



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA
CARRERA DE INGENIERÍA EN SOFTWARE

TEMA: “DESARROLLO DE UN SISTEMA SOFTWARE DE APRENDIZAJE PROFUNDO QUE OPTIMICE EL DIAGNÓSTICO DE PLAGAS EN HOJAS DE CULTIVOS DE PAPAS EN EL SECTOR LA LIBERTAD PARROQUIA TOACASO PROVINCIA DE COTOPAXI”


**AUTORES: CHOLOQUINGA COCHA, LUIS GERARDO
REYES NEGRETE, ALEX OMAR**

DIRECTOR: ING. GARCÉS GUAYTA, LUCAS ROGERIO

LATACUNGA, 2020



Resumen



- Consiste en el desarrollo de un sistema software (aplicación móvil), que optimice el diagnóstico de plagas en hojas de cultivos de papas.



- Presenta las siguientes funcionalidades

1. Diagnóstico de plagas en tiempo real, a través de la cámara del dispositivo móvil.

2. Información sobre el control de plagas.

3. Información sobre las plagas que existen en los cultivos de papas en la actualidad.

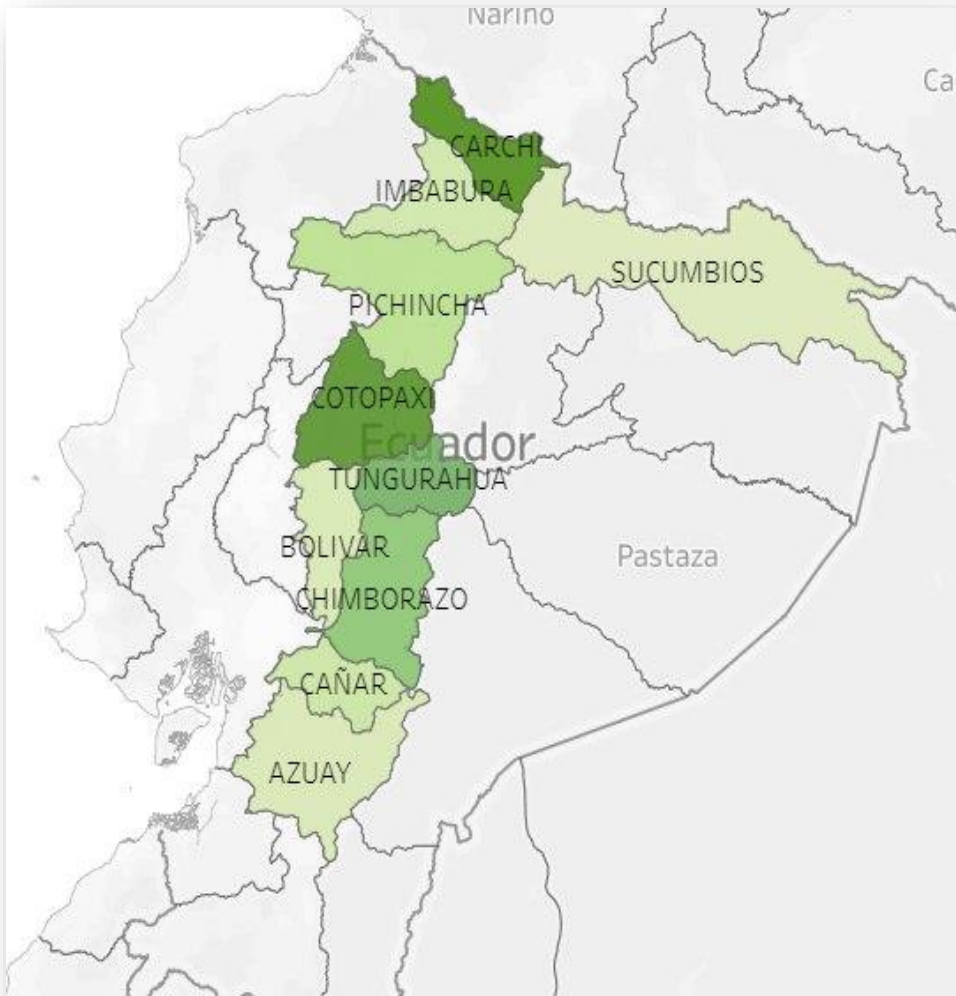
4. Diagrama detallado, para realizar el diagnóstico adecuado en cultivos de papas.

Metodología
MOBILE-D

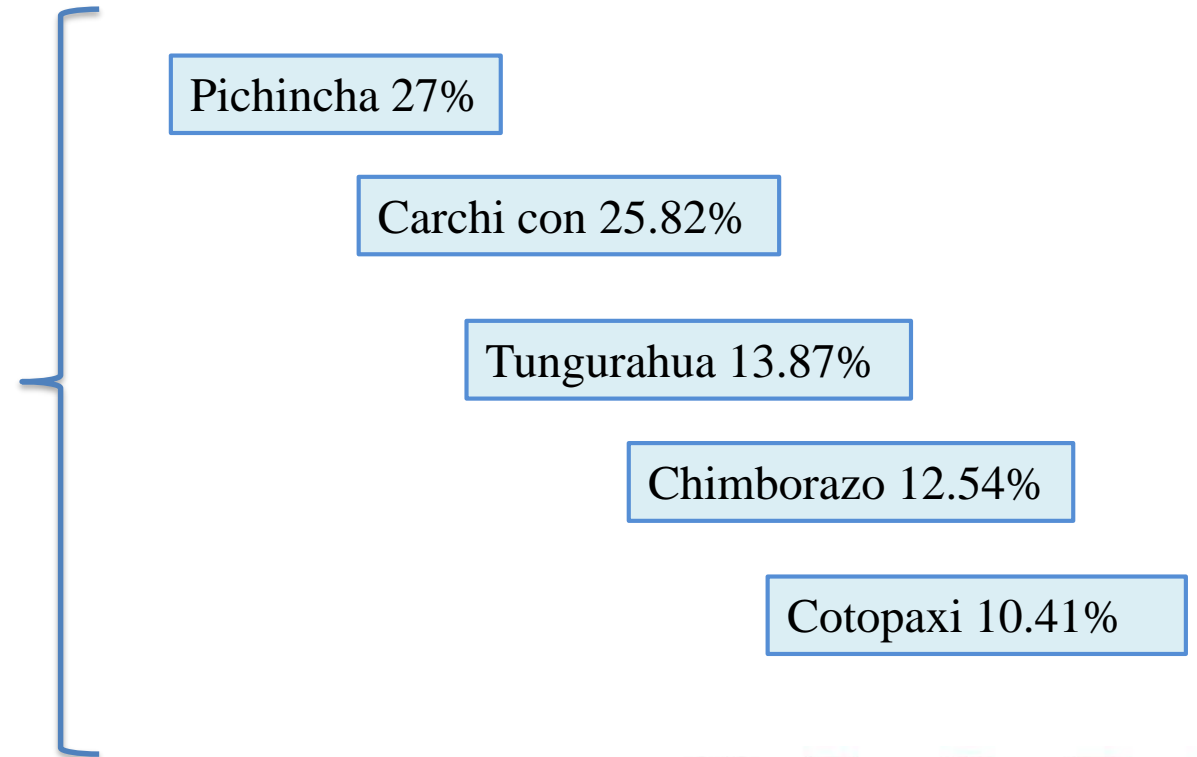


ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

Planteamiento del Problema



- La papa por años, ha sido un cultivo de gran prioridad en el Ecuador. Hoy en día, los agricultores del país siembran anualmente cerca de 29.532 hectáreas de este cultivo, distribuido a nivel nacional de la siguiente , manera:



Planteamiento del Problema

- En la actualidad, han surgido plagas que han llevado a que el cultivo enfrente varios problemas que ponen en riesgo el bienestar económico de los agricultores y en general la seguridad alimentaria del país.
- En la provincia de Cotopaxi, los cantones con mas siembras de papas son: Latacunga, Salcedo y Saquisilí. Las principales parroquias de cultivos de papas en el cantón Latacunga son: Tanicuchi, Toacaso, Mulalo, Ignacio Flores, Alaquez y Juan Montalvo.
- En la parroquia de Toacaso se siembran anualmente alrededor de 4.500 a 5000 hectáreas de papas, las cuales están divididas en diferentes sectores.
- Los sectores con mayor producción de papas son: La Libertad y San Francisco.



Planteamiento del Problema

- Las principales plagas que amenazan los cultivos de papas en el sector la Libertad:

Mosca Minadora



Psílido de la punta morada



- Causando pérdidas económicas a los pequeños y medianos productores de la zona.

Planteamiento del Problema



- El problema principal esta en el **diagnóstico** de plagas en hojas de cultivos de papas.


debido

- Los agrónomos y agricultores de la zona realizan el diagnóstico mediante detección sintomatológica visual, lo que implica un alto grado de complejidad.
- Las plagas presentan formas similares, donde incluso los agrónomos experimentados a menudo no logran diagnosticar con éxito las plagas específicas y por lo tanto, llegan a conclusiones y tratamientos erróneos.



Formulación del Problema

Con toda la información detallada en el anterior punto, se plantea la siguiente interrogante:



¿Como optimizar el diagnóstico de plagas en hojas de cultivos de papas en el sector la Libertad Parroquia Toacaso Provincia de Cotopaxi?



OBJETIVOS

General

- Desarrollar un sistema software de aprendizaje profundo que optimice el diagnóstico de plagas en hojas de cultivos de papas en el sector la Libertad parroquia Toacaso provincia de Cotopaxi.

Específicos

- Elaborar el marco teórico sobre los diferentes algoritmos que existen en el campo del aprendizaje profundo, y sobre las plagas que amenazan los cultivos de papas a nivel de las hojas.
- Desarrollar el modelo de red neuronal mediante uno de los modelos de red neuronal pre-entrenados que existen en el campo del aprendizaje profundo.
- Desarrollar el sistema software móvil aplicando la metodología MOBILE-D.
- Implementar el sistema software en el sector la libertad parroquia Toacaso provincia Cotopaxi.
- Validar el sistema software mediante pruebas de funcionalidad y la valoración de un ingeniero agrónomo.



Hipótesis e Indicadores



¿ Si se desarrolla un sistema software de aprendizaje profundo entonces se optimiza el diagnostico de plagas en hojas de cultivos de papas en el sector la Libertad parroquia Toacaso provincia de Cotopaxi?



Número de plagas detectadas



Tiempo de análisis para el diagnóstico de plagas



Porcentaje de probabilidad de que sea la plaga correcta



Aplicar un plan preventivo de plagas



Disminución de pérdidas de producción de papas



Variable de la Investigación

Dependiente

- Se optimiza el diagnóstico de plagas en hojas de cultivos de papas en el sector la libertad parroquia Toacaso provincia de Cotopaxi.

Independiente

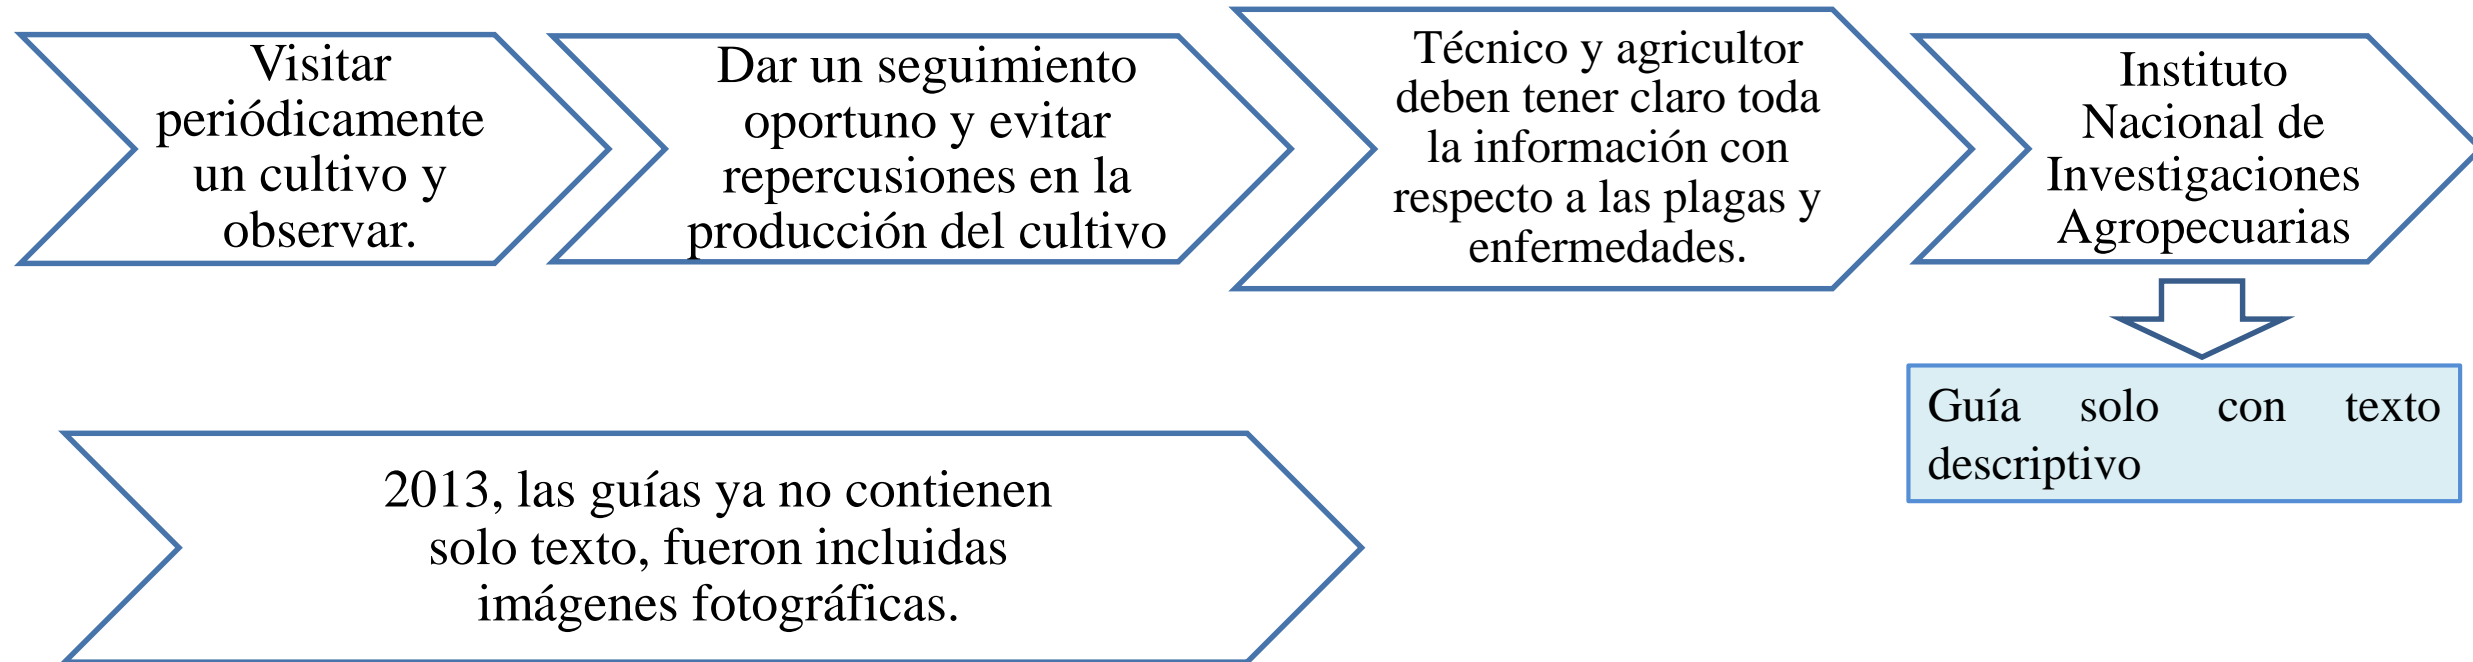
- Se desarrolla un sistema software basado en aprendizaje profundo.



Marco Teórico: Antecedentes Históricos

Métodos y Técnicas de diagnóstico de plagas en cultivos de papas

ETAPA 1: 1976-2017: Detección sintomatológica visual



Marco Teórico: Antecedentes Históricos

Métodos y Técnicas de diagnóstico de plagas en cultivos

ETAPA 2: 2013- Actualidad: Inteligencia Artificial



Las técnicas de inteligencia artificial, han logrado un crecimiento exponencial aplicado a diversos campos, incluida la agricultura.

Con la finalidad de facilitar información confiable sobre:

Sembrar

Regar

Fertilizar

Diagnosticar plagas y enfermedades

De manera rápida y eficiente



ESPE
ESCUELA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA


Marco Teórico: Antecedentes Conceptuales y Referenciales

Principales plagas que amenazan los cultivos de papas

El instituto Nacional Autónomo de Investigaciones Agropecuarias, plantea que, el cultivo de papa en nuestro país sufre el ataque de diversas plagas durante el transcurso de su ciclo de cultivo, que de no efectuarse un adecuado control producirían severas pérdidas económicas



La mosca minadora es una de las principales plagas que amenazan los cultivos de papas en Sudamérica. Los insectos adultos son de color negro y muestran pequeñas manchas de color amarillo. Las larvas se alimentan del tejido que encuentran del haz y del envés de las hojas.



- Es una enfermedad muy difícil de detectar y controlar, causa grandes pérdidas a nivel mundial
- Es transmitida por un insecto, afecta a los cultivos de papas a nivel mundial y recientemente ha sido reportado en Ecuador



Marco Teórico: Antecedentes Conceptuales y Referenciales

Tecnologías aplicadas a los métodos de diagnóstico de plagas o enfermedades

El método tradicional de detección sintomatológica visual ha sido complementado con la aparición de algoritmos y diferentes técnicas de inteligencia artificial. Se detallan dos proyectos relacionados



- Nuru, una aplicación móvil de PlantVillage para detectar enfermedades de los cultivos en África



- Diseño y Desarrollo de un sistema prototipo de diagnóstico de afecciones en plantas de cítricos utilizando procesamiento de imágenes y aprendizaje profundo



Marco Teórico: Antecedentes Conceptuales y Referenciales

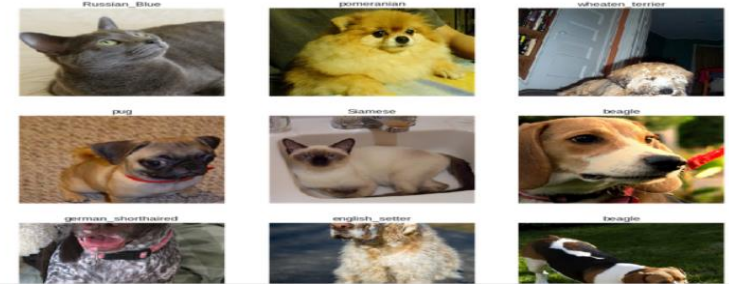
Aprendizaje Profundo

- El aprendizaje profundo lleva a cabo el uso una red neuronal artificial que se compone de un número de niveles jerárquicos.
- En el nivel inicial de la jerarquía la red aprende algo simple y luego envía esta información al siguiente nivel.
- El siguiente nivel toma esta información sencilla, la combina, compone una información algo un poco más compleja, y se lo pasa al tercer nivel, y así sucesivamente.

Tareas



Clasificación de imágenes



Detección de Objetos



Reconocimiento de voz




ESPE
ESCUELA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA

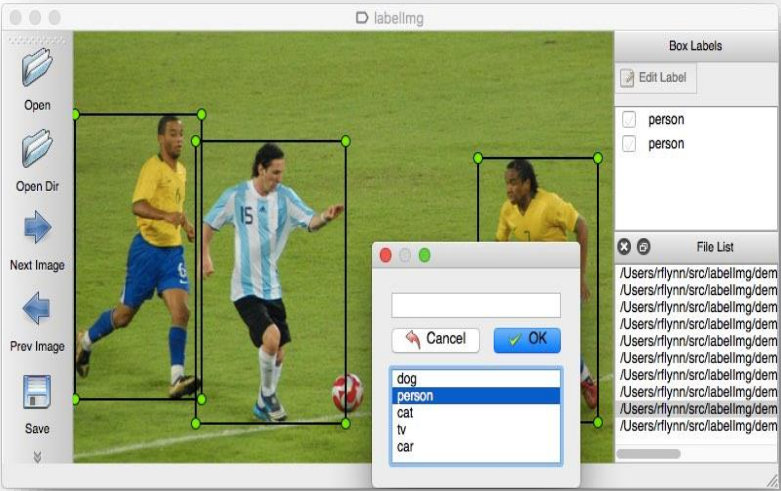
Marco Teórico: Antecedentes Conceptuales y Referenciales

Redes Neuronales Convolucionales (CNN)

- La CNN es un tipo de Red Neuronal Artificial que contiene varias capas ocultas especializadas y con una jerarquía
- Esto quiere decir que las primeras capas pueden detectar líneas, curvas y se van especializando hasta llegar a capas más profundas que reconocen formas complejas como un rostro o la silueta de un animal.



Marco Teórico: Herramientas para el desarrollo del sistema software



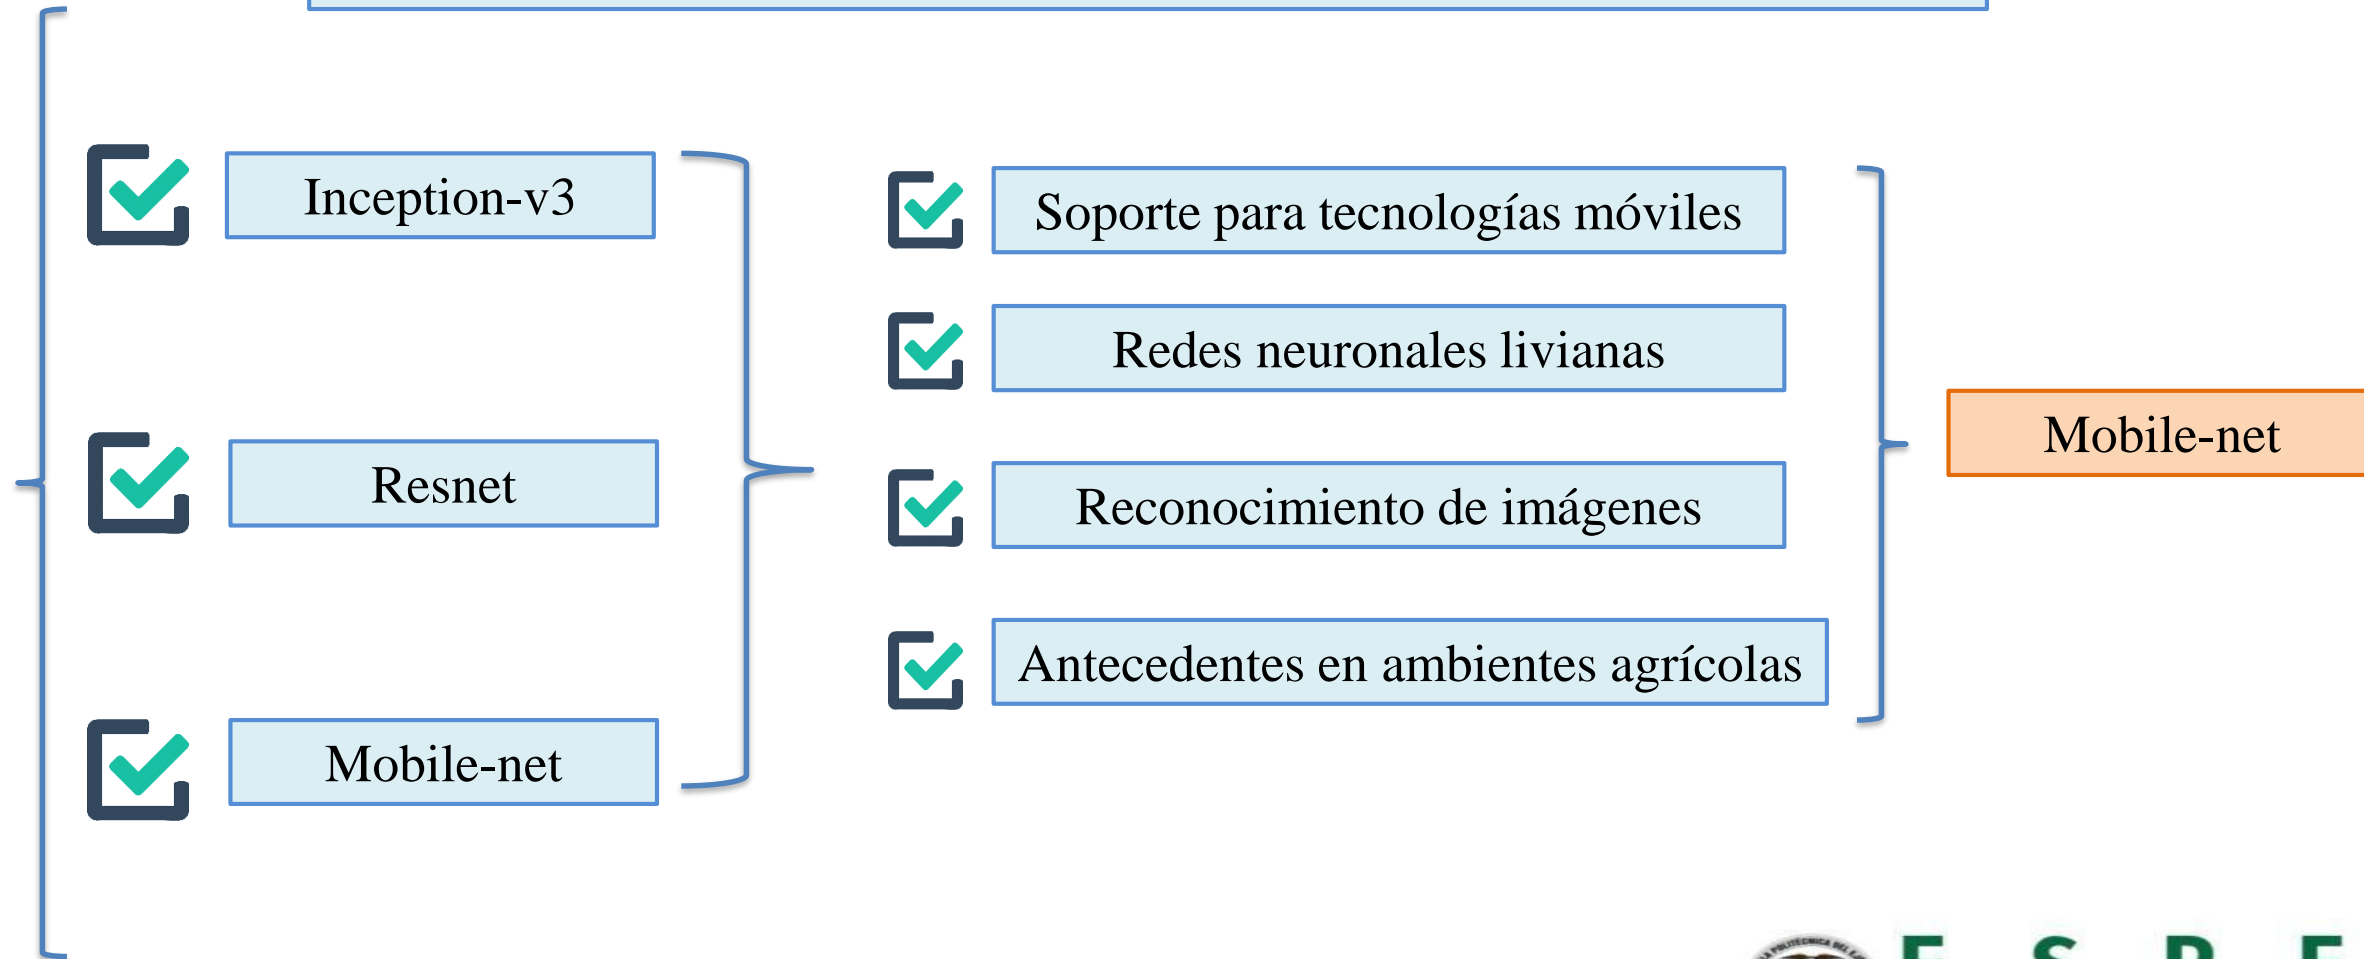
Tensorflow Object Detection API

Creating accurate machine learning models capable of localizing and identifying multiple objects in a single image remains a core challenge in computer vision. The TensorFlow Object Detection API is an open source framework built on top of TensorFlow that makes it easy to construct, train and deploy object detection models. At Google we've certainly found this codebase to be useful for our computer vision needs, and we hope that you will as well.

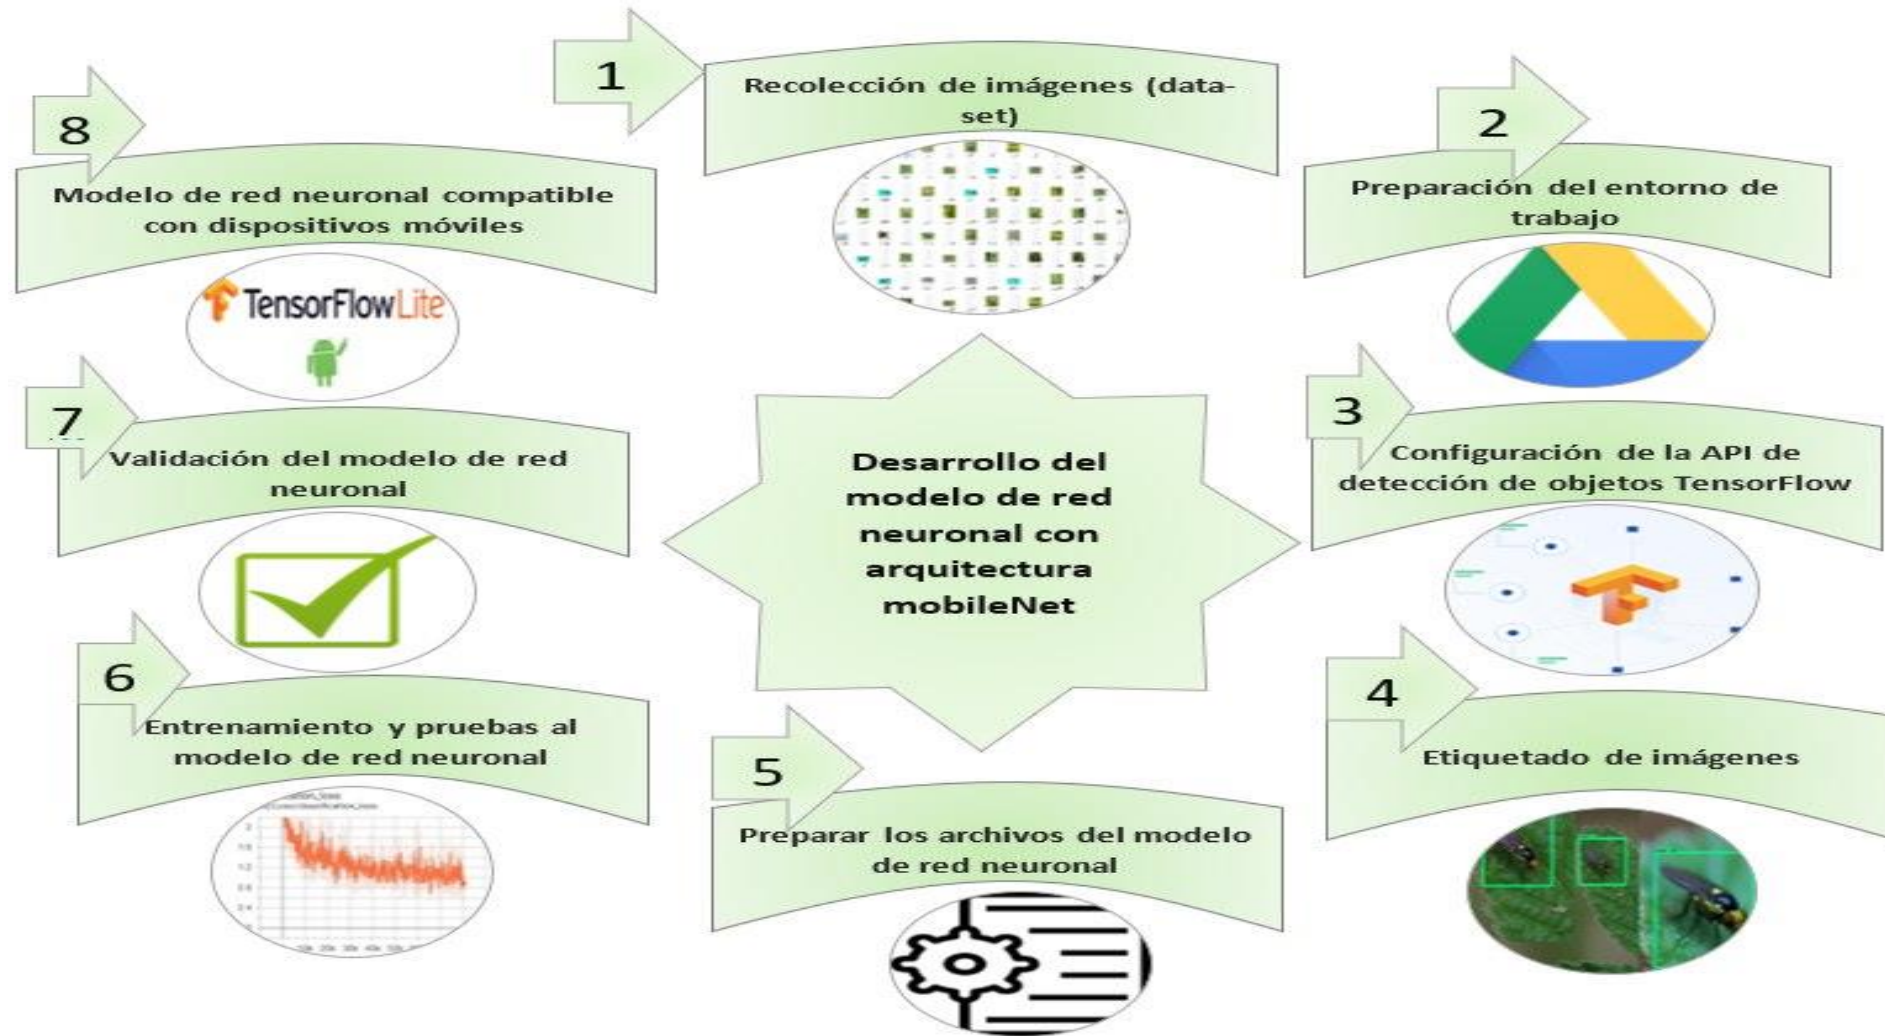
An image of a beach scene with several bounding boxes and confidence scores. Labels include 'kite' (97%, 99%, 92%, 90%, 54%, 92%) and 'person' (97%, 86%, 76%, 54%, 99%, 99%).

Desarrollo: Modelo de Red Neuronal

Criterios para seleccionar la arquitectura para el modelo de red neuronal.



Desarrollo: Modelo de Red Neuronal



Desarrollo: Modelo de Red Neuronal

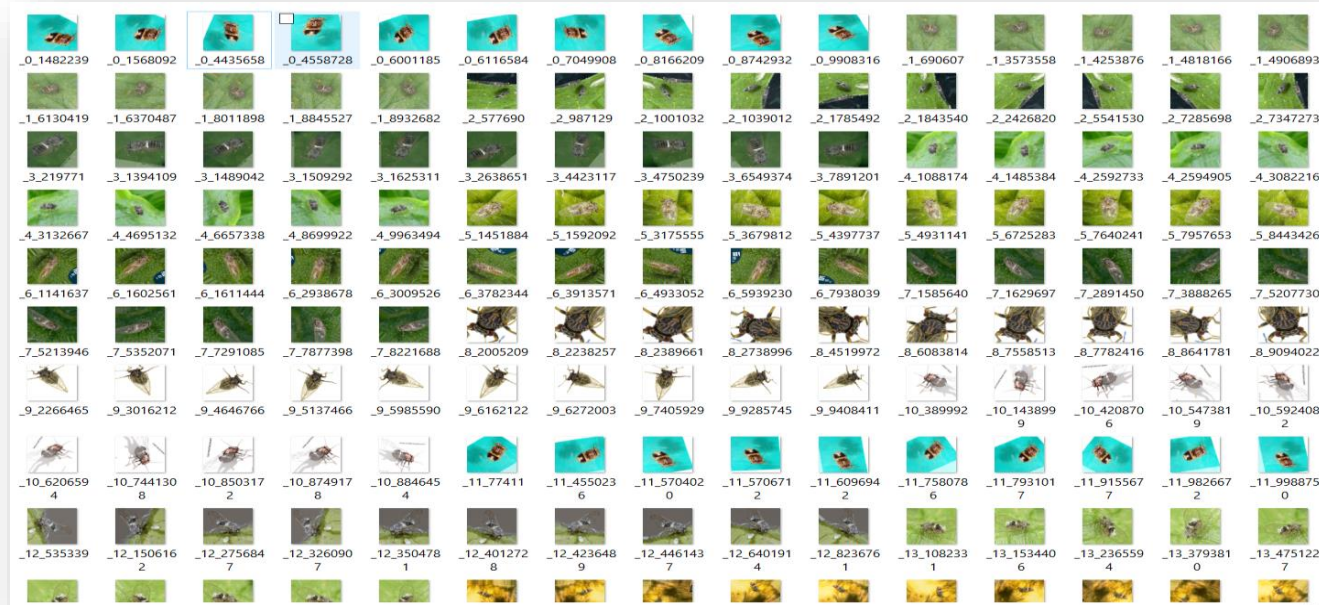
1. Recolección de imágenes:

Imágenes recolectas en los diferentes lotes de cultivos de papas en el sector la Libertad.

Mosca Minadora y Psílido de la punta morada

Las imágenes contienen la plaga (insecto adulto) que amenaza la planta a nivel de las hojas.

Total se tiene 20000 imágenes



Desarrollo: Modelo de Red Neuronal

2. Preparación del entorno de trabajo

Uso de Google Colaboraty

The logo for Google Colab, featuring the word "colab" in a bold, lowercase, orange font. The letters are stylized with a slight shadow effect.

Servicio gratuito en la nube que permite escribir, ejecutar código, guardar y compartir tus análisis mediante el navegador.

3. Configuración de la API de detección de objetos de TensorFlow

Proporciona modelos precisos de aprendizaje profundo capaces de identificar, ubicar múltiples objetos en una imagen.



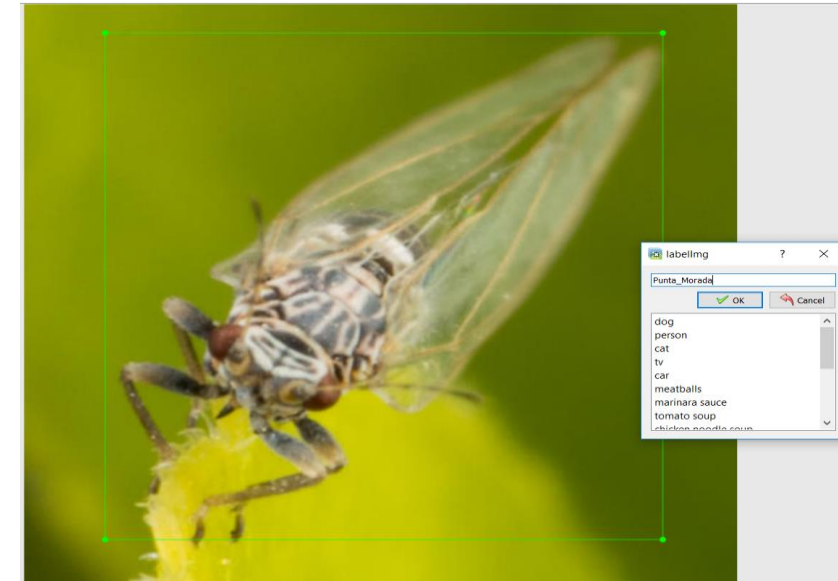
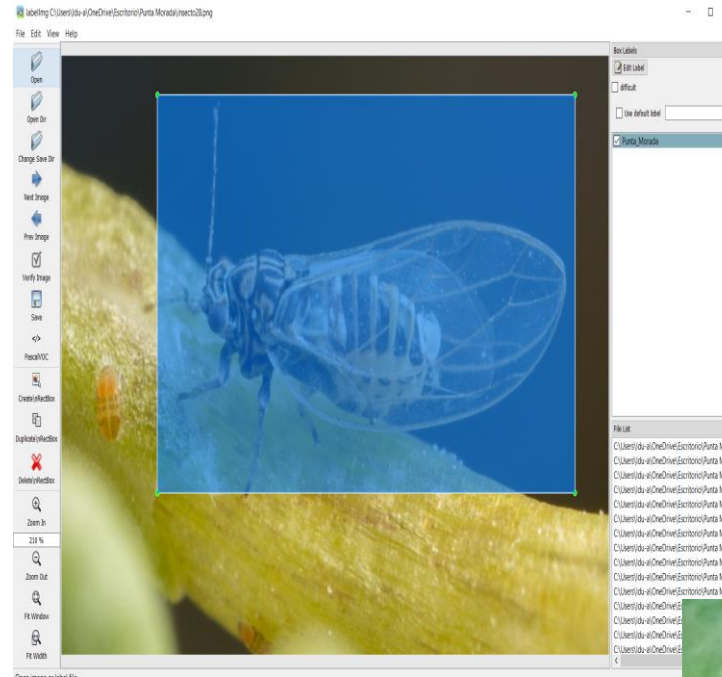
Desarrollo: Modelo de Red Neuronal

3. Etiquetado de Imágenes

labelImg es un software libre que permite realizar el etiquetado de imágenes.

El etiquetado de imágenes permite conocer el nombre de la plaga y marcar las coordenadas de la plaga dentro de la imagen.

Este software genera archivos XML por cada imagen etiquetado.



Ruta de imagen

Nombre de la clase

Nombre de la imagen

Coordenadas donde se encuentra el objeto etiquetado



ESPE
ESCUOLA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA

Desarrollo: Modelo de Red Neuronal

4. Conversión de archivos para formato de TensorFlow



Desarrollo: Modelo de Red Neuronal

5. Preparación de los archivos de configuración del modelo de red neuronal

Tensorflow proporciona modelos de redes neuronales para el reconocimiento de imágenes. Estas son típicamente redes neuronales convolucionales.

Clasificación

Reconocer categorías como gatos, perros, automóviles o cualquier otra cosa. El sistema clasifica la imagen **como un todo**, en función de estas categorías.

Detección de objetos

Son más potente que la clasificación, puede detectar varios objetos en la misma imagen. También etiqueta los objetos y muestra su ubicación dentro de la imagen.



Desarrollo: Modelo de Red Neuronal

La API de detección de objetos de **TensorFlow** proporciona el uso de modelo pre-entrenados

MobileNet_v2_coco

Archivo de configuración

ssdlite_mobilenet_v2_coco

Name	Date modified	Type	Size
saved_model	9/9/2019 12:56 PM	File folder	
checkpoint	5/9/2018 11:51 PM	File	1 KB
frozen_inference_graph.pb	5/9/2018 11:52 PM	PB File	19,445 KB
model.ckpt.data-00000-of-00001	5/9/2018 11:51 PM	DATA-00000-OF-0...	17,779 KB
model.ckpt.index	5/9/2018 11:51 PM	INDEX File	18 KB
model.ckpt.meta	5/9/2018 11:51 PM	META File	3,580 KB
pipeline	5/9/2018 11:51 PM	XML Configuration...	5 KB

```
item {
  id: 1
  name: 'minador'
}

item {
  id: 2
  name: 'IPuntaMorada'
}

item {
  id: 3
  name: 'insecto_normal'
}
```

Etiquetas

```
fine_tune_checkpoint: "/content/drive/My Drive/TFConfig/TFmodels/research/object_detection/ssd_mobilenet_v2_coco/model.ckpt"
fine_tune_checkpoint_type: "detection"
# Note: The below line limits the training process to 200K steps, which we
# empirically found to be sufficient enough to train the pets dataset. This
# effectively bypasses the learning rate schedule (the learning rate will
# never decay). Remove the below line to train indefinitely.
num_steps: 200000
data_augmentation_options {
  random_horizontal_flip {
  }
}
data_augmentation_options {
  ssd_random_crop {
  }
}
}

train_input_reader: {
  tf_record_input_reader {
    input_path: "/content/drive/My Drive/TFConfig/TFmodels/research/object_detection/images/train.record"
  }
  label_map_path: "/content/drive/My Drive/TFConfig/TFmodels/research/object_detection/training/labelmap.txt"
}

eval_config: {
  num_examples: 6000
  # Note: The below line limits the evaluation process to 10 evaluations.
  # Remove the below line to evaluate indefinitely.
  max_evals: 10
}

eval_input_reader: {
  tf_record_input_reader {
    input_path: "/content/drive/My Drive/TFConfig/TFmodels/research/object_detection/images/test.record"
  }
  label_map_path: "/content/drive/My Drive/TFConfig/TFmodels/research/object_detection/training/labelmap.txt"
  shuffle: false
  num_readers: 1
}
```



Desarrollo: Modelo de Red Neuronal

6. Entrenamiento y pruebas del modelo de red neuronal

El entrenamiento fue definido en el archivo de configuración del modelo en 200000 iteraciones, el data-set esta dividido en 70% de imágenes para entrenamiento y 30% para pruebas.

El proceso de entrenamiento de la red neuronal duro aproximadamente 50 horas.

En el transcurso del entrenamiento la función de perdida disminuyo consistentemente por debajo de uno.

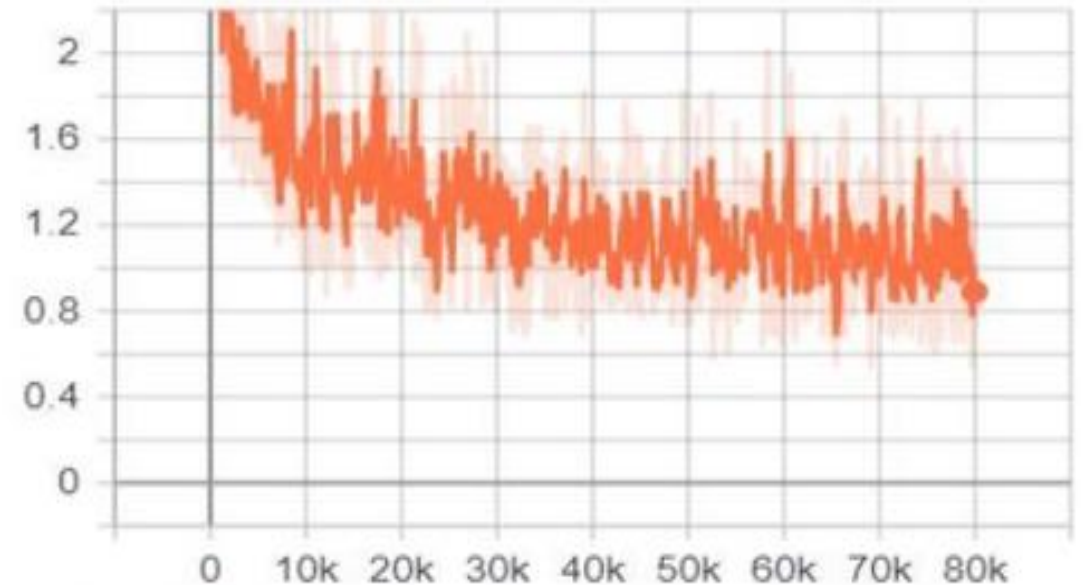
El resultado del entrenamiento alcanzo un valor aproximado de 0.70



Desarrollo: Modelo de Red Neuronal




No	Iteraciones	Valor aproximado de la función de pérdida
1	10000	4.1492
2	20000	3.6284
3	30000	2.9873
4	40000	2.6856
5	50000	2.4263
6	60000	2.0256
7	70000	1.6796
8	80000	1.3794
9	90000	0.9885
10	100000	0.9790
11	110000	0.9634
12	120000	0.9263
13	130000	0.9023
14	140000	0.8678
15	150000	0.8312
16	160000	0.8098
17	170000	0.7899
18	180000	0.7623
19	190000	0.7412
20	200000	0.7145


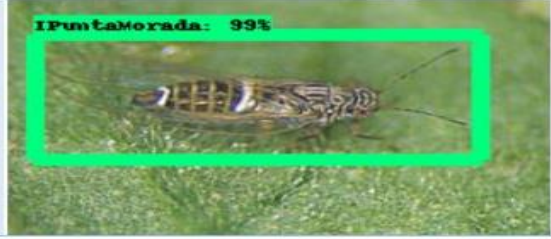


Loss/classification_loss
tag: Losses/Loss/classification_loss



Desarrollo: Modelo de Red Neuronal

7. Validación de la red neuronal

N.	Plaga	Diagnóstico	Acierto
1	minador		99%
			99%
			77%




2	Punta morada		92%
			99%
			86%
			99%

Desarrollo: Modelo de Red Neuronal

8. Convertir el modelo a un formato compatible para dispositivos móviles



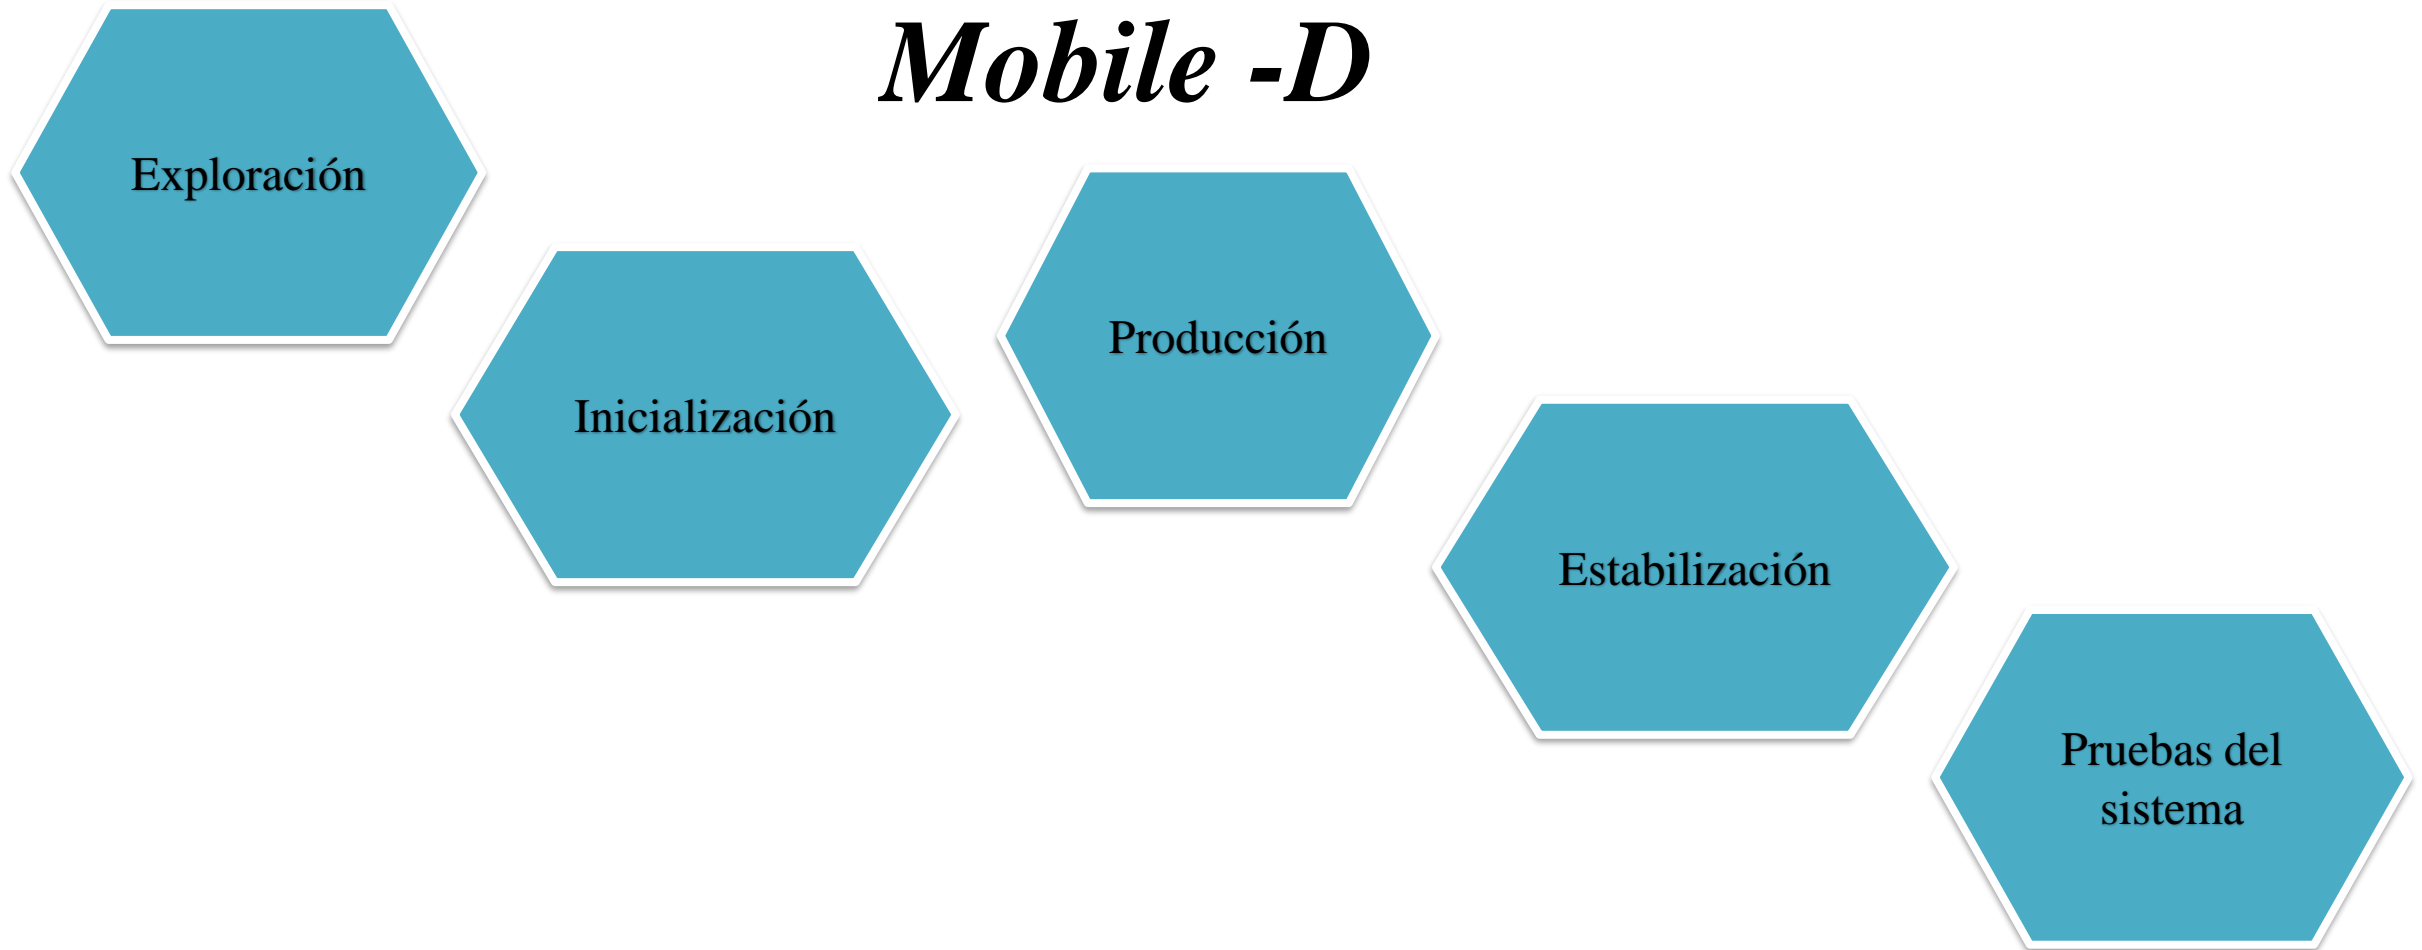
Permite convertir modelos de redes neuronales a un formato compatible para dispositivos móviles con el objetivo de optimizar el hardware del dispositivo móvil.

<input type="checkbox"/> Nombre	Fecha de modifica...	Tipo	Tamaño
 detect.tflite	27/09/2019 2:08	Archivo TFLITE	5.514 KB
 tflite_graph.pb	25/09/2019 20:37	Archivo PB	22.033 KB
 tflite_graph	27/09/2019 9:58	Archivo PBTXT	24.576 KB



Desarrollo: Aplicación Móvil

Mobile -D



Desarrollo: Aplicación Móvil

Exploración

Establecimiento de los Stakeholders



Técnicos agrónomos



Agricultores

Establecimiento del Proyecto



cámaras de capacidad
mínima 13 megapíxeles



Sistema operativo
Android con versión
mayor o igual a 7



ESPE
ESCUELA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA

Desarrollo: Aplicación Móvil

Inicialización

Requisitos Iniciales

Detectar posibles amenazas de plagas en hojas de cultivos de papas

Información de las plagas existentes en cultivos de papas

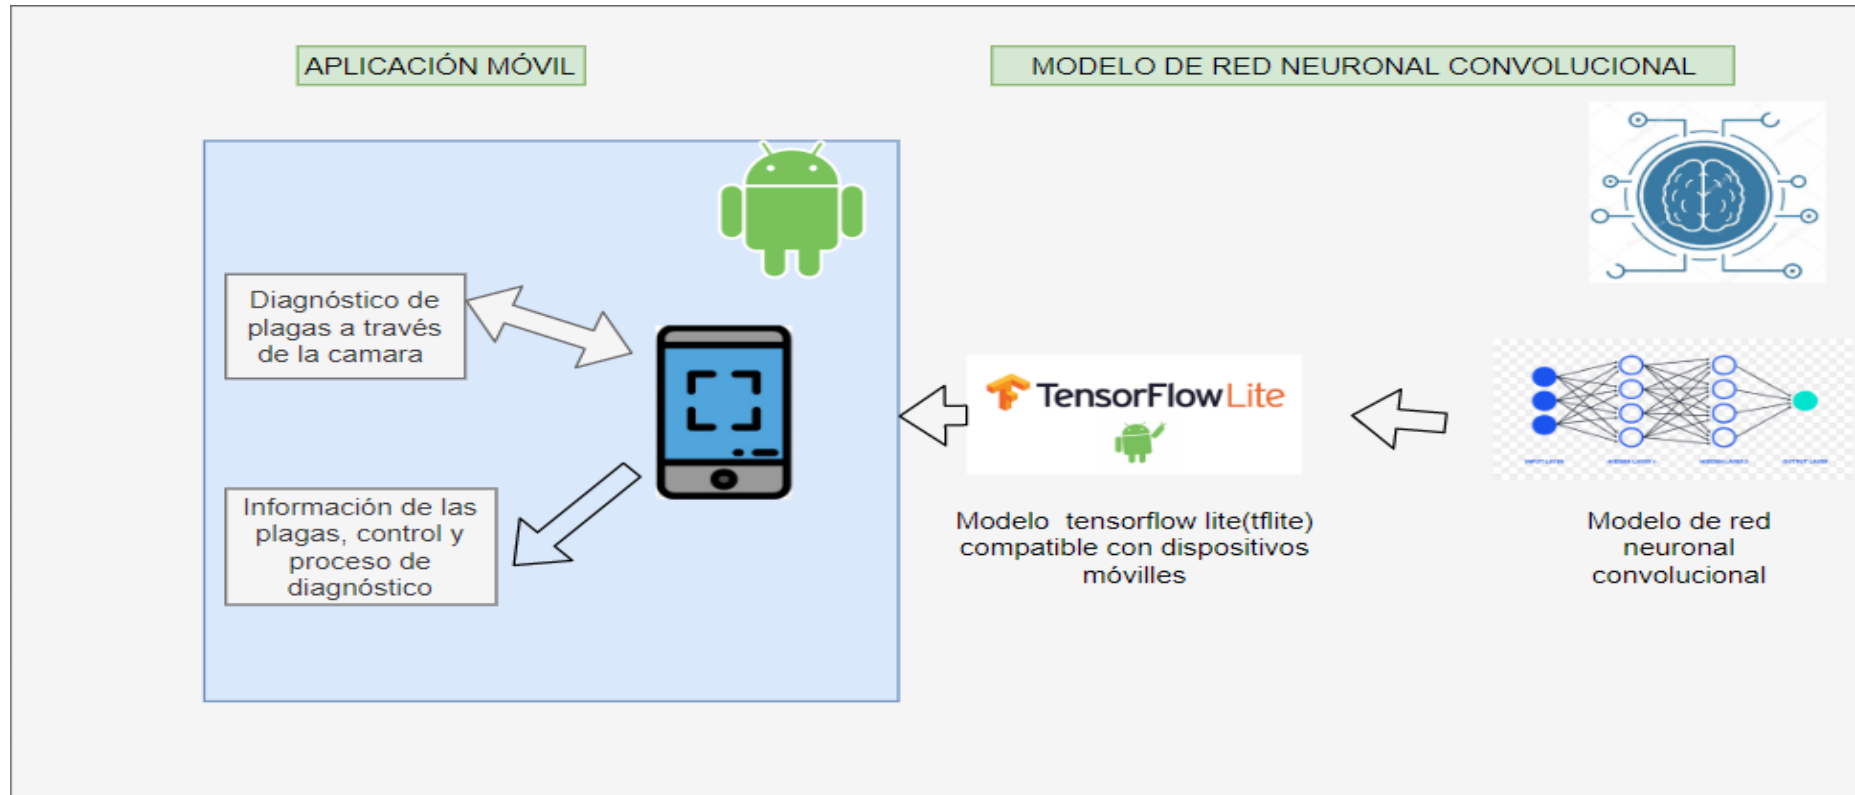
Información de insecticidas existentes para el control de plagas

Información sobre el proceso de diagnóstico de plagas en cultivos de papas



Desarrollo: Aplicación Móvil

Arquitectura de la Aplicación



Desarrollo: Aplicación Móvil

Descripción de las Interfaces de Usuario

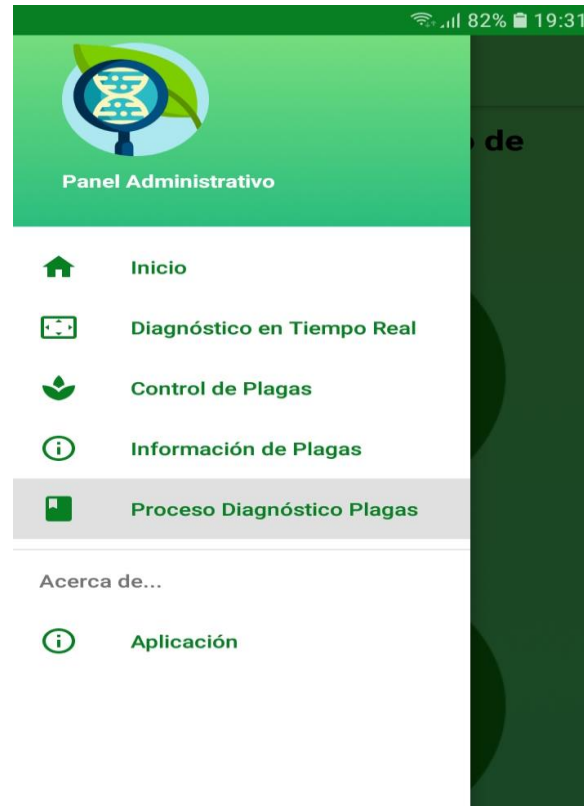


Pantallas informativas de la aplicación



Desarrollo: Aplicación Móvil

Descripción de las Interfaces de Usuario



Menú principal de la aplicación



Desarrollo: Aplicación Móvil

Descripción de las Interfaces de Usuario



Inicio



Diagnóstico en tiempo real



Control de Plagas

Desarrollo: Aplicación Móvil

Descripción de las Interfaces de Usuario



Información de las plagas



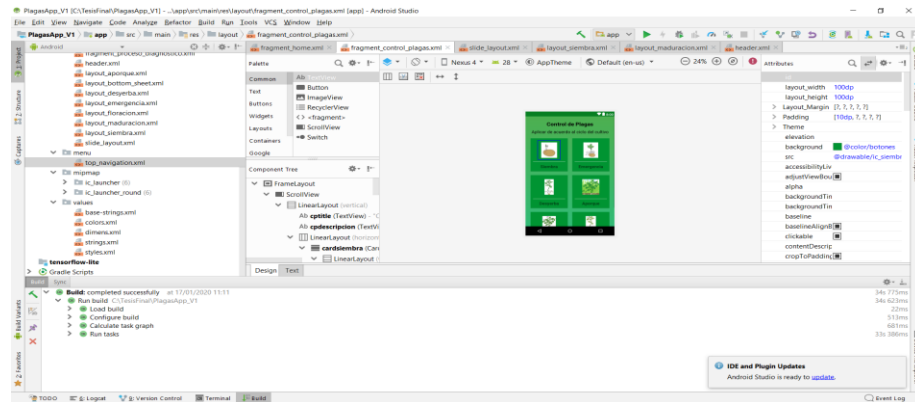
Proceso de Diagnóstico de plagas



Desarrollo: Aplicación Móvil

Producción

Una vez finalizado con el diseño de la aplicación móvil se comenzó con la implementación de las funcionalidades de la misma.



garantizando la calidad a través de pruebas que permitieron validar que la aplicación cumple con todos los requisitos establecidos

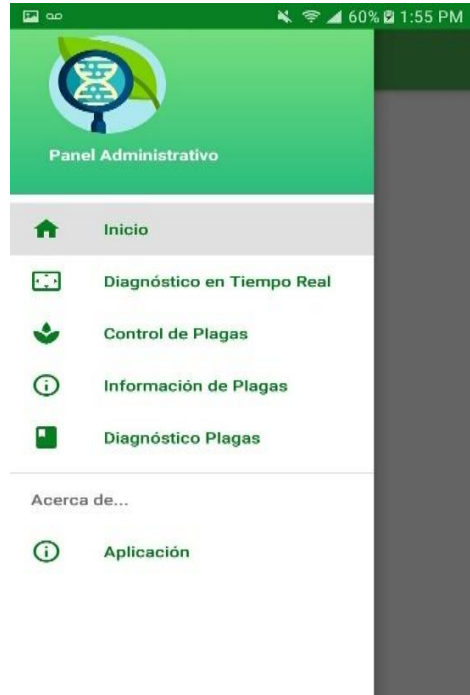
Estabilización

- En esta fase se realizó las últimas tareas de integración del sistema

- Con la finalidad de que el sistema completo funcione correctamente



Pruebas de la aplicación móvil



Pruebas de interfaz

Pruebas de aceptación

Caso de prueba: Detectar posibles amenazas de plagas en hojas de cultivos de papas.

Opción de prueba: Detectar posibles amenazas de plagas en hojas de cultivos de papas.

Numero de caso de prueba: 1

Numero de HU:1

Nombre de caso de prueba: Detectar posibles amenazas de plagas en hojas de cultivos de papas con el dispositivo móvil

Precondiciones: Una vez abierta la aplicación seleccionamos del menú la opción "Diagnóstico en Tiempo Real", esta activará la cámara del dispositivo móvil y mediante el uso del modelo de red neuronal desarrollado en el capítulo 3, se marcará un cuadro sobre la plaga detectada con un porcentaje de precisión.

Resultado esperado:

La aplicación se abrirá sin ningún error en el dispositivo móvil.

La aplicación detectara posible amenaza de plagas en los cultivos de papas.

Evaluación:

La aplicación funcionó correctamente.

Se detecto posibles amenazas de plagas en las papas de manera satisfactoria.

Pruebas de aceptación

Validación: Sistema Software (aplicación móvil)

Se aplicó una encuesta de medición de acuerdo a los indicadores planteados en nuestro proyecto de titulación. Todo esto esta fueron realizadas en un ambiente controlado.



Dos grupos de personas

10 técnicos agrónomos

5 expertos en cultivos de papas



ESPE
ESCUELA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA

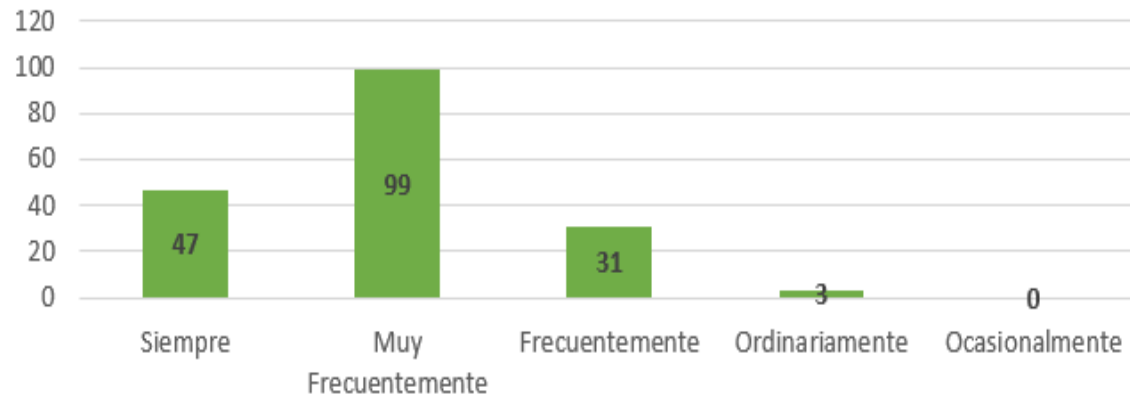
Validación: Sistema Software (aplicación móvil)

Porcentaje de aceptación del sistema software (aplicación móvil)

Técnicos agrónomos del ministerio de agricultura y ganadería


Expertos en cultivos de papas

Niveles de Aceptación del Sistema Software (Aplicación Móvil)



81,11 % Aceptación

Niveles de Aceptación del Sistema Software (Aplicación Móvil)



84,22 % Aceptación



Validación: Sistema Software (aplicación móvil)

Prueba de Hipótesis con Chi-Cuadrado

Hipótesis de la Investigación: ¿Si se desarrolla un sistema software de aprendizaje profundo entonces se optimiza el diagnóstico de plagas en hojas de cultivos de papas en el sector la Libertad parroquia Toacaso provincia de Cotopaxi?

Hipótesis Nula (H_0): El sistema software basado en aprendizaje profundo y la optimización del diagnóstico de plagas en hojas de cultivos de papas son independientes.

Hipótesis Alternativa (H_A): El sistema software basado en aprendizaje profundo y la optimización del diagnóstico de plagas en hojas de cultivos de papas son dependientes.



Prueba de Hipótesis con Chi-Cuadrado



Regla de decisión:

- Se acepta la hipótesis nula (H_0), si: $\chi^2_{\text{observado}} < \chi^2_{\text{crítico}}$
- Se acepta la hipótesis alternativa (H_A), si: $\chi^2_{\text{observado}} > \chi^2_{\text{crítico}}$

Validación: Sistema Software (aplicación móvil)

Conclusiones de los resultados presentados

- El análisis de resultados con la prueba de Chi Cuadrado realizada para cada indicador del proyecto permite corroborar que, la optimización del diagnóstico de plagas en hojas de cultivos de papas sector la Libertad parroquia Toacaso provincia de Cotopaxi depende claramente del sistema software (aplicación móvil) basado en aprendizaje profundo.
- Los datos de las encuestas aplicadas indican que el sistema software (aplicación móvil) de aprendizaje profundo, es apto para su uso, así cumpliendo con la hipótesis planteada en el proyecto de titulación, la cual hace mención a la optimización del diagnóstico de plagas en hojas de cultivo de papas en el sector la Libertad parroquia Toacaso provincia de Cotopaxi.



Conclusiones

- Se logro cumplir con el objetivo del proyecto, desarrollar un sistema software de aprendizaje profundo que optimice el diagnóstico de plagas en hojas de cultivos de papas en el sector la Libertad parroquia Toacaso provincia de Cotopaxi.
- El estudio comparativo realizado entre las diferentes arquitecturas de redes neuronales existentes en el campo del aprendizaje profundo, se pudo conocer que la arquitectura MobileNet es la más adecuada, debido a que son redes neuronales especializadas en el procesamiento de imágenes y están enfocados para el desarrollo de aplicaciones móviles.
- El entrenamiento de la red neuronal se realizó mediante aprendizaje de transferencia, debido a que esta técnica permite acelerar el proceso de entrenamiento de días a horas y de igual manera el conjunto de datos (imágenes) disminuye de millones a miles.



Conclusiones

- La construcción del data-set y el etiquetado de imágenes se realizó de forma manual, se realizó un tratamiento de las imágenes las cuales fueron clasificadas, procesadas y se realizó un aumento de datos para completar un total de 20000 imágenes que fueron utilizadas para el entrenamiento de la red neuronal, se considera a esta etapa como la que tomo más tiempo realizar para el desarrollo del proyecto de investigación.
- Se determinó que el uso de la tecnología es una opción útil para ayudar a agricultores y técnicos agrónomos en el proceso de detección de plagas en sus cultivos de papas, al ser una herramienta que logro llamar la atención por todas las funcionalidades e información que brinda y la facilidad de uso en sectores rurales, ya que no es necesario una conexión a internet para el funcionamiento de la aplicación.
- La aplicación permite la detección de plagas en tiempo real a través de la cámara del dispositivo móvil, una vez detectada la presencia de plagas en sus cultivos, puede acceder a la opción control de plagas donde puede encontrar diferentes tipos de control dependiendo de la época en la que se encuentre el cultivo, de igual manera puede encontrar información relevante sobre las principales plagas que actualmente están afectando mayormente a los cultivos y la información enfocada a los agricultores para realizar un proceso de diagnóstico de plagas a sus cultivos.



Recomendaciones

- Se recomienda tener un periodo de adaptación tanto en técnicos agrónomos como en agricultores en el uso del aplicativo software, debido a que los mismos no cuentan con poco a nada de experiencia, por lo que se supone un cambio para ellos.
- Se recomienda que la aplicación desarrollada puede ser utilizada por agricultores y técnicos agrónomos con el fin de optimizar el diagnóstico de plagas, poder aplicar un control de las plagas encontradas y de esta manera poder disminuir las pérdidas que se tienen por la presencia de plagas en sus cultivos.
- Para tener un buen rendimiento de la aplicación móvil se recomienda el uso de un dispositivo con versión mínima de Android 7.0, y cámaras de capacidad mínima de 13 megapíxeles

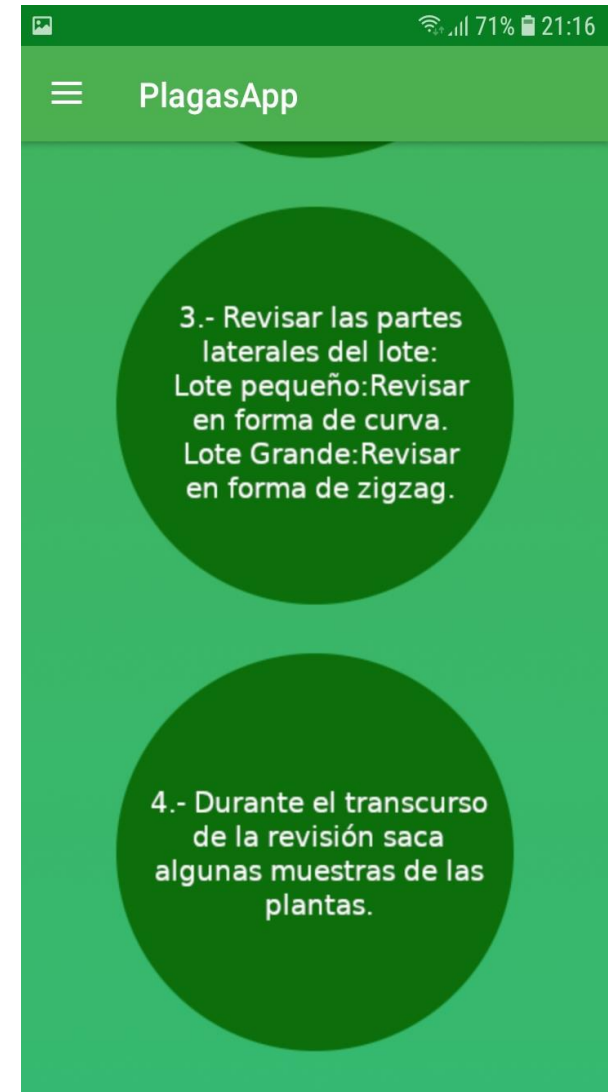


Recomendaciones


- Investigar sobre una herramienta que permita realizar el etiquetado de imágenes de forma automática, de ser posible desarrollar una ya que el etiquetado manual requiere un lapso de tiempo más extenso
- Se recomienda a futuro incrementar el número de plagas a ser detectadas y la automatización en el diagnóstico de plagas en otros tipos de cultivos
- Se recomienda a futuro incrementar funcionalidades en la aplicación como notificaciones, sistema de base de datos y geolocalización



Demostración



Demostración




ESPE
ESCUELA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA

Demostración



ESPE
ESCUOLA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA

Demostración



ESPE
ESCUELA POLITÉCNICA DEL EJÉRCITO
CAMINO A LA EXCELENCIA