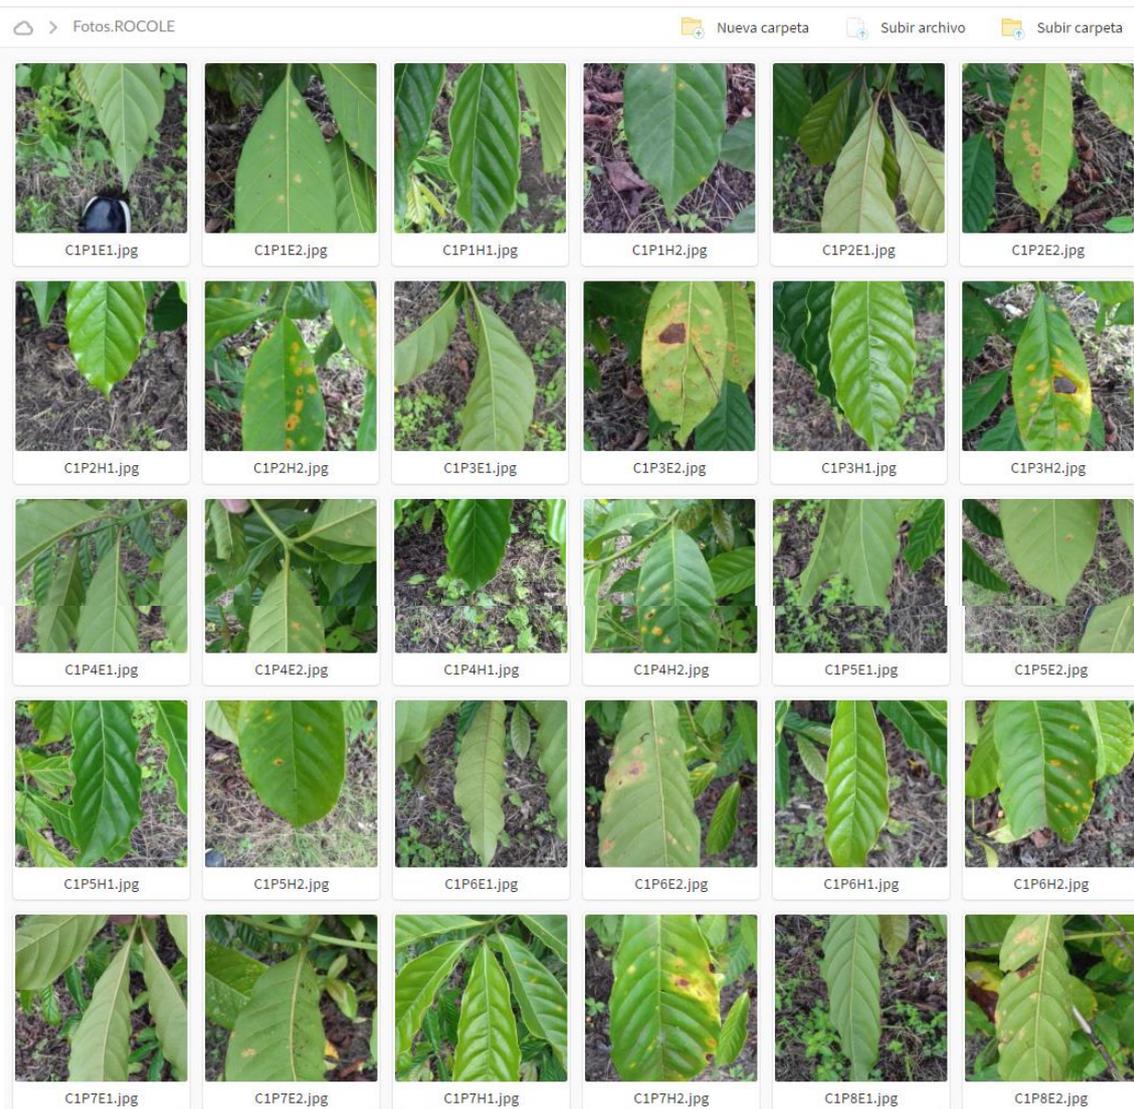
- Lin, Z., Mu, S., Huang, F., Mateen, K. A., Wang, M., Gao, W., & Jia, J. (2019). A unified matrix-based convolutional neural network for fine-grained image classification of wheat leaf diseases. *IEEE Access*, 7, 11570–11590. <https://doi.org/10.1109/ACCESS.2019.2891739>
- Loncomilla, P. (2018). *Deep learning: Redes convolucionales*. Retrieved from <https://ccc.inaoep.mx/~pgomez/deep/presentations/2016Loncomilla.pdf>
- Lorente, D., Gómez, J., Aleixos, N., Cubero, S., Oscar, L., Serrano, A., ... Blasco, J. (2011). *Selection of optimal wavelength features for decay detection in citrus fruit using the ROC curve*. 6, 530–541. <https://doi.org/10.1007/s11947-011-0737-x>.The
- Martins, S. J., Soares, A. C., Medeiros, F. H. V., Santos, D. B. C., & Pozza, E. A. (2015). Contribution of host and environmental factors to the hyperparasitism of coffee rust under field conditions. *Australasian Plant Pathology*, 44(6), 605–610. <https://doi.org/10.1007/s13313-015-0375-2>
- Melo, A., Mathias, I. M., Dias, H., Submiss, D., Aceita, D., Tais, I., & Concluiu, A. (2015). *Uso de Redes Neurais Artificiais para o reconhecimento autom ático do O í dio da Soja via smartphone com o aux í lio da biblioteca OpenCv*.
- Mitchell, T. M., Carbonell, J. G., & Michalski, R. S. (1986). *Machine Learning*. <https://doi.org/10.1007/978-1-4613-2279-5>
- Muthukannan, K., Latha, P., Pon Selvi, R., & Nisha, P. (2015). Classification of diseased plant leaves using neural network algorithms. *ARP Journal of Engineering and Applied Sciences*, 10(4), 1913–1919.
- Naik, H. S., Zhang, J., Lofquist, A., Assefa, T., Sarkar, S., Ackerman, D., ... Ganapathysubramanian, B. (2017). A real-time phenotyping framework using machine learning for plant stress severity rating in soybean. *Plant Methods*, 13(1), 1–12. <https://doi.org/10.1186/s13007-017-0173-7>
- Omrani, E., Khoshnevisan, B., Shamshirband, S., Saboohi, H., Anuar, N. B., & Nasir, M. H. N. M. (2014). Potential of radial basis function-based support vector regression for apple disease detection. *Measurement*, 55, 512–519. <https://doi.org/10.1016/j.measurement.2014.05.033>
- Organización de la Naciones Unidas para la Alimentación y la Agricultura. (2016). *EL estado mundial de la agricultura y la alimentación*. <https://doi.org/0251-1371>
- P-salazar, J., Sánchez-delacruz, E., & Biswal, R. R. (2018). *Clasificación de clorosis en hojas de árboles de naranja mediante aprendizaje automático Classification of Chlorosis in Leaves of Orange Trees Using Machine Learning*. 147(5), 185–195.
- Parraga-Alava, J., Cusme, K., Loor, A., & Santander, E. (2019). RoCoLe: A robusta coffee leaf images dataset for evaluation of machine learning based methods in plant diseases recognition. *Data in Brief*, 104414. <https://doi.org/10.1016/j.dib.2019.104414>

- Pereira, L. A. M., Nakamura, R. Y. M., de Souza, G. F. S., Martins, D., & Papa, J. P. (2012). Aquatic weed automatic classification using machine learning techniques. *Computers and Electronics in Agriculture*, *87*, 56–63. <https://doi.org/10.1016/j.compag.2012.05.015>
- Picazo, O., y Baumela, L. (2018). *Redes neuronales convolucionales profundas para el reconocimiento de emociones en imágenes*. Retrieved from [http://oa.upm.es/51441/1/TFM\\_OSCAR\\_PICAZO\\_MONTOYA.pdf](http://oa.upm.es/51441/1/TFM_OSCAR_PICAZO_MONTOYA.pdf)
- Pinto, N. G. M., Rossato, V. P., Coronel, D. A., & Schuh, A. B. (2018). The performance of agriculture in latin america: analysing efficiency and efficacy in the region. *Revista Facultad de Ciencias Económicas*, *26*(2), 33–44. <https://doi.org/10.18359/rfce.2775>
- Quintero, C., Merchán, F., Cornejo, A., & Galán, J. S. (2018). Uso de Redes Neuronales Convolucionales para el Reconocimiento Automático de Imágenes de Macroinvertebrados para el Biomonitorio Participativo. *KnE Engineering*, *3*(1), 585. <https://doi.org/10.18502/keg.v3i1.1462>
- Ramya, V., & Lydia, M. A. (2016). Leaf Disease Detection and Classification using Neural Networks. *International Journal of Advanced Research in Computer and Communication Engineering*, *5*(11), 207–210. <https://doi.org/10.17148/IJARCCE.2016.51144>
- Redolfi, J. (2018). *Aplicación en agricultura de precisión de esquemas actuales de reconocimiento visual*.
- Rodríguez, J. P., Girón, E. J., Corrales, D. C., & Corrales, J. C. (2018). A *Guideline for Building Large Coffee Rust Samples Applying Machine Learning Methods*. [https://doi.org/10.1007/978-3-319-70187-5\\_8](https://doi.org/10.1007/978-3-319-70187-5_8)
- Sannakki, S. S., Rajpurohit, V. S., Nargund, V. B., & Kulkarni, P. (2013). *Diseases using Neural Networks* ". 3–7.
- Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., & Stefanovic, D. (2016). Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification. *Computational Intelligence and Neuroscience*, *2016*. <https://doi.org/10.1155/2016/3289801>
- Sun, X., Mu, S., Xu, Y., Cao, Z., & Su, T. (2019). *Image Recognition of Tea Leaf Diseases Based on Convolutional Neural Network*. Retrieved from <http://arxiv.org/abs/1901.02694>
- Tan, W., Zhao, C., & Wu, H. (2016). Intelligent alerting for fruit-melon lesion image based on momentum deep learning. *Multimedia Tools and Applications*, *75*(24), 16741–16761. <https://doi.org/10.1007/s11042-015-2940-7>
- Velázquez-López, N., Sasaki, Y., Nakano, K., Mejía-Muñoz, J. M., & Romanchik Kriuchkova, E. (2011). Detección de cenicilla en rosa usando procesamiento de imágenes por computadora. *Revista Chapingo. Serie Horticultura*, *17*(2), 151–160. Retrieved from [http://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1027-152X2011000200008&lng=es&nrm=iso&tlng=es](http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1027-152X2011000200008&lng=es&nrm=iso&tlng=es)

- Vera Cruz, C. (2013). Roya del Cafeto (Hemileia Vastatrix). Retrieved from <http://www.cesvver.org.mx/roya-del-cafe-hemileia-vastatrix/>
- Vinogradov, G. M. (2015). Diseño e implementación de un sistema de detección de malezas en cultivos Cundiboyacenses. *Nhk技研*, 151, 10–17. <https://doi.org/10.1145/3132847.3132886>
- Wang, G., Sun, Y., & Wang, J. (2017). Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning. *Computational Intelligence and Neuroscience*, 2017. <https://doi.org/10.1155/2017/2917536>
- Yang, W., Jia, L., & Wang, G. (2015). *Application Streaming: A Mobile Application Distribution Method*. [https://doi.org/10.1007/978-3-319-27119-4\\_21](https://doi.org/10.1007/978-3-319-27119-4_21)
- Zhang, X., Qiao, Y., Meng, F., Fan, C., & Zhang, M. (2018). Identification of maize leaf diseases using improved deep convolutional neural networks. *IEEE Access*, 6, 30370–30377. <https://doi.org/10.1109/ACCESS.2018.2844405>
- Zhang, Y., & Hu, J. (2019). Development of Mobile Application for Higher Education: An Introduction. In *Handbook of Mobile Teaching and Learning* (pp. 1–6). [https://doi.org/10.1007/978-3-642-41981-2\\_15-2](https://doi.org/10.1007/978-3-642-41981-2_15-2)
- Zuleyka, D., Carretero, R., Donato, A. :, Flores, A., Gonzalo, E., & Padín, C. (2018). *Diagnóstico automático de roya amarilla en hojas de cafeto aplicando técnicas de procesamiento de imágenes y aprendizaje de máquina*. 104. <https://doi.org/10.1109/JSSC.2011.2163214>

# **ANEXOS**

**ANEXO 1. CONJUNTO DE DATOS DE LAS IMÁGENES OBTENIDAS EN  
LAS PARCELAS DEL CIIDEA DE LA ESPAM MFL.**



**Anexo 1** Conjunto de datos de las imágenes obtenidas en las parcelas del CIIDEA en la ESPAM MFL  
**Fuente:** Los autores

**ANEXO 2. TABLA DE REVISIÓN BIBLIOGRÁFICA**

TABLA DE RESUMEN DE LA REVISIÓN BIBLIOGRAFICA						
N°	AÑO	TITULO	TIPO DE RED UTILIZADA	DESCRIPCIÓN DEL PAPER	PORCENTAJE DE EFECTIVIDAD DEL ALGORITMO	ENFERMEDAD/PLAGAS
1	2019	Image Recognition of Tea Leaf Diseases Based on Convolutional Neural Network (Sun et al., 2019).	Convolutional Neural Network	Este trabajo se centra en el reconocimiento de hojas enfermas de té, basada en la red neuronal convolucional, en el que se incluyen 7 enfermedades foliares, en este trabajo, las funciones de activación de la capa convolucional y la capa totalmente conectada es ReLU. La arquitectura de la red utilizada tiene 9 capas, que contiene 2 capas de convolución, 2 capas de agrupación, 2 capas de normalización de respuesta parcial, 2 capas de conexión completa y 1 capa de salida de clasificación.	93.75%	Enfermedades en hoja de té
2	2019	Investigating Input Protocols, Image Analysis, and Machine Learning Methods for an Intelligent Identification System of Fusarium Oxysporum Sp. in Soil Samples (B et al., 2019).	Convolutional Neural Network	Este artículo hace experimentos comparando dos métodos de aprendizaje en el que los resultados de los experimentos utilizan 64 × 64 entradas de imagen de tamaño 64 píxeles. Así mismo, se observaron los tiempos de procesamiento como 45.46min, y 15 s. Los experimentos con las entradas de imagen más pequeños de 32 × 32 dimensiones de 32 pixel, quedando demostrado que las imágenes con pequeñas resoluciones dan un mayor porcentaje de efectividad.	81,12%	Fusarium oxysporum Sp. en suelo
3	2018	Image-Based Tomato Leaves Diseases Detection Using Deep	Convolutional Neural Network	Esta red está compuesta por seis clases de las cuales cinco son las enfermedades y la hoja sana. El modelo usado consta de dos	99,84%	Enfermedad en hojas de tomate: mancha bacteriana, tizón

		Learning (Ashqar & Abu-naser, 2018).		partes: La primera parte del modelo (extracción de características), que es el mismo para el enfoque a todo color y en escala de grises, consta de 4 convoluciones, capas con función de activación relu, cada uno seguido por Max Pooling layer. La segunda parte después de la capa plana contiene dos capas densas para ambos enfoques, pero a todo color. El primero tiene 256 unidades ocultas, por otro lado, el enfoque de escala de grises tiene 128 unidades ocultas en la primera capa, se redujo el tamaño de la red de escala de grises para evitar el sobreajuste, la última capa tiene Softmax como activación y 6 salidas que representan las 6 clases.		temprano, Mancha Septorial, Molde foliar, Yellow Leaf Curl Virus.
4	2018	Identification of Maize Leaf Diseases Using Improved Deep Convolutional Neural Networks (X. Zhang et al., 2018).	Convolutional Neural Network	La red contiene tres capas convolucionales, dos capas totalmente conectadas, y una capa de pérdida. Después de cada capa convolucional en el modelo, hay una capa puesta en común y una operación Relu. Además, esta investigación hace la comparación de la tasa de aprendizaje entre el modelo GoogLeNet y Cifar10. Para el modelo Cifar10 la tasa de aprendizaje de este modelo es fijo en 0,0002. Mientras que para el modelo GoogLeNet la tasa de aprendizaje es 0,001.	98,9%	Enfermedades en la hoja de maíz: Curvularia, mosaico enano, mancha de la hoja gris, tizón de la hoja del Norte, mancha marrón, punto redondo, óxido y tizón de la hoja del sur
5	2018	A Unified Matrix-Based Convolutional Neural Network for Fine-Grained Image Classification	Convolutional Neural Network	La clasificación de las enfermedades de los cultivos se ve afectada por varias interferencias visuales, entre ellas la falta de	96.5%	Enfermedades de la hoja de trigo de invierno

		of Wheat Leaf Diseases (Lin et al., 2019).		iluminación, el rocío y las fluctuaciones de los equipos. Para abordar este desafío, se propuso una red neuronal convolucional unificada (CNN) que denota la red neuronal convolucional basada en matriz (M-bCNN). Su sello distintivo es la matriz de núcleo convolucional, cuyas capas convolucionales se organizan paralelamente en forma de matriz y se integran con DropConnect, unidad lineal exponencial, normalización de la respuesta local, etc., para eliminar el gradiente excesivo y desvanecido.		
6	2018	Aplicación móvil para la detección y tratamiento de daños de los cultivos de la parroquia Taura del cantón Durán, mediante el uso de software de análisis de imagen basado en técnicas de machine Learning (Andrade Vera, 2018).	Convolutional Neural Network	La aplicación proporcionó un detector visual a través de la cámara que identifica si la planta enfocada posee alguna plaga presente consultando con su red neuronal entrenada con ejemplos de un número seleccionado de plagas por tipo de cultivo. El proyecto generará beneficios económicos a largo plazo mediante la recolección de datos del estado de los terrenos mediante GPS y el detector de plagas generando un historial del suelo para consultorías de empresas dedicadas a la actividad agrícola. Teniendo como datos de entrada 1000 imágenes de diferentes plantas utilizando el 80% del total de la imágenes para entrenamiento y el 20% restante para pruebas, además se hizo la utilización de la librería Tensor- Flow para la clasificación de las imágenes.	77.3% plagas	Antracnosis, <i>Botrytis</i> , Caracol, Cochinilla algodonosa, Cochinilla negra, <i>Hollin</i> , minador, Mosca blanca, <i>Oidio</i> , Oruga, Procesionaria pino, Pulgones, Roya

7	2018	Diagnóstico automático de roya amarilla en hojas de cafeto aplicando técnicas de procesamiento de imágenes y aprendizaje de máquina (Zuleyka et al., 2018).	Backpropagation (BP) networks, radial basis function (RBF) neural networks, generalized regression networks (GRNNs) y probabilistic neural networks	El presente trabajo de titulación de la Pontificia Universidad Católica de Perú que tiene como finalidad desarrollar un modelo algorítmico, que a través de métodos de procesamiento de imágenes y aprendizaje de máquina permitiese detectar si una hoja está infectada o no con Roya Amarilla, y en caso lo estuviese, cuantificar de forma automática el grado de severidad. El alcance del trabajo no contempla la separación del fondo de la imagen y la hoja, se asume que las hojas llegan segmentadas, el diagrama general que sigue este modelo algorítmico de diagnóstico automático de “la roya” es el siguiente: caracterización de las regiones sanas e infectadas de las hojas, clasificación automática utilizando aprendizaje de máquina de las regiones sanas e infectadas y la determinación automática del grado de severidad. Obteniendo como entradas las imágenes tomadas de las hojas de café, utilizando la librería OpenCV se genera el procesamiento de las imágenes de entradas y teniendo como salidas o resultados del procesamiento de las imágenes un grado en la escala de severidad.	90%	<i>Hemileia Vastatrix</i> - Roya del café
8	2018	Identificación de síntomas de <i>Huanglongbing</i> en hojas de cítricos mediante técnicas de deep Learning (Berger et al., 2018).	Redes neuronales artificiales convolucionales	En este trabajo se describe el desarrollo de una aplicación móvil que utiliza técnicas de deep learning para identificar síntomas de Huanglongbing y carencias nutricionales en hojas de árboles cítricos. Se evaluaron los	98.5%.	<i>Huanglongbing</i>

				modelos de aprendizaje por transferencia MobileNet e Inception utilizando Tensorflow y Python, al utilizar técnicas de aprendizaje automático como las redes neuronales convolucionales que permitió la clasificación de las imágenes de hojas de un conjunto de evaluación utilizando el modelo MobileNet, Inception extrae las características generales de las 1200 imágenes de entrada, donde 800 imágenes fueron de entrenamiento y 400 de pruebas utilizando una RNA convolucional y las clasifica en función de esas características con capas totalmente conectadas.		
9	2018	Clasificación de <i>clorosis</i> en hojas de árboles de naranja mediante aprendizaje automático (P-salazar, Sánchez-delacruz, & Biswal, 2018).	Perceptrón multicapa	Esta investigación propone evaluar un conjunto de clasificadores para su implementación en la detección de enfermedades usando características sintomáticas en hojas de árboles de naranja Valencia ( <i>Citrus Sinensis</i> ). El diagrama de flujo que sigue para llegar a obtener la clasificación se basa en los siguientes flujos de datos: la captura de las imágenes 60 sanas y 60 infectadas, el procesamiento de las imágenes, la obtención de características de las imágenes procesadas, la selección de las características obtenidas, la selección de criterios y modelos para empezar el entrenamiento teniendo 80 imágenes y 40 para pruebas, la selección del algoritmo basado en aprendizaje	89%	<i>Clorosis Variegada</i>

				automático para la clasificación, las pruebas de combinación de algoritmos y la evaluación general.		
10	2017	Deep Learning for Tomato Diseases: Classification and Symptoms Visualization (Brahimi et al., 2017).	CNN (Convolutional Neuronal Network)	Para analizar el modelo propuesto, se utilizó los métodos de visualización para comprender los síntomas y para localizar las regiones de la enfermedad en la hoja. En esta investigación se hizo uso de dos modelos de CNN (AlexNet y GoogleNet) de los cuales se hizo una comparación. La arquitectura de AlexNet tiene cinco capas de convoluciones con la función de activación RELU, Las imágenes de entrada de la red cambian de tamaño 256x256 píxeles, la capa de salida contiene nueve clases correspondientes a las enfermedades de las hojas del tomate.	99,18	Detección de nueve enfermedades en la hoja de tomate: Bacterial Spot, Early blight, Leaf Mold, Septoria spot, Spider mites, Target Spot, Mosaic virus, Yellow Leaf Curl Virus.
11	2017	Deep convolutional neural network for classifying Fusarium wilt of radish from unmanned aerial vehicles (Ha et al., 2017).	CNN (Convolutional Neuronal Network)	La arquitectura VGG-A es adoptada para distinguir Fusarium marchitamiento del rábano y rábano sano. Esta red consta de ocho capas de convolución y dos capas totalmente conectadas. La red original VGG-A toma imágenes de 224x224 de entrada. En este estudio las imágenes cuentan con un tamaño de 200x200 píxeles para la entrada de la red.	93,3%	Fusarium marchitamiento del rábano
12	2017	Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning (Wang et al., 2017).	CNN (Convolutional Neuronal Network)	Cada capa convolucional tiene 32 filtros de tamaño de 3x3, Unidades Rectificado Lineal de Activación (RELU), todas las capas vienen seguidas de una capa de 2x2 max-puesta en común, excepto para la última capa	90,4%	Podredumbre negra de la hoja de la manzana: Botryosphaeria obtusa

				convolucional, que tiene 64 filtros. La primera capa totalmente conectada tiene 64 unidades con una activación RELU y es seguido por una capa de deserción. La última capa totalmente conectada tiene cuatro salidas, que corresponde con las cuatro clases (fase sana, etapa temprana, etapa media y etapa final) que se alimentan en la capa softmax para calcular la salida de probabilidad.		
13	2017	Disease Detection on the Leaves of the Tomato Plants by Using Deep Learning (Durmus et al., 2017).	CNN (Convolutional Neuronal Network)	Este trabajo realiza la comparación de dos modelos AlexNet y SqueezeNet. AlexNet tiene cinco capas convolucionales, cada uno es seguido por la capa ReLU. La capa 5 se alimenta a la red totalmente conectada después de la agrupación. Las capas totalmente conectadas tienen capas de omisión. La última capa conectada tiene la clase probabilidades de entrada de la imagen. Las cuales son clasificadas por el clasificador softmax. Por otro lado, la arquitectura de SqueezeNet comienza con capa convolucional, seguida de ocho módulos de fuego, seguidos por capas convolucionales, y clasificador softmax.	95,6% AlexNet 95,3% SqueezeNet	Manchas bacterianas, tizón temprano, tizón tardío, moho foliar, mancha foliar de septoria, ácaros, mancha, virus del mosaico, virus del rizo de la hoja amarilla.
14	2017	A Deep Learning-based Approach for Banana Leaf Diseases Classification (Amara et al., 2017).	CNN (Convolutional Neuronal Network)	En este trabajo se utilizó la arquitectura de red del modelo LeNet en el cual se usó capas totalmente conectadas, donde cada neurona proporciona una conexión completa a todos los mapas de características aprendidas emitidos desde la	80%	Sigatoka de plátano y moteado de plátano

				capa anterior en la convolución. Estas capas conectadas se basan en la función de activación de softmax para calcular las puntuaciones de las clases. La entrada del clasificador softmax es un vector de las características resultantes del proceso de aprendizaje y la salida son una probabilidad de que una imagen pertenece a una clase dada.		
15	2017	A real-time phenotyping framework using machine learning for plant stress severity rating in soybean (Naik et al., 2017).	Árboles de decisión K-NN	El conjunto de datos se muestreó aleatoriamente en dos subconjuntos en una proporción de 75-25%. El subconjunto más grande (75%) sirvió como conjunto de entrenamiento, mientras que el subconjunto restante sirvió como conjunto de datos de prueba (25%). Además, evaluamos el rendimiento del clasificador en conjuntos de datos adicionales. Un conjunto de datos consistió en imágenes de material genético completamente diferente. Además, repetimos el experimento de campo en 2016 y utilizamos el clasificador entrenado en las imágenes de este experimento. El conjunto de datos de entrenamiento se usa para entrenar al clasificador, al aprender un mapeo del % Y y B con sus clasificaciones IDC esperadas. Posteriormente, el conjunto de datos de prueba se utiliza para estimar el rendimiento del modelo de clasificación,	96%	Haba - Soybean

				aplicándolo en el conjunto de datos de prueba para clasificar cada observación.		
16	2017	Evaluación de un método de Aprendizaje Supervisado para la detección de las enfermedades, <i>Antracnosis</i> y <i>Phytophthora Infestans</i> en cultivos de fruta de Risaralda (Galvis, 2017).	Perceptrón multicapas	La Universidad Tecnológica de Pereira Colombia presentó en una de sus tesis la evaluación de un método para detectar las enfermedades <i>Antracnosis</i> y <i>Phytophthora Infestans</i> en los cultivos de tomate, plátano y mora. Sin embargo, muchas de las enfermedades que se encuentran en las plantas requieren de un diagnóstico preciso del patógeno o patógenos que los causa, bien sea porque los síntomas que se producen en la planta sean variables o imprecisos que pueden dar lugar a confusión de la muestra o por el contrario diferentes patógenos causen un síntoma similar en la misma planta para ello se han desarrollado diferentes investigaciones sobre el reconocimiento de enfermedades en plantas, donde se han planteado metodologías basadas en visión por computador y aprendizaje de máquina: Las técnicas de K-Means, red neuronal pre-entrenada y otra técnica son los histogramas de color RGB, TSL, Lab donde se calcula una distancia estadística para obtener una función de separación entre la enfermedad; los métodos de orientation code matching (OCM), máquinas de soporte vectorial (SVMs) para detectar y reconocer las enfermedades en sus primeras etapas.	90%	<i>Antracnosis</i> y <i>Phytophthora Infestans</i>

17	2017	Automatic plant disease diagnosis using mobile capture devices, applied on a wheat use case (Johannes et al., 2017).	Redes neuronales convolucionales (CNN )	Este trabajo analiza el rendimiento de la identificación temprana de tres enfermedades endémicas del trigo en Europa: roya, septoria y mancha canela. El análisis se realizó utilizando 7 dispositivos móviles y más de 3500 imágenes capturadas en dos sitios piloto en España y Alemania durante 2014, 2015 y 2016. Los resultados obtenidos revelan métricas de AuC (Área bajo la Característica de Funcionamiento del Receptor – ROC – Curva) más altas de 0.80 para Todas las enfermedades analizadas en las pruebas piloto en condiciones reales.	90%	<i>Hemileia Vastatrix</i> Roya, <i>Septoria</i> y mancha canela en el trigo.
18	2016	Leaf Disease Detection and Classification using Neural Networks (Ramya & Lydia, 2016).	Back Programming	Este artículo propone un enfoque para la detección y clasificación de enfermedades foliares en plantas utilizando procesamiento de imágenes. El algoritmo presentado tiene tres pasos básicos: Pre procesamiento de imágenes y análisis, Caracterización de la extracción y reconocimiento de enfermedades de las plantas. El objetivo es detectar los síntomas de la enfermedad ocurrida en hojas de una forma precisa. Una vez que la imagen capturada está es procesada, las diversas propiedades de la hoja de la planta, como la intensidad, el color y el tamaño se extraen y se envían al clasificador SVM con la red neuronal de propagación Back para su clasificación.	92%	Enfermedades foliares en plantas de berenjena.

19	2016	Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification (Sladojevic et al., 2016).	CNN (Convolutional Neuronal Network)	Cada capa convolucional tiene los mapas de igual tamaño y un grano de tamaño se desplaza por determinada región de la imagen de entrada, la función de activación RELU se aplica después de la primera y segunda capa porque reduce 5 mejores tasas de error superiores a -1, dentro de una capa oculta las neuronas se segmentan en “mapas de características”, cada neurona en un mapa de característica busca la misma función, pero en diferentes posiciones de la imagen de entrada. Básicamente, el mapa de característica es el resultado de aplicar convolución a través de una imagen.	96,3%	13 enfermedades: Pear, Cherry, and peach, porosity. Peach, powdery mildew. Peach, Taphrina deformans Apple, pear, Erwinia amylovora, coffee, entre otras
20	2015	Artificial neural network modelling of the antioxidant activity and phenolic compounds of banana submitted to different drying treatments (Guiné et al., 2015).	Feed Forward	La red de este trabajo de investigación uso el método de entrenamiento de Levenberg Marquardt y Mean Squared Método de error (MSE) para la evaluación del desempeño. Esta red está compuesta por cuatro entradas (variedad, estado / método de deshidratación, tipo de extracto y orden de extracto) y una salida, para cada una de las variables por separado, la red está compuesta por una sola capa oculta con diez neuronas. Cabe recalcar que este estudio se lo realizo para dos clases de banana Musa nana y Musa cavendishii para ambos casos se tenían las mismas variables de entrada.	85%	<i>Actividad antioxidante y compuestos fenólicos</i>

21	2015	Intelligent alerting for fruit-melon lesion image based on momentum deep learning (Tan et al., 2016).	CNN (Convolutional Neuronal Network)	Esta red está compuesta por cinco capas de red convolucional. La capa de entrada de la red recibe una imagen de 28x28 pixeles conectada a cuatro convoluciones en las que cuentan con mapas de características, el primer mapa es de 24x24 pixeles, la siguiente convolución es de 12x12 y 8x8 y 4x4 consecutivamente. una arquitectura de “doble pirámide” se formó en la red de aprendizaje. Es decir que la función de mapa (F. Mapas) la resolución se reduce hacia atrás, mientras que su número aumenta hacia atrás. Para la red, la invariancia geométrica de la transformación se desarrolla mediante la reducción progresiva resolución mapa de características, y la consiguiente pérdida de información es compensada por la abundancia avanzar en cantidad.	97,5%	<i>Detección de lesiones de piel del melón</i>
22	2015	Uso de Redes Neurais Artificiais para o reconhecimento automático do Oídio da Soja via smartphone com o auxílio da biblioteca OpenCv (Melo et al., 2015).	Red Neuronal feed-forward	Este trabajo desarrollo una aplicación para el reconocimiento de Oídio de Soja. Se hizo uso del aprendizaje supervisado, y el algoritmo de entrenamiento basado en propagación hacia atrás. La topología fue 6-15-10, es decir, 6 neuronas de entrada representando las características, 15 en la capa oculta y 10 de salida, siendo ésta referente a los 10 posibles valores de severidad en el que el nivel 0 corresponde a la hoja sana y el nivel 9 el mayor grado de	90,75%	<i>Erysiphe diffusa – Oídio da soja-Oídio de la soya</i>

				afectación, de modo que sólo 1 se activa como resultado.		
23	2015	Leaf disease classification using artificial neural network (Ishak, Rahiman, Kanafiah, & Saad, 2015).	Red Neuronal feed-forward	Tres capas existen en esta red neuronal, incluyendo una capa de entrada con dos Parámetros, una capa oculta que contiene diez neuronas y una capa de salida que contiene una sola neurona. Los pesos de la conexión de red se establecen aleatoriamente en la fase de aprendizaje. Los parámetros de entrada son normalizados entre 0 y 1.	99,2%	Calidad de la hoja Phyllanthus Elegans Wall (Asin-Asin Gajah)
24	2015	Classification of diseased plant leaves using neural network algorithms (Muthukannan, Latha, Pon Selvi, & Nisha, 2015).	Feed Forward Neural Network (FFNN). Learning Cuantización vectorial (LVQ). Redes de función de base radial (RBF).	En este trabajo el algoritmo de red neuronal es propuesto para la clasificación de hojas de plantas enfermas como la de los frijoles y hojas de calabaza las redes neuronales como Feed Forward Neural Network (FFNN), cuantificación de vectores de aprendizaje (LVQ) y red radial de función bases (RBF) se probaron para estas dos clasificaciones. El rendimiento se mide utilizando parámetros de clasificación como precisión, exactitud, relación de recuperación y f_mesure. Con dichos parámetros el desempeño fue analizado y basado en el análisis en el enfoque de clasificación FFNN ya que proporciona un mejor resultado.	90,6% 56,7% 71,1%	Calidad en hojas de frijoles y hojas de calabaza.
25	2015	Diseño e implementación de un sistema de detección de malezas en cultivos Cundiboyacenses (Vinogradov, 2015).	Redes neuronales (NN). Máquinas de soporte vectorial (SVM)	Este presente trabajo se lo realizó para poder determinar si el cultivo es óptimo, o si existe presencia de las diferentes especies de arvenses para proseguir a hacer la	83.2% 82.5%	<i>Pennisetum clandestinum</i> - Kikuyo

				<p>diferenciación con el cultivo, tomando en cuenta diferentes características, dicha información se procesará en una unidad central que contiene un software desarrollado en Python-OpenCV y Matlab, la unificación de procesos desarrollados en estos programas se encargará de la toma de decisiones para una detección afirmativa de malezas, que utiliza Se tomaron 350 fotografías de diferentes cultivos de la región Cundiboyacense en diferentes etapas de crecimiento de los mismos, con un enfoque superficial y bajo condiciones naturales de iluminación, de las cuales se emplearon las 520 imágenes que se obtuvieron. Teniendo 400 imágenes de tratamiento o entrenamiento y 120 para pruebas. Para la clasificación de los cultivos se utilizó clasificador del vecino más cercano (KNN), Clasificador Bayesiano y para la detección de la maleza se utilizó Redes neuronales (NN) y Máquinas de soporte vectorial (SVM), que como resultados o salidas de las imágenes procesadas</p>		
26	2014	Potential of radial basis function-based support vector regression for apple disease detection (Omrani et al., 2014).	RBF (Radial Basis Network)	<p>Este artículo entrena una red neuronal para la detección de tres enfermedades en las hojas de las manzanas en el que, para entrenar la red neuronal, se consideraron 33 variables independientes entre características de color, forma y textura</p>	99,8%	<p>Enfermedades de la manzana: Alternaria, mancha negra y plaga minera</p>

				como entradas, Se emplearon las características de textura, la matriz wavelet y las técnicas de matriz de coexistencia de nivel de gris, mientras que las enfermedades de la manzana detectadas fueron elegidas como una salida. La red fue entrenada utilizando el 70% de los 320 experimentos originales y el 30% restante se aplicaron para crear un conjunto de datos de prueba. Estas redes fueron entrenadas con El algoritmo de entrenamiento de Levenberg Marquard.		
27	2013	Diagnosis and Classification of Grape Leaf Diseases using Neural Networks (Sannakki, Rajpurohit, Nargund, & Kulkarni, 2013).	Feed forward Back Propagation Neural	La red propuesta en este trabajo cuenta con tres capas de entrada, oculta y salida en el que la función de transferencia sigmoide se utiliza para generar la salida en cada etapa. La capa de entrada tiene 9 nodos, que son relacionado con dos características de textura 9: contraste, uniformidad, probabilidad máxima, homogeneidad, diferencia inversa, varianza de la diferencia, varianza diagonal, entropía de las bandas H de área de la lesión. La capa de salida contiene dos neuronas.	100%	Moho vellosa, moho polvoriento y antracnosis
28	2013	An artificial neural network approach to identify fungal diseases of cucumber ( <i>Cucumis sativus</i> L.) plants using digital	Feed Foward Back Propagation	La red que se utilizó se entrenó con el algoritmo de propagación inversa de Levenberg-Marquardt. Por lo tanto, la arquitectura de la red se consideró como	90%	<i>enfermedades fúngicas de plantas de pepino: Pseudoperonospora</i>

		image processing (Asefpour Vakilian & Massah, 2013).		una red 5–20–2 que representa cinco nodos en la capa de entrada (características: entropía, homogeneidad, temperatura media de la hoja y la temperatura máxima.), 20 nodos en la capa oculta y dos nodos en la salida. Se utilizaron conjuntos de datos de 20 imágenes de hojas para validación cruzada, y se mantuvieron 30 conjuntos de datos para evaluar los resultados presentados.		<i>cubensis, Sphaerotheca fuliginea</i>
29	2012	Aquatic weed automatic classification using machine learning techniques (Pereira, Nakamura, de Souza, Martins, & Papa, 2012).	RBF (Radial Basis Network)	Esta investigación propone la clasificación automática de malezas acuáticas mediante aprendizaje automático. En este trabajo se utilizó la distancia euclidiana para medir la similitud entre diferentes vectores de características. Además, se realizó experimentos que se llevaron a cabo con el fin de comparar cinco diferentes descriptores de formas y seis técnicas de reconocimiento de patrones supervisados, en donde se demostró que OPF, Bayes, SOM y SVM-RBF obtuvieron resultados similares, siendo OPF el enfoque más rápido si se considera la totalidad del tiempo de formación, es decir, entrenamiento y pruebas.	96,41%	Control de malezas acuáticas: E. crassipes P. stratiotes S. auriculata
30	2011	Selection of Optimal Wavelength Features for Decay Detection in Citrus Fruit Using the ROC Curve and Neural Networks (Lorente et al., 2011).	Perceptrón multicapa	Los resultados son obtenidos utilizando imágenes de mandarinas con los píxeles etiquetados en cinco clases diferentes. La metodología utilizada para seleccionar el número óptimo de neuronas ocultas era	91.4% Modelo 1, 95,6% Modelo 2	Detección de descomposición en cítricos: <i>Penicillium italicum</i> , <i>Penicillium Digitatum</i>

				estimar la tasa de éxito de clasificación para varios modelos variando el número de neuronas en la capa oculta, en un primer modelo, arquitecturas con un número variable de neuronas ocultas se probaron de 25 a 1,025, en un segundo modelo, las arquitecturas con un número variable de 75 a 225 neuronas fueron probadas, seleccionando finalmente un MLP que usó 125 neuronas en La capa oculta y la función sigmoide como la función de activación ( g ).		
31	2011	Detección de cenicilla en rosa usando procesamiento de imágenes por computadora (Velázquez-López et al., 2011).	Redes neuronales convolucionales	La construcción de esta investigación surge de resolver el problema de no detectar a tiempo la Cenicilla que ataca a las hojas de las rosas, dicha enfermedad se caracteriza con esporas blancas en el haz de las hojas, la implementación de aprendizaje automático en conjunto con la visión por computadora permitió la detección temprana de esta enfermedad, el sistema de detección desarrollado permite detectar la enfermedad en un espacio de color HSV utilizando la librería OpenCV. Donde para obtener mejores resultados se usó una distancia de 10 cm para la obtención de las imágenes.	89.95%	<i>Podospaera pannosa</i> - Cenicilla rosal

32	2010	A Framework for Detection and Classification of Plant Leaf and Stem Diseases (Al Bashish, Braik, & Bani-Ahmad, 2010).	Feed forward back propagation	Este trabajo propone una solución basada en el procesamiento de imágenes para la Detección y clasificación automática de enfermedades foliares. El número de capas ocultas en la red neuronal fue 10, el número de entradas a la red neuronal representan las seis clases de hojas es decir las cinco enfermedades foliares y la hoja sana. La función de rendimiento fue el error cuadrático medio (MSE).	93%	<p>Detección de enfermedades foliares:</p> <ol style="list-style-type: none"> <li>1.- quemaduras tempranas.</li> <li>2.- moho algodonoso.</li> <li>3.- moho de ceniza.</li> <li>4.- Quemadura.</li> <li>5.- blancura minúscula.</li> </ol>
----	------	---	-------------------------------	--	-----	--

**Anexo 2** Tabla de resumen de la revisión bibliográfica.

**Fuente:** Los autores.

### **ANEXO 3. EJECUCIÓN DE LAS ITERACIONES EN PYTHON.**

The image shows the Spyder Python IDE interface. The main editor window displays a Python script named `rust.prediction.py`. The script includes imports for `keras`, `matplotlib`, `numpy`, and `os`. It defines a `load_image` function and a main loop that iterates over a directory of files, loading and predicting each image. The terminal window shows the output of the script, displaying training progress for 20 epochs. Each epoch output includes the time taken, steps per second, loss, and accuracy.

```

1 # Load_model_sample.py
2 from keras.models import load_model
3 from keras.preprocessing import image
4 import matplotlib.pyplot as plt
5 import numpy as np
6 import os
7
8
9 def load_image(img_path, show=False):
10
11     img = image.load_img(img_path, target_size=(100, 100))
12     img_tensor = image.img_to_array(img)
13     img_tensor = np.expand_dims(img_tensor, axis=0)
14     img_tensor /= 255.
15     if show:
16         plt.imshow(img_tensor[0])
17         plt.axis('off')
18         plt.show()
19
20     return img_tensor
21
22
23 # Load model
24
25 model = load_model("v3_iteracion_6.h5")
26 sana=roya=0
27 directorio='test/'
28 archivos = os.listdir(directorio)
29
30 for x in range(len(archivos)):
31
32     # image path
33     img_path = directorio + archivos[x]
34     #0=healthy
35     #1=unhealthy (roya)
36
37     # Load a single image
38     new_image = load_image(img_path)
39     # check prediction
40     pred = model.predict(new_image)
41
42     prediccion=np.argmax(pred)

```

Terminal de Python output:

```

12/11 [=====] - 31s 3s/step - loss: 0.2949 - acc: 0.9036
Epoch 10/20
12/11 [=====] - 33s 3s/step - loss: 0.2857 - acc: 0.8802
Epoch 11/20
12/11 [=====] - 33s 3s/step - loss: 0.2667 - acc: 0.9080
Epoch 12/20
12/11 [=====] - 32s 3s/step - loss: 0.1932 - acc: 0.9193
Epoch 13/20
12/11 [=====] - 31s 3s/step - loss: 0.2291 - acc: 0.9080
Epoch 14/20
12/11 [=====] - 32s 3s/step - loss: 0.1177 - acc: 0.9479
Epoch 15/20
12/11 [=====] - 32s 3s/step - loss: 0.1335 - acc: 0.9557
Epoch 16/20
12/11 [=====] - 30s 3s/step - loss: 0.1439 - acc: 0.9529
Epoch 17/20
12/11 [=====] - 34s 3s/step - loss: 0.0805 - acc: 0.9792
Epoch 18/20
12/11 [=====] - 33s 3s/step - loss: 0.0725 - acc: 0.9792
Epoch 19/20
12/11 [=====] - 31s 3s/step - loss: 0.0497 - acc: 0.9895
Epoch 20/20
12/11 [=====] - 34s 3s/step - loss: 0.1388 - acc: 0.9401

```

### Anexo 3 Ejecución de las iteraciones en Python.

Fuente: Los autores.

**ANEXO 4. CERTIFICACIÓN DEL GRUPO SISCOM EN CUMPLIMIENTO DE  
LA SISTEMATIZACIÓN DE LA EXPERIENCIA.**

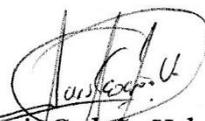
Calceta, 27 de noviembre de 2019

## CERTIFICACIÓN

El suscrito, LUIS CRISTOBAL CEDEÑO VALAREZO, con cédula de identidad número 1306246651, director del proyecto de investigación titulado “CARACTERIZACIÓN DE LA ROYA EN CULTIVOS DE CAFÉ ROBUSTA MEDIANTE TÉCNICAS AVANZADAS DE INTELIGENCIA COMPUTACIONAL”, propuesto el grupo de Investigación SISCOM, con CUP 383713; certifico que he recibido y realizado las pruebas de verificación del trabajo de tesis titulado “APLICACIÓN MOVIL DE DETECCIÓN Y CLASIFICACIÓN DE LA ROYA EN HOJAS DE CAFÉ ROBUSTA MEDIANTE APRENDIZAJE AUTOMÁTICO”, de los egresados KEVIN DANIEL CUSME ZAMBRANO y ANGÉLICA MARÍA LOOR PINARGOTE, mismo que ha sido aprobado de manera satisfactoria.

Los interesados pueden hacer uso de la presente certificación, como estimen conveniente.

Atentamente,



Mg. Luis Cedeno Valarezo  
**DIRECTOR DEL PROYECTO DE INVESTIGACIÓN  
GRUPO SISCOM**

**Anexo 4** Certificación del grupo SISCOM en cumplimiento de la sistematización de la experiencia.

**Fuente:** Los autores.