



FACULTAD DE INGENIERÍA

Carrera de Ingeniería de Sistemas Computacionales

“SOLUCIÓN DE MACHINE LEARNING EN EL
RECONOCIMIENTO DE PLAGAS PARA PLANTONES DE
ARÁNDANO”

Tesis para optar el título profesional de:

Ingeniero de Sistemas Computacionales

Autores:

Bach. Renzo Manuel Delgado Pajares

Bach. Gloria Isabella Obeso Li

Asesor:

Dr. José Alberto Gómez Ávila

Trujillo - Perú

2019

DEDICATORIA

A mis padres, que siempre creyeron en mí y me brindaron su apoyo incondicional.

Renzo Manuel Delgado Pajares

A mis padres, quienes me motivan día a día con sus palabras de aliento y dedicación.

Gloria Isabella Obeso Li

AGRADECIMIENTO

A todos los docentes y al personal de la empresa Danper que nos apoyaron durante el desarrollo de la investigación.

Renzo Manuel Delgado Pajares

A Dios por estar presente en cada paso dado y a todos los docentes que nos apoyaron en este trabajo y a lo largo de toda la carrera.

Gloria Isabella Obeso Li

TABLA DE CONTENIDOS

DEDICATORIA	2
AGRADECIMIENTO.....	3
ÍNDICE DE TABLAS	5
ÍNDICE DE FIGURAS	6
ÍNDICE DE ECUACIONES	7
RESUMEN	8
ABSTRACT	9
CAPÍTULO I. INTRODUCCIÓN	10
1.1. Realidad problemática	10
1.2. Formulación del problema	22
1.3. Objetivos	23
1.4. Hipótesis	23
CAPÍTULO II. METODOLOGÍA	24
2.1. Tipo de investigación.....	24
2.2. Población y muestra	24
2.3. Técnicas e instrumentos de recolección y análisis de datos.....	24
2.4. Procedimiento	24
CAPÍTULO III. RESULTADOS	30
CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES	37
4.1. Discusión	37
4.2. Conclusiones	39
4.3. Recomendaciones	40
REFERENCIAS	41
ANEXOS	49

ÍNDICE DE TABLAS

Tabla 1. Recolección de datos antes de usar la aplicación móvil.....	25
Tabla 2. Comparación de metodologías de desarrollo de software.....	26
Tabla 3. Recolección de datos después de usar la aplicación móvil	28
Tabla 4. Resultados de la verosimilitud positiva del reconocimiento de plagas para plantones de arándano.....	30
Tabla 5. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la verosimilitud positiva del reconocimiento de plagas para plantones de arándano.....	30
Tabla 6. Resultados de la sensibilidad del reconocimiento de plagas para plantones de arándano.....	32
Tabla 7. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la sensibilidad del reconocimiento de plagas para plantones de arándano.....	32
Tabla 8. Resultados de la especificidad del reconocimiento de plagas para plantones de arándano.....	34
Tabla 9. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la especificidad del reconocimiento de plagas para plantones de arándano.....	35
Tabla 10. Resultados de certeza en el reconocimiento de plagas para plantones de arándano.....	36

ÍNDICE DE FIGURAS

Figura 1. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la verosimilitud positiva del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia.....	31
Figura 2. Campana de Gauss en t student para la verosimilitud positiva del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia.	31
Figura 3. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la sensibilidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia.....	33
Figura 4. Campana de Gauss en t student para la sensibilidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia.....	33
Figura 5. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la especificidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia.....	35
Figura 6. Campana de Gauss en t student para la especificidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia.....	35

ÍNDICE DE ECUACIONES

Ecuación 1. Fórmula para calcular dimensión sensibilidad	28
Ecuación 2. Fórmula para calcular la dimensión especificidad.....	28
Ecuación 3. Fórmula para calcular la verosimilitud positiva del reconocimiento de plagas en la planta del arándano	29

RESUMEN

El presente trabajo se realizó con el propósito de determinar la influencia de una solución de machine learning en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo en el año 2019.

El tipo de estudio fue cuasiexperimental; con una muestra constituida por 10 evaluadores que trabajan en el fundo “Agromorín” de la empresa Danper, seleccionados por su disponibilidad. Para la recolección de datos, se aplicó una ficha de observación y para el análisis de datos se utilizó la prueba t Student la cual se obtuvo con ayuda de la herramienta estadística XLSTAT en el programa Microsoft Excel.

Las dimensiones comprendidas en el reconocimiento de plagas para plantones de arándano fueron sensibilidad y especificidad, mientras que las dimensiones comprendidas en la solución de machine learning fueron adecuación funcional y usabilidad. Los resultados obtenidos demostraron un aumento tanto en sensibilidad y especificidad en la medición realizada después de la aplicación de la solución de machine learning.

Con base en lo mencionado, podemos concluir que una solución de machine learning tiene una influencia positiva en el reconocimiento de plagas para plantones de arándano.

Palabras claves: machine learning, heliothis, argyrotaenia, sensibilidad, especificidad

ABSTRACT

The present research was done with the goal of determining the influence of a machine learning solution in the recognition of plagues for blueberry seedlings in the city of Trujillo in 2019.

The type of study was quasi-experimental; with a sample of 10 evaluators that work at the “Agromorin” field property of Danper company, chosen for their availability. Moreover, an observation sheet was applied for the data collection, and the student’s test was used to analyze the data.

The dimensions include in the recognition of plagues for blueberry seedlings were sensitivity and specificity, while the dimensiones included in the machine learning solution were functional suitability and usability. The results obtained showed an increase in both sensitivity and specificity in the measurement made after the application of the machine learning solution.

Based on the above, we can conclude that a machine learning solution has a positive influence on the recognition of plagues for blueberry seedlings.

Keywords: machine learning, heliothis, argyrotaenia, sensitivity, specificity

CAPÍTULO I. INTRODUCCIÓN

1.1. Realidad problemática

El arándano, fruto perteneciente a la familia de los berries, presenta un alto crecimiento en el mercado internacional. Cifras de la producción mundial de este fruto muestran una tasa de crecimiento promedio anual de 9.1% desde el año 2010, alcanzando una producción mundial de 585 mil toneladas en el año 2014, siendo los principales países productores Estados Unidos, Canadá y la Unión Europea (Ministerio de Agricultura y Riego [MINAGRI], 2016).

El arándano, a pesar de ser un cultivo relativamente nuevo en el Perú, refleja su crecimiento en producción y exportación a gran escala. Su producción creció a una tasa promedio de 206% anual entre el año 2012 al 2018. El año pasado la producción de ese fruto registró 89,7 mil toneladas, siendo las regiones más productoras del país La Libertad y Lambayeque (MINAGRI, 2019).

Un factor importante que afecta a los cultivos ocasionando grandes pérdidas son las plagas. De acuerdo con la Organización de las Naciones Unidas para la Alimentación y Agricultura, se pierde hasta un 40% de la producción agrícola mundial a raíz de daños producidos por plagas (León, 2015).

Los agricultores y empresas dedicadas al rubro agrícola buscan controlar sus hectáreas de cultivo y detectar a tiempo la presencia de plagas. El ministerio de agricultura y riego apoya a las empresas agricultoras a controlar la propagación de plagas, causante de pérdidas considerables en la producción. Se calculó que una de las plagas con más presencia en los sembríos del país es la mosca de la fruta, la cual causa pérdidas de hasta US\$ 100 millones anuales (MINAGRI, 2019).

En los campos de cultivo de la Asociación APREMAC ubicados en Conache, se detectaron distintas plagas: mosca de botón floral, trips, pulgones, loritos y dione juno, en más del 50% de cultivos de maracuyá, perjudicando severamente la producción y generando considerables pérdidas económicas (Tu Región Informa, 2018).

Según el Centro Nacional de Información de Pesticidas, la identificación correcta de plagas ayuda a un control más fácil y eficaz; mientras que un error en la identificación puede ocasionar pérdidas de tiempo, dinero, y riesgos innecesarios (National Pesticide Information Center, 2017).

Es por esto, que los agricultores buscan encontrar plagas a tiempo en las plantas y reconocerlas acertadamente para poder plantear un control de aplicaciones adecuado. De esta manera, evitan su propagación y por consiguiente, pérdidas en números que afectan tanto a la economía del país, así como a las empresas agrícolas y productores.

Es muy común que operarios y más aún especialistas no puedan reconocer una plaga en el momento, tengan que analizarla con detenimiento o hasta hacer uso de laboratorios especializados para poder diagnosticar la plaga.

Para reconocer o diagnosticar una enfermedad en una planta se debe poseer habilidades de observación e investigación. El manejo de la plaga encontrada depende de la identificación apropiada de la enfermedad de la planta. Sin un correcto diagnóstico, sería una pérdida de tiempo, dinero y producción. Un diagnóstico adecuado de la enfermedad en una planta es vital e importante (Riley, Williamson & Maloy, 2016).

La empresa agrícola Danper, perteneciente al sector agroindustrial y exportador, produce y exporta una gran variedad de productos agrícolas, entre ellos el arándano, principal producto que ha crecido abismalmente en los últimos años. En su experiencia, las principales plagas que afectan esta planta son *Heliothis* y *Argyrotaenia*.

Por lo tanto, en el presente trabajo de investigación se tomará en cuenta los rastros que dejan las plagas *Heliothis* y *Argyrotaenia* en la planta del arándano.

Se han considerado los siguientes estudios como antecedentes del presente proyecto de investigación:

Los autores Hanson, Joy y Francis (2017) en su investigación “Plant leaf disease detection using deep learning and convolutional neural network” tuvieron como objetivo identificar el nivel de precisión en el reconocimiento de enfermedades en plantas por sus síntomas visuales. Para ello, recolectaron distintas fotografías de enfermedades las cuales fueron etiquetadas por un experto agricultor. Se enfocaron solo en las hojas y en imágenes con una resolución mayor o igual a 500 píxeles. En total, recolectaron 30,880 imágenes para entrenamiento y 2,589 para pruebas. Desarrollaron un sistema utilizando las imágenes y redes neuronales convolucionales profundas. Se obtuvo como resultado una precisión de 96.3%. Los autores llegaron a la conclusión que el uso de técnicas como deep learning y redes neuronales, son muy útiles en el reconocimiento de patrones y detección de objetos.

Los autores Ashqar y Abu-Naser (2018) en su investigación “Image-based tomato leaves diseases detection using deep learning” tuvieron como objetivo demostrar la viabilidad de las redes neuronales convolucionales para clasificar 5 enfermedades en la hoja del tomate. Para lograrlo, extrajeron 900 imágenes a color (150 x 150 píxeles) de la base de datos PlantVillage que incluyó 5 enfermedades e imágenes de hojas sanas. Para la red neuronal, utilizaron 4 capas convolucionales con la función de activación ReLu, cada una seguida de una capa Max Pooling. Luego, utilizaron una Flatten Layer y luego dos Dense Layer. Obtuvieron como resultado en promedio una precisión de 99.84% en el reconocimiento, por lo que llegaron a la conclusión que el entrenamiento de modelos de deep learning en conjuntos de datos de imágenes es un enfoque viable hacia el diagnóstico de enfermedades de cultivos usando un teléfono inteligente.

En la investigación “Image classification using deep learning”, los autores Manoj, Neelima, Harshali y Venu (2018), tuvieron como objetivo estudiar la clasificación de imágenes utilizando deep learning. Para ello, utilizaron la arquitectura de redes neuronales convolucionales AlexNet, la cual consiste en 5 capas convolucionales, 2 de submuestreo y 3 completamente conectadas. La red se entrenó utilizando una GPU GTX 580, la cual tiene una memoria de 3GB. Para las pruebas, seleccionaron 4 imágenes: anémona de mar, barómetro, estetoscopio e interferómetro de radio. Los resultados que obtuvieron fueron satisfactorios, debido a que lograron reconocer cada una de las imágenes por lo que llegaron a la conclusión que utilizar algoritmos de deep learning para la clasificación de imágenes es altamente efectivo y otorga buenos resultados.

Los autores Al-Hiary, Bani-Ahmad, Reyalat, Braik y Alrahamneh (2011) en la investigación “Fast and accurate detection and classification of plant diseases” tuvieron como objetivo determinar el nivel de precisión en el reconocimiento de plagas. Para ello, agregaron los pasos identificación y eliminación de píxeles a una solución que incluye el procedimiento desde la adquisición de la imagen hasta la extracción de características usando el método de agrupación K-means. Además, los píxeles que representan la plaga en la hoja se convirtieron de formato RGB a HSI (matiz, saturación e intensidad). El proceso de reconocimiento con una red neuronal previamente entrenada. Como resultado se obtuvo una precisión de 94.33% en promedio de las 6 clases examinadas (5 enfermedades y 1 planta sana). Los autores

concluyeron que el uso de redes neuronales y el método de agrupación K-medias respalda significativamente la detección precisa de enfermedades de la hoja de las plantas.

Los autores Ramcharan et al. (2017) en la investigación “Using transfer learning for image-based cassava disease detection” tuvieron como objetivo determinar la precisión de reconocimiento de enfermedades en la yuca. Para lograrlo, desarrollaron un sistema con el modelo de machine learning Inception V3 el cual usa transfer learning de la base de datos ImageNet de Google. Alimentaron la base de datos con un total de 15,000 imágenes usando una cámara digital Sony Cybershoot 20.2-megapíxeles. Usaron el 80% del total de imágenes para entrenamiento, 10% para la validación y 10% para las pruebas, y como resultado obtuvieron 93% de precisión de reconocimiento. Los resultados de esta investigación mostraron lo eficiente que es el reconocimiento de imágenes utilizando transfer learning en una red neuronal convolucional con el modelo Inception v3.

En el estudio “Visão computacional para detecção de doenças fúngicas na agricultura”, los autores Galvão, Carvalho y Rocha (2017), tuvieron como objetivo demostrar la influencia de la visión computacional en el reconocimiento de los hongos Cercosporiose y Ferrugem. Para ello, desarrollaron un software utilizando inteligencia artificial y visión computacional. El software recibe la imagen a ser analizada, realiza una comparación de píxeles entre la imagen a analizar y la imagen con presencia de hongos, y finalmente determina si hay presencia de hongos en la imagen en cuestión. El tiempo promedio para obtener los resultados del procesamiento de una imagen es de 2 minutos y medio, y los resultados obtenidos de las imágenes procesadas fueron correctos. Los autores llegaron a la conclusión que, a pesar de tener resultados positivos, el costo computacional del procesamiento es elevado y necesita ser optimizado.

Horn et al. (2018), en su investigación “The INaturalist species classification and detection dataset”, expusieron que la cantidad y variedad de datos utilizados influyen en el reconocimiento de imágenes. Para ello, desarrollaron INaturalist, una plataforma donde las personas que desean contribuir a mejorar el conjunto de imágenes puedan adicionarlas a través de un aplicativo móvil. Las imágenes son clasificadas por expertos y hasta el momento INAT2017 consta de 675,000 imágenes (5,000 especies). En las pruebas, los modelos de redes neuronales IncRestNetV2 e IncRestNetV2 SE

dieron los mejores resultados. Llegaron a la conclusión que INat2017 es imparcial y tiene la oportunidad de crecer junto con la comunidad. Además, a futuro se espera poder reconocer y determinar características adicionales tales como sexo, hábitat, entre otros.

Los autores Wahid, Jaison, Arun y Kumar (2018) en la investigación “Plant disease identification using image classification techniques” tuvieron como objetivo demostrar la influencia de técnicas de clasificación de imágenes en el reconocimiento de enfermedades en plantas. Los autores explicaron que, mediante el modelo Inception v3 de Tensorflow y un conjunto de imágenes de plagas que se desea reconocer, es posible reconocer la imagen con un cierto grado de precisión. Además, los autores propusieron incluir a un experto, que clasifique las imágenes al mismo tiempo que la aplicación móvil para comparar resultados y dar un diagnóstico final. De esta manera, obtienen un resultado más acertado. Finalmente, la solución propuesta será de gran utilidad cuando no se disponga de experiencia suficiente para identificar enfermedades en plantas, además se espera que la cantidad de cultivos infectados se reduzca debido al temprano y acertado diagnóstico que la aplicación móvil brinde.

Los autores Mohanty, Hughes y Salathé (2016) en su investigación “Using deep learning for image-based plant disease detection” tuvieron como objetivo determinar la arquitectura con mejores resultados. Para ello, utilizaron las arquitecturas de redes neuronales: AlexNet y GoogleNet con los mecanismos de entrenamiento: Transfer learning y Learning from Scratch y una base de datos de 54,306 fotos de plantas enfermas, las cuales dividieron en 38 categorías. Toda la información fue procesada a través de Caffe (framework de código abierto para deep learning). Usando GoogleNet, Transfer Learning, 80% de imágenes para entrenamiento y 20% para pruebas obtuvieron como resultado una precisión de 99.34% por lo que concluyeron que la mejor arquitectura para el presente estudio fue GoogleNet basado en Transfer Learning.

En el artículo, elaborado por Cáceres, Amaya y Ramos (2014), “Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de Begonia Semperflorens (flor de azúcar)”, los autores tuvieron como objetivo determinar la influencia del procesamiento de imágenes en el reconocimiento de plagas en la planta ‘flor de azúcar’. Para ello, desarrollaron un software en la plataforma Visual Express C# y utilizaron un AR Drone 2.0 para la toma de fotografías

a una distancia aproximada de 30 cm. de la planta. Se recolectaron 200 fotografías, de las cuales 10 se utilizaron para las pruebas. El resultado de acierto obtenido fue de 90,2%. Los autores precisaron que los métodos de reconocimiento facilitan el análisis de plagas en extensas áreas de cultivo y que esto trae consigo ventajas de tipo económico y social, como el ahorro de tiempo, recursos y disminución de esfuerzo físico de los trabajadores.

Los autores Adhikari, Shrestha, Baiju y Kumar (2018), en su investigación “Tomato plant diseases detection system using image processing” tuvieron como objetivo determinar el nivel de precisión en el reconocimiento de enfermedades en la planta del tomate. Para lograrlo, recolectaron un total de 520 imágenes de hojas, frutos y tallos de la planta del tomate, divididas en 4 clases: mancha gris, cranco bacteriano, tizón tardío y planta de tomate sana. Luego, con la red neuronal AlexNet entrenaron el modelo y obtuvieron como resultados un 95% para tizón tardío, 89% para cranco bacteriano y 92% para mancha gris. Los autores llegaron a la conclusión que el aumento de la data, transformando las imágenes originales brindó un mejor rendimiento del modelo. Además, mencionaron que el principal desafío fue la recolección de variadas imágenes para un mejor entrenamiento y por consecuente, una mejor detección.

Los autores Majundar, Kole, Chakraborty, y Majumder (2014) en su investigación “Review: detection & diagnosis of plant leaf disease using integrated image processing approach” tuvieron como objetivo explorar cada una de las etapas y métodos utilizados en trabajos de investigación sobre el reconocimiento de enfermedades en la hoja de una planta. En la primera etapa, las imágenes usualmente fueron capturadas por cámaras digitales. En la siguiente etapa, se resaltó sus características importantes. Luego, se eliminó el ruido y se segmentó la imagen. Finalmente, se clasifican las imágenes según el grado de presencia de una enfermedad haciendo uso de técnicas como: Percentage Infection, Support Vector Machine o Back-Propagation Neural Network. Los autores concluyeron que los métodos que se deben seguir en cada paso dependen de la hoja del cultivo que se haya considerado.

Los autores Pai y Amutha (2017) en su investigación “A review on image processing in plant disease detection” tuvieron como objetivo revisar la información encontrada en estudios enfocados en la detección de enfermedades en plantas. En un artículo de investigación, los autores implementaron un algoritmo con un enfoque de

red neural probabilística para el reconocimiento de hojas de plantas. El algoritmo funcionó con una precisión del 90% en 32 tipos de plantas. En otro artículo, se utilizó un modelo de diagnóstico CLASE (Laboratorio Central de Expertos Agrícolas). Para diagnosticar un trastorno a partir de una imagen de la hoja, se utilizan cuatro fases de procesamiento de imágenes: mejora, segmentación, extracción de características y clasificación. Los autores concluyeron que existen las dos características principales de la detección de enfermedades de las plantas son: la velocidad y la precisión.

El autor Ferentinos (2018) en su investigación “Deep learning models for plant disease detection and diagnosis” tuvo como objetivo determinar la red neuronal convolucional con mejores resultados. Para ello, utilizó 5 redes neuronales convolucionales en el estudio las cuales fueron: AlexNet, AlexNetOWTBn, GoogleNet, Overfeat, VGG. Usó Torch7 (Machine Learning Framework) y Python. Como conjunto de datos utilizó 87,848 fotografías, entre hojas infectadas y sanas (58 clases de plagas en 25 diferentes plantas). El 80% del total de imágenes fue utilizado para entrenamiento mientras que el 20% restante, para las pruebas. Los resultados obtenidos fueron en un 99.48% de tasa de éxito cuando se usó la red neuronal VGG. El autor concluyó que las redes neuronales convolucionales son adecuadas para la detección y el diagnóstico automático de enfermedades de las plantas a través del análisis de imágenes de hojas simples.

Los autores Bashish, Braik y Bani-Ahmad (2011) en su investigación “Detection and classification of leaf diseases using k-means-based segmentation and neural-networks-based classification” tuvieron como objetivo determinar el porcentaje de reconocimientos acertados en la identificación de enfermedades en hojas. Para ello, procesaron la imagen con la técnica K-means, extrajeron características y convirtieron el formato de color RGB a HSI. Utilizaron 192 imágenes para el entrenamiento como para las pruebas. Los resultados para las plagas “early scotch” y “ashen mold” fue de 100% de reconocimientos correctos, para “cottony mold”, 96%, para “late scorch”, 80%, para “tiny whitesses”, 88% y finalmente, fueron reconocidas 92% de las imágenes de hojas sanas. Los autores concluyeron que el estudio presentado puede apoyar significativamente en la detección automática de enfermedades en hojas de plantas en el área de Jordania.

Los autores Garud y Devi (2017) en su investigación “Detection of diseases on plant leaf with the help of image processing” tuvieron como objetivo proponer un

instrumento para la detección de enfermedades en hojas. Para ello, propusieron capturar imágenes con una cámara digital, extraer características de las hojas, convertir las imágenes a escala de grises y segmentar la imagen para obtener la región infectada de la hoja usando K-means clustering, K-medoids clustering y detección de bordes. De toda la investigación realizada por los autores, propusieron el uso de Raspberry pi como unidad independiente de reconocimiento debido a su tamaño y a que funciona como una PC de escritorio. El sistema autónomo propuesto ayudará a analizar las enfermedades de las plantas con mucha precisión en menos tiempo, con menos esfuerzo y sin necesidad de recurrir a una computadora fuera del campo ni a un experto.

Patil y Pawar (2017), en su investigación “Detection and classification of plant leaf disease”, tuvieron como objetivo definir el nivel de precisión de un aplicativo móvil en el reconocimiento de plagas en hojas. Para ello, desarrollaron una aplicación móvil que, al tomar una fotografía, esta es enviada a un web service para ser procesada, extraer sus características y compararla con las imágenes en la base de datos de enfermedades en plantas en busca de una coincidencia. El mejor resultado obtenido muestra una precisión de 90.98% en el reconocimiento de la enfermedad que presenta la hoja de la planta afectada. Los autores llegaron a la conclusión que utilizar estrategias de CBIR (Consulta de imágenes mediante ejemplo) en los componentes de bajo nivel de la imagen como sombras, forma y superficie incrementan la rapidez y la precisión del reconocimiento.

Los autores Sannakki, Rajpurohit, Nargund y Kulkarni (2013), en su investigación “Diagnosis and classification of grape leaf diseases using neural networks”, tuvieron como objetivo demostrar la viabilidad de la técnica K-means en el reconocimiento de plagas en la hoja de la planta de uva. Para cumplir su objetivo, recolectaron fotografías de hojas de uva con presencia de enfermedades (300x300px). Con la técnica K-means, segmentaron la fotografía en 6 partes para determinar cuál segmento presenta la plaga. En las pruebas, utilizaron 17 imágenes de plantas de uva infectadas con mildiú vellosa y 16 imágenes de mildiú polvoriento, obteniendo como resultado un 100% de precisión en el reconocimiento de ambas. Los autores llegaron a la conclusión que es necesario obtener imágenes variadas de plantas de uva, además, resaltaron que otros algoritmos de segmentación pueden ser utilizados para mejorar el proceso de reconocimiento.

El autor Petrellis (2019), en su investigación "Plant disease diagnosis for smart phone applications with extensible set of diseases", tuvo como objetivo determinar la influencia de una aplicación móvil en el diagnóstico de enfermedades en plantas. Para ello, usó la cámara de los celulares Lumia 550 y Sony Xperia XA1, con 5 y 23 megapíxeles de resolución respectivamente para recolectar entre 22 a 56 imágenes para pruebas y 6 a 8 para entrenamiento de 5 plagas de diferentes plantas. Las fotografías fueron redimensionadas a 1024x576 píxeles para un procesamiento más rápido. Para el procesamiento, utilizó distintos métodos tanto de machine learning como de árboles de decisiones. Haciendo uso de la red neural multicapas perceptrón, técnica perteneciente a machine learning, obtuvo como resultado, en promedio de las 5 enfermedades, 52.4% de sensibilidad y 88% de especificidad en el diagnóstico.

Los autores Turkoglu y Hanbay (2019) en su investigación "Plant disease and pest detection using deep learning-based features", tuvieron como objetivo determinar la influencia de deep learning en la detección de pestes y enfermedades en las plantas. Para ello, recolectaron 1956 fotografías de resolución 4000x6000 con una cámara Nikon 7200d tanto de hojas y frutos de las cuales 197 del total fueron utilizadas para las pruebas. Trabajaron en el programa MatLab y para el procesamiento de las imágenes, tuvieron en cuenta distintas arquitecturas de inteligencia artificial como: Inception V3, AlexNet, VGG16, ResNet50, entre otras; además aplicaron la técnica de transfer learning a cada arquitectura usada. Como resultado, la arquitectura VGG16 dio los mejores resultados, siendo: 96.64% en sensibilidad y 99.54% en especificidad. La arquitectura Inception v3 dio como resultados 87.05% en sensibilidad y 98.90% en especificidad.

Gulhane y Gurjar (2011), en su investigación "Detection of diseases on cotton leaves and its possible diagnosis", tuvieron como objetivo determinar la precisión de reconocimiento de enfermedades en la planta de algodón usando redes neuronales. Para ello, desarrollaron un software que realiza el reconocimiento a través de la segmentación de una imagen con un algoritmo que determina las zonas que se encuentran afectadas por alguna enfermedad. El resultado pasa a través de una red neuronal no supervisada que extrae la parte afectada por la enfermedad. La parte afectada es comparada con la base de datos de enfermedades y se procede con el reconocimiento. Los resultados obtenidos mostraron una media de 86.3% en imágenes de plantas con presencia de costras y moho. Los autores llegaron a la conclusión que

el método de segmentación de imágenes por color es bastante eficiente y puede ser utilizado para analizar varias enfermedades que afectan a la planta de algodón.

Por otro lado, el presente trabajo de investigación se justifica por las siguientes razones:

Esta investigación se realizó porque se pretende mejorar la certeza y precisión de los reconocimientos de plagas que más afectan a la planta del arándano, reemplazando al experto, mediante una aplicación móvil que tiene como base la técnica de machine learning. De esta manera, se busca agilizar el proceso de reconocimiento y generalizarlo, para que usuarios con poca experiencia en el rubro agrícola puedan reconocer plagas en sus cultivos.

Asimismo, se busca demostrar que la técnica de machine learning se puede aplicar en el rubro agrícola y es muy útil para el reconocimiento de imágenes. El impacto que genera esta novedosa técnica de inteligencia artificial es muy grande, debido a que no solo se dedica al reconocimiento de imágenes sino también, a la implementación de modelos predictivos para una mejor toma de decisiones, reconocimiento de voz, predicciones en finanzas hasta en el clima, y en cualquier otro rubro.

Por último, con el presente proyecto el agricultor con poca experiencia en identificación de plagas se verá beneficiado; además de, complementar el criterio de un agrónomo experto.

Adicionalmente, el presente proyecto presentó las siguientes limitaciones:

Fue complicado acceder libremente a los campos de cultivo para obtener las imágenes necesarias para el proyecto de investigación, por lo que las visitas a los fundos de la empresa Danper fueron programadas para poder ingresar con un trabajador del área de Investigación, Desarrollo e Innovación de la empresa mencionada.

La carencia de diversas plagas en los cultivos del arándano debido a su fenología presentó una restricción en las plagas a estudiar, por lo que se tuvo en cuenta las plagas más comunes y que están presentes a lo largo de todo el proceso de cultivo.

La disponibilidad de la conexión a internet fue una restricción debido a que los cultivos usualmente están en zonas alejadas a la ciudad por lo que la conexión puede ser débil para procesar imágenes y en algunos casos puede no haber señal. Por eso, se

implementó la opción en la aplicación de insertar imágenes desde la galería del teléfono para que así el usuario pueda recorrer los campos, tomar las fotografías y luego en un lugar con conexión a internet, procesar las imágenes.

Con relación al software implementado, se iba a utilizar la plataforma Azure para desplegar los servicios web; sin embargo, por razones de costo, se optó por la plataforma Google Cloud App Engine debido a que se puede desplegar servicios en Python de manera gratuita.

Finalmente, en la presente investigación se rescataron conceptos como:

Machine learning: Rama de inteligencia artificial con la cual un sistema aprende a partir de una base de datos. Un sistema con machine learning aprende iterativamente siendo entrenado con data para dar resultados cada vez más precisos (Hurwitz & Kirsch, 2018).

Plaga: Las plagas son organismos de biotipo vegetal o animal que causan daños en diferentes partes de la planta o productos vegetales interfiriendo con los cultivos (Zepeda-Jazo, 2018).

Heliothis: Plaga perteneciente a la familia de los lepidópteros (insectos con alas) que tiene un ciclo de vida de 44 días aproximadamente. En su mayor desarrollo mide hasta 35 mm de longitud. Pasa por 6 estados larvales donde inicialmente se alimenta perforando los pétalos de las flores y las hojas de la planta. Posteriormente migran hacia los frutos (Córdova, 2015).

Argyrotaenia: Plaga perteneciente a la familia de los lepidópteros, que cuando está en su estado de larva pequeña, busca hojas tiernas para refugiarse y alimentarse. A medida que se desarrollan dejan daños en las hojas en forma de perforaciones con una coloración marrón y unidas entre sí mediante hilos de seda (Núñez & Scatoni, 2013).

Chanchito blanco: Plaga perteneciente a la familia hemíptera, que se alimentan de la savia de las plantas. Las hembras miden aproximadamente 3 a 4 mm de longitud; mientras que, los machos son un poco más pequeños. Transmiten virus y su excreción extremadamente azucarada produce hongos (Núñez & Scatoni, 2013).

Bemisia: Plaga también conocida como mosca blanca que causa daños directos como fitotoxicidad o desórdenes fisiológicos al alimentarse de las hojas de una planta ocasionando deformación y decoloración de la planta (Cuéllar & Morales, 2006).

Botrytis cinerea: Plaga responsable del moho gris en la planta que pasa por las siguientes etapas en una infección: penetración de la superficie de la hoja de la planta, muerte del tejido de la hoja penetrada, expansión de hojas, reproducción de larvas (Choquer et al., 2007).

SCRUM: Es una metodología de desarrollo ágil de software que utiliza un enfoque incremental. Define roles y emplea un conjunto reglas y artefactos que son parte de una estructura necesaria para su correcto funcionamiento (Cadavid, Fernández & Morales, 2013). En cada iteración se trabaja con los siguientes artefactos:

Product Backlog: Lista de requerimientos que el cliente define y especifica. Está ordenada por valor y prioridad. Esta lista evoluciona a lo largo del proyecto y se basa en las historias que el usuario plantee en relación con las funciones del producto.

Sprint Backlog: Es un subconjunto de tareas del Product Backlog, el cual está más detallado. Cada cambio requerido es tomado en cuenta en el siguiente Sprint Backlog dependiendo de su prioridad.

Monitoreo de Progreso: Es la suma del trabajo que falta realizar en el Sprint. Permite evaluar el progreso del proyecto.

Incremento: Es la suma de todas las tareas terminadas en el Sprint Backlog. Se considera que una tarea está terminada si es que es funcional y cumple con lo requerido por el cliente.

ISO 25010: Es un standard internacional que define la calidad de software de un producto desde el punto de vista de calidad de uso y calidad de producto. (Haslinda et al., 2015). Dentro del modelo de calidad de producto está compuesto por ocho características de las cuales se usarán dos para el presente proyecto de investigación:

Adecuación funcional: Se refiere al grado en que un producto o sistema satisface los requerimientos solicitados por el cliente. (Haslinda et al., 2015). Las subcaracterísticas usadas en la siguiente investigación fueron:

- **Complejidad funcional:** Grado en que un conjunto de funciones cubre todas las tareas especificadas y cumple los objetivos del usuario.
- **Corrección funcional:** Grado en el que el producto o sistema resultados correctos con una precisión adecuada. (Franca & Soares, 2015)

Usabilidad: Se refiere al grado en que un producto o sistema puede ser utilizado por los usuarios para lograr objetivos específicos, con efectividad y eficiencia. (Haslinda et al., 2015). A continuación, las subcaracterísticas utilizadas en la presente investigación:

- **Capacidad de aprendizaje:** Grado en el que el sistema o producto permite al usuario aprender su uso y aplicación.
- **Capacidad para ser usado:** Grado en el que el sistema o producto permite al usuario operarlo de manera sencilla. (Franca & Soares, 2015)

Modelo Vista Vista-Modelo: Es un patrón arquitectónico que utiliza tres elementos:

Modelo: Representa la capa de datos y la lógica del negocio.

Vista: Representa a la interfaz de usuario encargada de mostrar la información y de las interacciones.

Vista-Modelo: Es el intermediario que gestiona los eventos e interacciones que ocurren en la vista. También se encarga de la lógica de la interfaz de usuario, los comandos, eventos y contiene una referencia al Modelo. (Garofalo, 2011)

1.2. Formulación del problema

¿De qué manera una solución de machine learning influye en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo en el año 2019?

1.3. Objetivos

1.3.1. Objetivo general

Determinar la influencia de una solución de machine learning en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo en el año 2019.

1.3.2. Objetivo específico

- Determinar el nivel de sensibilidad del reconocimiento de plagas para plantones de arándano con la influencia de una solución de machine learning en la ciudad de Trujillo en el año 2019.
- Determinar el nivel de especificidad del reconocimiento de plagas para plantones de arándano con la influencia de una solución de machine learning en la ciudad de Trujillo en el año 2019.
- Definir el grado de certeza del reconocimiento de plagas para plantones de arándano con una solución de machine learning en la ciudad de Trujillo en el año 2019.

1.4. Hipótesis

Una solución de machine learning influye positivamente en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo en el año 2019.

CAPÍTULO II. METODOLOGÍA

2.1. Tipo de investigación

Cuasiexperimental

2.2. Población y muestra

Población

Todos los evaluadores que trabajan en el fundo “Agromorín” de la empresa Danper.

Muestra

La muestra es de 10 evaluadores que trabajan en el fundo “Agromorín” de la empresa Danper, seleccionados por su disponibilidad.

2.3. Técnicas e instrumentos de recolección y análisis de datos

Recolección de datos

Técnicas

Para la obtención de los indicadores: verdadero positivo, falso negativo, verdadero negativo y falso positivo se usó la técnica de observación.

Instrumentos

De acuerdo con la técnica aplicada, el instrumento utilizado para los indicadores: verdadero positivo, falso negativo, verdadero negativo y falso positivo fue la Ficha de observación, la cual fue elaborada por los autores.

Análisis de datos

Para el análisis de datos se usó la herramienta XLSTAT en el programa Microsoft Excel.

2.4. Procedimiento

Para elaborar el instrumento de recolección de datos, se consideró que los indicadores: verdadero positivo, falso negativo, verdadero negativo y falso positivo podían ser deducidos con solo la respuesta de la plaga reconocida por parte del personal a cargo

de las pruebas y del aplicativo móvil. Este instrumento fue validado por el MBA Raúl Saldaña en el documento de matriz de validación (ver Anexo nro. 3), en este documento se verificó que la variable dependiente tenga relación con sus dimensiones y estas con sus indicadores.

Para obtener las fotografías de las hojas a analizar, se tuvo acceso al fundo “Agromorín”, propiedad de la empresa “Danper”, el cual tiene un tamaño aproximado de 120 hectáreas dedicadas al cultivo del arándano. Los recorridos fueron guiados por un ingeniero agrónomo especializado en la planta del arándano y sus plagas.

Las imágenes fueron tomadas con los celulares “Xiaomi Redmi Note 6” y “iPhone 7”, los cuales tienen una cámara de 12 MP.

La recolección de datos antes de la implementación de la aplicación móvil tuvo una duración de cuatro semanas y para ejecutarla se realizó lo siguiente:

1. Se solicitó a diferentes trabajadores reconocer la plaga en una hoja de la planta del arándano.
2. Se anotó en la ficha de observación el nombre de la plaga reconocida.
3. Los datos obtenidos se pasaron a una hoja de cálculo de Excel.
4. Con ayuda de un ingeniero agrónomo, se determinó si las respuestas fueron acertadas para así obtener los indicadores: verdadero positivo, falso negativo, verdadero negativo y falso positivo.

Tabla 1. *Recolección de datos antes de usar la aplicación móvil*

Evaluador/Indicador	VP	FN	VN	FP	Total
Evaluador 1	7	1	8	4	20
Evaluador 2	5	2	5	8	20
Evaluador 3	12	2	5	1	20
Evaluador 4	11	3	5	1	20
Evaluador 5	10	3	6	1	20
Evaluador 6	5	3	7	5	20
Evaluador 7	6	2	4	8	20
Evaluador 8	10	0	4	6	20
Evaluador 9	7	3	4	6	20
Evaluador 10	8	3	5	4	20
Total	81	22	53	44	200

Fuente: Elaboración propia.

La implementación de la solución de machine learning para reconocer plagas en la planta del arándano tuvo una duración de 8 semanas y se ejecutó de la siguiente manera:

1. Se determinó la metodología de desarrollo de la aplicación móvil, la cual es parte de la solución, mediante el siguiente cuadro comparativo:

 Tabla 2. *Comparación de metodologías de desarrollo de software*

Criterios	SCRUM	XP	RUP
Ciclo de vida	<ul style="list-style-type: none"> • Planeación • Puesta en escena • Desarrollo • Entrega. 	<ul style="list-style-type: none"> • Exploración • Planeación • Iteraciones • Productionizing • Mantenimiento. 	<ul style="list-style-type: none"> • Inicio • Elaboración • Construcción • Transición
Duración del proyecto	Corto	Corto	Largo
Flexibilidad	Sí	Sí	No
Comunicación con el cliente	Mucha	Mucha (cliente en sitio)	Poca
Iterativo	Sí	Sí	No
Orientado a	Al cliente	Al cliente	A los procesos

Fuente: Navarro, Fernández y Morales (2013)

Se decidió usar la metodología ágil SCRUM debido a que el proyecto implementado incluye el desarrollo de una aplicación móvil en un corto periodo de tiempo. Además, se necesita usar una metodología que sea flexible, es decir, que se adapte a las variaciones que se puedan presentar durante el desarrollo del proyecto. También, se escogió SCRUM debido a que es iterativa, es decir, permite mostrar los avances del proyecto y las funcionalidades implementadas al cliente, a fin de obtener una retroalimentación por parte de él. Asimismo, fue necesario tener en cuenta una metodología que esté orientada al cliente, es decir que cubra sus necesidades e incluya una comunicación frecuente con él. Por último, se buscó utilizar una metodología cuyo ciclo de vida se adapte a la planificación realizada para el proyecto, como es: Planificación, Puesta en escena, Desarrollo y Entrega, las cuales son iterativas y cortas por lo que se ajusta perfectamente al proyecto.

2. Haciendo uso de la metodología, para la fase de planificación se elaboró el Product Backlog, el cual contiene la lista de tareas a realizar.
3. Para la fase de puesta en escena, se elaboraron las historias de usuario, las cuales contienen el detalle de los requerimientos especificados por el usuario. En este artefacto se prioriza las funcionalidades del producto a desarrollar. Al ser una fase iterativa, puede ir variando a lo largo del desarrollo del proyecto.
4. Para la fase de desarrollo:
 - a. Se realizó la implementación de un modelo de machine learning utilizando como base la red neuronal convolucional Inception v3 y las librerías Tensorflow y Keras en el lenguaje de programación Python.
 - b. Se entrenó y afinó el modelo con las fotografías recolectadas para la investigación. Para la plaga Heliothis se utilizaron 215 fotografías para entrenamiento y 118 para validación; para Argyrotaenia, 165 y 89 respectivamente; y para plantas Sin plaga, 159 y 101 respectivamente.
 - c. Se exportó el modelo entrenado y se implementó un web service utilizando el framework Flask en el lenguaje de programación Python.
 - d. Se publicó el web service en la plataforma de Google Cloud (App Engine).
 - e. Se implementó la base de datos utilizando Cloud Firestore en la plataforma Firebase de Google.
 - f. Se implementó la aplicación móvil en el IDE Android Studio, utilizando el lenguaje de programación Kotlin para la plataforma Android.
5. Para la fase de entrega se realizó la instalación de la aplicación móvil en los dispositivos de los usuarios.

La recolección de datos después de usar la aplicación móvil tuvo una duración de dos semanas y para realizarla se ejecutaron los siguientes pasos:

1. Se adjuntó una fotografía de la hoja en cuestión para reconocer la plaga.
2. Con el resultado obtenido por la aplicación móvil, el encargado de la prueba anotó los datos obtenidos tanto para el nombre de la plaga como la precisión del resultado.
3. Los datos anotados se pasaron a una hoja de cálculo de Excel.

Tabla 3. *Recolección de datos después de usar la aplicación móvil*

Prueba/Indicador	VP	FN	VN	FP	Total
Prueba 1	13	1	5	1	20
Prueba 2	12	1	5	2	20
Prueba 3	11	3	5	1	20
Prueba 4	12	1	6	1	20
Prueba 5	11	3	5	1	20
Prueba 6	12	1	6	1	20
Prueba 7	14	0	5	1	20
Prueba 8	12	2	5	1	20
Prueba 9	13	1	5	1	20
Prueba 10	14	1	4	1	20
Total	124	14	51	11	200

Fuente: Elaboración propia.

Por último, se hizo un cálculo en base a los indicadores para obtener los valores de cada dimensión de la siguiente forma:

$$\text{Sensibilidad} = \frac{VP}{VP + FN}$$

Ecuación 1. *Fórmula para calcular dimensión sensibilidad*

VP: total de Verdaderos Positivos

FN: total de Falsos Negativos

Sensibilidad representa la probabilidad de que el resultado de la prueba sea positivo cuando se ha encontrado la plaga en la hoja.

$$\text{Especificidad} = \frac{VN}{VN + FP}$$

Ecuación 2. *Fórmula para calcular la dimensión especificidad*

VN = total de Verdaderos Negativos

FP = total de Falsos Positivos

Especificidad representa la probabilidad de que el resultado de la prueba sea negativo cuando la planta está sana o la plaga en estudio no ha sido reconocida acertadamente.

Luego, para tener un valor que represente el reconocimiento de *Heliothis* y *Argyrotaenia* en la planta del arándano, se aplicó la siguiente fórmula en los indicadores que se midieron antes de la implementación de aplicativo móvil y después de la aplicación del aplicativo móvil.

$$LR^+ = \frac{\textit{Sensibilidad}}{1 - \textit{Especificidad}}$$

Ecuación 3. *Fórmula para calcular la verosimilitud positiva del reconocimiento de plagas en la planta del arándano*

La razón de verosimilitud positiva (LR^+) es una medida de rendimiento que depende de la sensibilidad y especificidad de una prueba. Si el resultado de LR^+ es mayor a 1 esto indica que hay más posibilidades de un resultado positivo cuando se encuentra una hoja con una plaga sea *Heliothis* o *Argyrotaenia*. Esta razón de verosimilitud cuantifica el incremento sobre el conocimiento de la presencia de las plagas.

Después de haber obtenido cada valor, se aplicó la prueba estadística t Student a las mediciones que representan al reconocimiento de *Heliothis* y *Argyrotaenia* en la planta del arándano y sus dimensiones: sensibilidad y especificidad. Para ello se tomaron los datos de preprueba y posprueba de cada medición y se usó la herramienta XLSTAT del programa Microsoft Excel.

CAPÍTULO III. RESULTADOS

A continuación, se muestran e interpretan los resultados del uso de la aplicación móvil en el reconocimiento de plagas para plantones de arándano, en la ciudad de Trujillo, año 2019.

Tabla 4. Resultados de la verosimilitud positiva del reconocimiento de plagas para plantones de arándano.

Caso de prueba	Pre - Test	Post - Test	Diferencia (d)	$d_i - \bar{d}$	$(d_i - \bar{d})^2$
1	2,6250	5,5714	-2,9464	-0,3052	0,0931
2	1,1607	3,2308	-2,0701	0,5712	0,3263
3	5,1429	4,7143	0,4286	3,0698	9,4239
4	4,7143	6,4615	-1,7473	0,8940	0,7993
5	5,3846	4,7143	0,6703	3,3116	10,9666
6	1,5000	6,4615	-4,9615	-2,3203	5,3837
7	1,1250	6,0000	-4,8750	-2,2337	4,9896
8	1,6667	5,1429	-3,4762	-0,8349	0,6971
9	1,1667	5,5714	-4,4048	-1,7635	3,1099
10	1,6364	4,6667	-3,0303	-0,3890	0,1514
MEDIA	2,6122	5,2535	-2,6413	Varianza(s)	29,1099

Fuente: Elaboración propia.

Para continuar con el análisis se debe tener en cuenta las siguientes hipótesis:

H₀: El valor de verosimilitud positiva en el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning es menor o igual que el valor de verosimilitud positiva antes de usar la solución de machine learning.

H_a: El valor de verosimilitud positiva en el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning es mayor que el valor de verosimilitud positiva antes de usar la solución de machine learning.

Para comprobar las hipótesis se hizo uso de la herramienta estadística XLSTAT en el programa Microsoft Excel usando la prueba t student.

Tabla 5. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la verosimilitud positiva del reconocimiento de plagas para plantones de arándano.

Variable	Observaciones	Obs. con datos perdidos	Obs. sin datos perdidos	Mínimo	Máximo	Media	Desv. típica
Pre - test	10	0	10	1,125	7,000	3,265	2,407
Post - test	10	0	10	3,231	6,462	5,253	0,984

Fuente: Elaboración propia

Se consideró al intervalo $] -\infty; -0,495]$ de confianza para la diferencia entre las medias al 95%.

Diferencia	-1,988
t (Valor observado)	-2,441
t (Valor crítico)	-1,833
GL	9
valor-p (unilateral)	0,019
alfa	0,05

Figura 1. Análisis estadístico usando la prueba *t* student con la herramienta XLSTAT para la verosimilitud positiva del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia

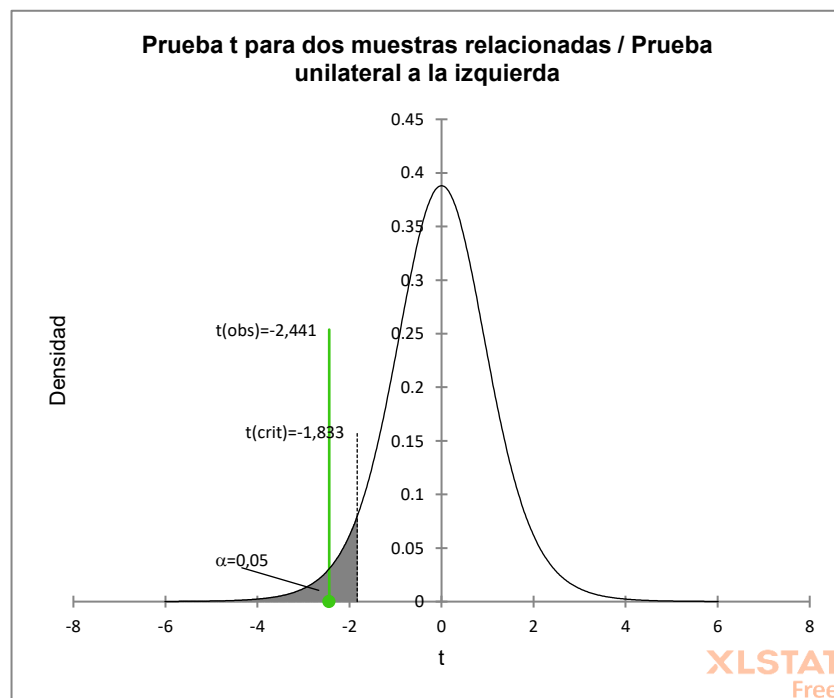


Figura 2. Campana de Gauss en *t* student para la verosimilitud positiva del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia.

Como resultado del análisis, se obtuvo el valor estadístico $t(\text{obs}) = -2,441$, que al ser mayor que el valor crítico $t(\text{crit}) = -1,833$, se encuentra en el rango de rechazo de la hipótesis nula. Es decir, permite aceptar la hipótesis alterna y se puede concluir que, existe un aumento en el valor de la verosimilitud positiva frente al reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning, por lo tanto, esta tiene una influencia positiva sobre el reconocimiento de plagas para plantones de arándano.

Análisis de la dimensión sensibilidad

A continuación, se muestran e interpretan los resultados en la dimensión sensibilidad del uso de una solución de machine learning en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo, año 2019. Los datos fueron recolectados haciendo uso de una ficha de observación (ver Anexo nro. 4B).

Tabla 6. *Resultados de la sensibilidad del reconocimiento de plagas para plantones de arándano.*

Caso de prueba	Pre - Test	Post - Test	Diferencia (d)	$d_i - \bar{d}$	$(d_i - \bar{d})^2$
1	0,8750	0,9286	-0,0536	0,0649	0,0042
2	0,7143	0,9231	-0,2088	-0,0903	0,0082
3	0,8571	0,7857	0,0714	0,1899	0,0361
4	0,7857	0,9231	-0,1374	-0,0189	0,0004
5	0,7692	0,7857	-0,0165	0,1020	0,0104
6	0,6250	0,9231	-0,2981	-0,1796	0,0323
7	0,7500	1,0000	-0,2500	-0,1315	0,0173
8	1,0000	0,8571	0,1429	0,2613	0,0683
9	0,7000	0,9286	-0,2286	-0,1101	0,0121
10	0,7273	0,9333	-0,2061	-0,0876	0,0077
MEDIA	0,7804	0,8988	-0,1185	Varianza(s)	0,0004

Fuente: Elaboración propia.

Para continuar con el análisis se debe tener en cuenta las siguientes hipótesis:

H₀: La sensibilidad obtenida en el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning es menor o igual que la sensibilidad obtenida antes de usar la solución de machine learning.

H_a: La sensibilidad obtenida en el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning es mayor que la sensibilidad obtenida antes de usar la solución de machine learning.

Para comprobar las hipótesis se hizo uso de la herramienta estadística XLSTAT en el programa Microsoft Excel usando la prueba t student.

Tabla 7. *Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la sensibilidad del reconocimiento de plagas para plantones de arándano.*

Variable	Observaciones	Obs. con datos perdidos	Obs. sin datos perdidos	Mínimo	Máximo	Media	Desv. típica
Pre - test	10	0	10	0,625	1,000	0,780	0,106
Post - test	10	0	10	0,786	1,000	0,899	0,069

Fuente: Elaboración propia

Se consideró al intervalo $] -\infty; -0,033]$ de confianza para la diferencia entre las medias al 95%.

Diferencia	-0,118
t (Valor observado)	-2,533
t (Valor crítico)	-1,833
GL	9
valor-p (unilateral)	0,016
alfa	0,05

Figura 3. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la sensibilidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia




Figura 4. Campana de Gauss en t student para la sensibilidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia

Como resultado del análisis, se obtuvo el valor estadístico $t(\text{obs}) = -2,533$, que al ser mayor que el valor crítico $t(\text{crit}) = -1,833$, se encuentra en el rango de rechazo de la hipótesis nula. Es decir, permite aceptar la hipótesis alterna y se puede concluir que, existe un aumento en la sensibilidad ante el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning, por lo tanto, esta tiene una influencia positiva en la sensibilidad sobre el reconocimiento de plagas para plantones de arándano.

Análisis de la dimensión especificidad

A continuación, se muestran e interpretan los resultados en la dimensión especificidad del uso de una solución de machine learning en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo, año 2019. Los datos fueron recolectados haciendo uso de una ficha de observación (ver Anexo nro. 4B).

Tabla 8. *Resultados de la especificidad del reconocimiento de plagas para plantones de arándano*

Caso de prueba	Pre - Test	Post - Test	Diferencia (d)	$d_i - \bar{d}$	$(d_i - \bar{d})^2$
1	0,6667	0,8333	-0,1667	0,0715	0,0051
2	0,3846	0,7143	-0,3297	-0,0915	0,0084
3	0,8333	0,8333	0,0000	0,2381	0,0567
4	0,8333	0,8571	-0,0238	0,2143	0,0459
5	0,8571	0,8333	0,0238	0,2619	0,0686
6	0,5833	0,8571	-0,2738	-0,0357	0,0013
7	0,3333	0,8333	-0,5000	-0,2619	0,0686
8	0,4000	0,8333	-0,4333	-0,1952	0,0381
9	0,4000	0,8333	-0,4333	-0,1952	0,0381
10	0,5556	0,8000	-0,2444	-0,0063	0,0000
MEDIA	0,5847	0,8229	-0,2381	Varianza(s)	0,0008

Fuente: Elaboración propia.

Para continuar con el análisis se debe tener en cuenta las siguientes hipótesis:

H₀: La especificidad obtenida en el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning es menor o igual que la especificidad obtenida antes de usar la solución de machine learning.

H_a: La especificidad obtenida en el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning es mayor que la especificidad obtenida antes de usar la solución de machine learning.

Para comprobar las hipótesis se hizo uso de la herramienta estadística XLSTAT en el programa Microsoft Excel usando la prueba t student.

Tabla 9. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la especificidad del reconocimiento de plagas para plantones de arándano.

Variable	Observaciones	Obs. con datos perdidos	Obs. sin datos perdidos	Mínimo	Máximo	Media	Desv. típica
Pre - test	10	0	10	0,333	0,857	0,595	0,218
Post - test	10	0	10	0,714	0,857	0,823	0,041

Fuente: Elaboración propia

Se consideró al intervalo $] -\infty; -0,110]$ de confianza para la diferencia entre las medias al 95%.

Diferencia	-0,228
t (Valor observado)	-3,538
t (Valor crítico)	-1,833
GL	9
valor-p (unilateral)	0,003
alfa	0,05

Figura 5. Análisis estadístico usando la prueba t student con la herramienta XLSTAT para la especificidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia




Figura 6. Campana de Gauss en t student para la especificidad del reconocimiento de plagas para plantones de arándano. Fuente: Elaboración propia

Como resultado del análisis, se obtuvo el valor estadístico $t(\text{obs}) = -3,538$, que al ser mayor que el valor crítico $t(\text{crit}) = -1,833$, se encuentra en el rango de rechazo de la hipótesis nula. Es decir, permite aceptar la hipótesis alterna y se puede concluir que, existe un aumento en la especificidad ante el reconocimiento de plagas para plantones de arándano después de usar la solución de machine learning, es decir, esta tiene una influencia positiva en la especificidad sobre el reconocimiento de plagas para plantones de arándano.

Porcentaje de certeza

A continuación, se muestran los resultados promedio obtenidos de la certeza de los reconocimientos realizados por la solución de machine learning.

Tabla 10. *Resultados de certeza en el reconocimiento de plagas para plantones de arándano.*

Caso de prueba	Promedio
1	88,00
2	90,62
3	90,27
4	89,17
5	91,91
6	88,25
7	90,14
8	90,67
9	89,85
10	92,57
Total	90,14

Fuente: Elaboración propia

Como resultado total se obtuvo 90,14% de certeza en los reconocimientos realizados por la solución de machine learning.

CAPÍTULO IV. DISCUSIÓN Y CONCLUSIONES

4.1. Discusión

En la tabla 4, se puede apreciar que el valor promedio de verosimilitud positiva en el reconocimiento de plagas para plantones de arándano fue 2,6122 antes de usar la solución de machine learning. Posteriormente, después de haberla usado, el valor obtenido fue de 5,2535. Esto demuestra un aumento de un poco más del doble de la verosimilitud positiva en el reconocimiento de plagas para plantones de arándano. Los autores Gogtay y Thatte (2019) en el artículo “Statistical evaluation of diagnostic test – Part 2” afirman que el rango de la verosimilitud positiva va de 0 a infinito positivo y que mientras sea mayor que 1 aumentan las probabilidades que el resultado de la prueba sea positivo cuando la planta en cuestión tenga la enfermedad. Por otro lado, Silva y Molina en el artículo “Likelihood ratio (razón de verosimilitud): definición y aplicación en Radiología” aportan rangos de valores de verosimilitud positiva y su impacto, en donde aseguran que un resultado entre 2 y 5 se considera de utilidad regular; mientras que un resultado entre 5 y 10 se considera de utilidad buena. Lo que nos indica que, si bien es cierto, tanto el resultado de verosimilitud positiva antes de usar la solución de machine learning y después de haberla aplicado, son mayores que 1, ésta última está en el rango de utilidad buena; mientras que el resultado pre test se encuentra en el rango de utilidad regular.

En la tabla 5, observamos que el porcentaje promedio en el reconocimiento de plagas para plantones de arándano en la dimensión sensibilidad fue 78,04% antes de usar la solución de machine learning; mientras que, después de su implementación y aplicación, el valor subió a 89,88%. Esto demuestra un aumento del 11,84%. Al comparar este resultado con el obtenido por Petrellis (2019) en su investigación “Plant

disease diagnosis for smart phone applications with extensible set of disease” notamos que la sensibilidad obtenida fue de 52.4%, que es 37.48% menor a la obtenida en el presente trabajo de investigación. Si bien es cierto, las plagas a diagnosticar fueron diferentes, se puede deducir que una razón para esta diferencia en el resultado es la poca cantidad de imágenes utilizadas para entrenamiento; mientras Petrellis utilizó un promedio de 195 fotografías; en el presente estudio se utilizaron 539.

En los resultados mostrados en la tabla 6, se aprecia que el promedio en el reconocimiento de plagas para plantones de arándano en la dimensión especificidad fue 58,47% antes de usar la solución de machine learning; mientras que, después de implementarla y aplicarla, el valor aumentó en un 23,82% llegando a 82,29%. En el artículo “Plant disease and pest detection using deep learning-based features”, los autores Turkoglu y Hanbay (2019) obtuvieron un resultado de especificidad de un 98.90% el cual es mayor que el obtenido en esta investigación. El motivo de esta diferencia puede estar relacionado con la herramienta utilizada para recolectar las imágenes. En este caso, los autores utilizaron una cámara digital Nikon 7200d; mientras que en la presente investigación se utilizó la cámara de los celulares Xiaomi Redmi Note 6 y iPhone 7. Además, otro motivo se relaciona con la cantidad de imágenes utilizadas, la cual es mayor a la nuestra por una diferencia de 709.

En los resultados mostrados en la tabla 10, se aprecia que el promedio de la certeza en el reconocimiento de plagas para plantones de arándano fue 90,14% cuando se utilizó la solución de machine learning. Los autores Ramcharan et al. (2017) en el artículo “Using transfer learning for image-based cassava disease detection” obtuvieron como resultado en la certeza del reconocimiento de enfermedades en la planta de la yuca un 93%. Al comparar este resultado con el de la presente investigación podemos relacionar esta diferencia con la herramienta utilizada para tomar las fotografías, la

cantidad de fotos y plagas a reconocer. Mientras que el artículo mencionado utiliza una cámara digital Sony Cybershoot 20.2-megapíxeles, 15,000 imágenes y 5 plagas en la planta de la yuca, la presente investigación utiliza cámaras de 12 MP de los celulares Xiaomi Redmi Note 6 y iPhone 7, 1,247 imágenes y 2 plagas en la planta del arándano. De esta comparación podemos asumir que utilizar una cámara de mayor resolución y más imágenes en el entrenamiento ayuda a obtener mejores resultados.

4.2. Conclusiones

Al finalizar el presente trabajo de investigación, se llegaron a las siguientes conclusiones:

La solución de machine learning tuvo una influencia positiva en el reconocimiento de plagas para plantones de arándano.

Se demostró la influencia de una solución de machine learning en la sensibilidad del reconocimiento de plagas para plantones de arándano.

Se demostró la influencia de una solución de machine learning en la especificidad del reconocimiento de plagas para plantones de arándano.

Se definió la certeza del resultado de una solución de machine learning en el reconocimiento de plagas para plantones de arándano.

4.3. Recomendaciones

Para futuras investigaciones basados en el mismo tema del proyecto realizado, se recomienda lo siguiente:

Realizar un análisis inicial para determinar cuáles son las plagas con mayor presencia en el campo de cultivo, su fenología, y en qué época del año se encuentran con la finalidad de ampliar el catálogo de plagas.

Implementar la funcionalidad “Seleccionar la imagen de la galería” para darle flexibilidad a la aplicación y no depender de una constante conexión a internet.

Buscar opciones gratuitas de plataformas de despliegue de servicios tal como App Engine ofrecido por la plataforma Google Cloud Platform. Además, se debe tener en cuenta la compatibilidad nativa con el lenguaje de programación usado, en este caso Python.

REFERENCIAS

- Adhikari, S., Shrestha, B., Baiju, B., & Kumar, S. (2018). Tomato plant diseases detection system using image processing. *KEC Conference on Engineering and Technology*, 1-6. Recuperado desde: https://www.researchgate.net/publication/327930730_TOMATO_PLANT_DISEASES_DETECTION_SYSTEM_USING_IMAGE_PROCESSING
- Al-Hiary, H., Bani-Ahmad, S., Reyalat, M., Braik, M., & ALRahamneh, Z. (2011). Fast and accurate detection and classification of plant diseases. *International Journal of Computer Applications*, 17 (1), 31-38. Recuperado desde: <https://pdfs.semanticscholar.org/8d7b/a3f2c0479cdd49d736f95ffbb2eb1b6840a.pdf>
- Ashqar, B., & Abu-Naser, S. (2018) Image-based tomato leaves diseases detection using deep learning. *International Journal of Academic Engineering Research*, 2 (12), 10-16. Recuperado desde: <https://philarchive.org/archive/ASHITL-3>
- Bashish, D., Braik, M., & Bani-Ahmad, S. (2011). Detection and classification of leaf diseases using k-means-based segmentation and neural-networks-based classification. *Information Technology Journal*, 10 (2), 267-275. Recuperado desde: <http://docsdrive.com/pdfs/ansinet/itj/2011/267-275.pdf>
- Bishop, C., & Winn, J. (2019). *Model-based machine learning*. Portland, Estados Unidos, Taylor & Francis Inc. Recuperado desde: <http://mbmlbook.com/>
- Cáceres, C.; Amaya, D., & Ramos, O. (2014). Procesamiento de imágenes para reconocimiento de daños causados por plagas en el cultivo de *Begonia semperflorens* (flor de azúcar). *Acta Agronómica*, 64 (3), 273-279. Recuperado desde: <http://www.scielo.org.co/pdf/acag/v64n3/v64n3a11.pdf>

Cadavid, A; Fernández, J., & Morales, J. (2013). Revisión de metodologías ágiles para el desarrollo de software, *Prospectiva*, 11 (2), 30-39. Recuperado desde: <https://dialnet.unirioja.es/descarga/articulo/4752083.pdf>

Choquer, M., Elisabeth, F., Kunz, C., Levis, C., Pradier, J., Simon, A., & Viaud, M. (2007). Botrytis cinerea virulence factors: new insights into a necrotrophic and polyphageous pathogen. *Federation of European Microbiological Societies* 277 (2007), 1-10. Recuperado desde: https://www.researchgate.net/publication/230006325_Botrytis_cinerea

Conache: Se hallan plagas y enfermedades en 11 hectáreas de cultivos de maracuyá. (20 de abril, 2018). *Tu Región Informa*. Recuperado desde: <http://www.regionlalibertad.gob.pe/NOTICIAS/regionales/8915-conache-se-hallan-plagas-y-enfermedades-en-11-hectareas-de-cultivos-de-maracuya>

Córdova, P. (2015). Fluctuación poblacional de los insectos plaga en el cultivo de espárrago *Asparagus officinalis*, en Chincha. (Tesis de titulación). Universidad Nacional Agraria La Molina, Lima, Perú. Recuperado desde: <http://repositorio.lamolina.edu.pe/bitstream/handle/UNALM/1413/H10-C67-T.pdf?sequence=3&isAllowed=y>

Cuéllar, M., & Morales, F. (2006). La mosca blanca *Bemisia tabaco* (Gennadius) como plaga vectora de virus en frijol común (*Phaseolus vulgaris* L.). *Revista Colombiana de Entomología* 32 (1): 1-9. Recuperado desde: <http://www.scielo.org.co/pdf/rcen/v32n1/v32n1a01.pdf>

Ferentinos, K. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145 (2018), 311-318. Recuperado desde: https://www.researchgate.net/publication/322941653_Deep_learning_models_for_plant_disease_detection_and_diagnosis

Franca, J., & Soares, M. (2015). SOAQM: Quality model for soa applications based on ISO 25010. Recuperado desde:

<https://pdfs.semanticscholar.org/0330/e104d36445a8fc151d915462bd9137098a4c.pdf>

Fuente, M., & Calonge, T. (1999). Aplicaciones de las redes de neuronas en supervisión, diagnóstico y control de procesos. Recuperado desde:

https://books.google.com.pe/books/about/Aplicaciones_de_las_redes_de_neuronas_en.html?id=jUHGRXd5xU8C&redir_esc=y

Galvão G., Carvalho W., & Rocha W. (2017). Visão computacional para detecção de doenças fúngicas na agricultura. *Única cadernos académicos*, 2 (4), 1-20. Recuperado de:

<http://co.unicaen.com.br:89/periodicos/index.php/UNICA/article/download/67/69>

Garofalo, R. (2011). Building enterprise applications with windows: presentation foundation and the model view viewmodel pattern. Recuperado desde:

<https://pdfs.semanticscholar.org/05b8/ad02ade416ddbf52c424eea47ba3404cf8b4.pdf>

Garud, P., & Devi, R. (2017). Detection of diseases on plant leaf with the help of image processing. *International Journal of Engineering Technology Science and Research*, 4 (8), 912-918. Recuperado desde:

<https://pdfs.semanticscholar.org/4bd8/f0e486f184a54c71d29b00a2b99222104dfa.pdf>

Gogtay, N., & Thatte, U. (2017). Statistical evaluation of diagnosis test – Part 2. *Journal of The Association of Physicians of India*, 65, 86-91. Recuperado desde:

<https://www.kem.edu/wp-content/uploads/2012/06/13-Diagnostics-tests-2-1-1.pdf>

Gulhane, V., & Gurjar, A. (2011). Detection of diseases on cotton leaves and its possible diagnosis. *International Journal of Image Proccesing*, 5 (5), 590-598. Recuperado desde:

<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.742.3496&rep=rep1&type=pdf>

Hanson, J., Joy, A., & Francis, J. (2017) Plant leaf disease detection using deep learning and convolutional neural network. *International Journal of Engineering Science and Computing*, 7 (3), 5324-5328. Recuperado desde:

https://pdfs.semanticscholar.org/2163/f1c76e8d8d17d5e6759f6bae10165706a1dd.pdf?_ga=2.194037357.1367660213.1561267927-1872780032.1561267927

Haslinda, N., Fahmy, S., Sukinan, Roslina, Fariha, Z., Azliza, S., & Shiratuddin, N. (2015). Evaluation of e-book applications using ISO 25010. Recuperado desde:

https://www.researchgate.net/publication/286439618_Evaluation_of_e-Book_Applications_Using_ISO_25010

Horn, G., Aodha, O., Song, Y., Cui, Y., Sun, C., Shepard, A., ... Belongie, S. (2018). The INaturalist species classification and detection dataset. 8769-8778. Recuperado desde: <https://arxiv.org/pdf/1707.06642.pdf>

Hurwitz, J. & Kirsh, D. (2018). *Machine learning for dummies*. New Jersey, Estados Unidos, John Wiley & Sons. Recuperado de:

<https://www.ibm.com/downloads/cas/GB8ZMQZ3>

León, J. (2015). 40% de la producción de alimento se pierde por plagas y enfermedades. *Agencia Agraria de Noticias*. Recuperado desde: <https://agraria.pe/noticias/40-de-la-produccion-de-alimento-se-pierde-8729>

Majundar, D., Kole, D., Chakraborty, A., & Majumder, D. (2014). Review: detection & diagnosis of plant leaf disease using integrated image processing approach.

International Journal of Computer Engineering and Applications, 6 (3), 1-16.

Recuperado desde:

https://www.researchgate.net/publication/282783352_REVIEW_DETECTION_DIAGNOSIS_OF_PLANT_LEAF_DISEASE_USING_INTEGRATED_IMAGE_PROCESSING_APPROACH

Manoj, M., Neelima, M., Harshali, M., & Venu, M. (2018). Image classification using deep learning. *International Journal of Engineering & Technology*, 7 (2.7), 614-617.

Recuperado desde:

https://www.researchgate.net/publication/325116934_Image_classification_using_Deep_learning

Ministerio de Agricultura y Riego [MINAGRI]. (2016). El arándano en el Perú y el mundo: Producción, Comercio y Perspectivas. Lima, Perú. Recuperado de:

http://agroaldia.minagri.gob.pe/biblioteca/download/pdf/tematicas/f-taxonomia_plantas/f01-cultivo/el_arandano.pdf

Ministerio de Agricultura y Riego [MINAGRI]. (2019). MINAGRI: Exportaciones de arándano llegaron a los US\$ 589 millones el año pasado. Lima, Perú.

Recuperado de: <https://www.gob.pe/institucion/minagri/noticias/24651-minagri-exportaciones-de-arandanos-llegaron-a-los-us-589-millones-el-ano-pasado>

Ministerio de Agricultura y Riego [MINAGRI]. (2019). Minagri: Mosca de la fruta causa pérdidas por US\$ 100 millones anuales. Recuperado desde:

<https://gestion.pe/economia/minagri-mosca-fruta-causa-perdidas-us-100-millones-anuales-254873-noticia/>

Mohanty, S., Hughes, D., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7 (1419), 1-10. Recuperado desde:

<https://www.frontiersin.org/articles/10.3389/fpls.2016.01419/full>

National Pesticide Information Center (2017). Identifique su plaga. Recuperado desde:

<http://npic.orst.edu/pest/idpest.es.html>

Navarro, A., Fernández, J., & Morales, J. (2013). Revisión de metodologías ágiles para el desarrollo de software. *Prospectiva 11* (2), 30-39. Recuperado desde:

<https://dialnet.unirioja.es/servlet/articulo?codigo=4752083>

Núñez, S., & Scatoni, I. (2013). Tecnología disponible para el manejo de plagas en frutales de hoja caduca. Instituto Nacional de Investigación Agropecuaria. Uruguay. Recuperado desde:

http://www.inia.uy/Publicaciones/Documentos%20compartidos/St%202010_2013.pdf

Pai, P., & Amutha, S. (2017). A review on image processing in plant disease detection. *International Research Journal of Engineering and Technology*, 4 (4), 2449-2450.

Recuperado desde: <https://www.irjet.net/archives/V4/i4/IRJET-V4I4503.pdf>

Patil, A., & Pawar, V. (2017). Detection and classification of plant leaf disease. *International Advanced Research Journal in Science, Engineering and Technology*, 4 (4), 72-75.

Recuperado desde: https://www.researchgate.net/publication/313819584_Detection_and_Classification_of_Plant_Leaf_Disease

Petrellis, N. (2019). Plant disease diagnosis for smart phone applications with extensible set of diseases. *Applied Science* 9 (1952), 1-22. Recuperado desde:

<https://www.mdpi.com/2076-3417/9/9/1952/pdf>

Ramcharan, A., Baranowski, K., McCloskey, P., Ahmed, B., Legg, J., & Hughes, D. (2017).

Using transfer learning for image-based cassava disease detection. *Frontiers in Plant Science*, 8 (1852), 1-10. Recuperado desde:

https://www.researchgate.net/publication/318392725_Using_Transfer_Learning_for_Image-Based_Cassava_Disease_Detection

Riley, M., Williamson, M. & Maloy, O. (2002). Plant disease diagnosis. *The Plant Health Instructor*. Recuperado desde:

<https://www.apsnet.org/edcenter/disimpactmngmnt/casestudies/Pages/PlantDiseaseDiagnosis.aspx>

Sannakki, S., Rajpurohit, V., Nargund, V., & Kulkarni, P. (2013). Diagnosis and classification of grape leaf diseases using neural networks. *International Conference on Computing, Communications and Networking Technologies*. Recuperado desde:

https://www.researchgate.net/publication/269332436_Diagnosis_and_classification_of_grape_leaf_diseases_using_neural_networks

Silvia, C., & Molina, M. (2016). Likelihood ratio (razón de verosimilitud): definición y aplicación en radiología. *Revista Argentina de Radiología*, 81 (3), 204-208.

Recuperado desde:
<https://reader.elsevier.com/reader/sd/pii/S0048761916301910?token=B9BAD785EAF84E0E29B4E0450A27CAC454EFBBD6EA34B5C6276AD40F903A7B0285FCF9D766B4A0883C6548D1DC3231A3>

Turkoglu, M., & Hanbay, D. (2019). Plant disease and pest detection using deep learning-based features. *Turkish Journal of Electrical Engineering & Computer Sciences*. 2019 (27), 1636-1651. Recuperado desde:

<http://journals.tubitak.gov.tr/elektrik/issues/elk-19-27-3/elk-27-3-6-1809-181.pdf>

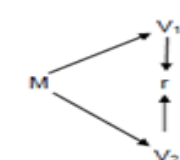
Wahid, A., Jaison, B., Arun, P., & Kumar, S. (2018). Plant disease identification using image classification techniques. *International Journal of Engineering Science and Computing*, 8 (4), 16795-16796. Recuperado desde:

<http://ijesc.org/upload/b2e4a211bbf02939e54e95e497f74bc3.Plant%20Disease%20Identification%20using%20Image%20Classification%20Techniques.pdf>

Zepeda-Jazo, I. (2018). Manejo sustentable de plagas agrícolas en México. *Agricultura, sociedad y desarrollo*, 15 (1), 99-108. Recuperado desde:
http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1870-54722018000100099&lng=es&nrm=iso#B9

ANEXOS

Anexo nro. 1. Matriz de consistencia

SOLUCIÓN DE MACHINE LEARNING EN EL RECONOCIMIENTO DE PLAGAS PARA PLANTONES DE ARÁNDANO				
PROBLEMA	HIPOTESIS	OBJETIVO GENERAL	VARIABLE 1	METODOLOGIA
¿Cómo una solución de machine learning influye en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo en el año 2019?	Una solución de machine learning influye positivamente en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo en el año 2019.	Determinar la influencia de una solución de machine learning en el reconocimiento de plagas para plantones de arándano en la ciudad de Trujillo en el año 2019.	SOLUCIÓN MACHINE LEARNING	Diseño  <p>Donde: M = Muestra V1 = SOLUCIÓN DE MACHINE LEARNING V2= RECONOCIMIENTO DE PLAGAS PARA PLANTONES DE ARÁNDANO, TRUJILLO 2019 r = relación de variables.</p>
				Población
				Todos los evaluadores que trabajan en el fundo "Agromorín" de la empresa Danper.

		OBJETIVOS ESPECIFICOS	VARIABLE 2	Muestra
		<ul style="list-style-type: none"> • Determinar el nivel de sensibilidad del reconocimiento de plagas para plantones de arándano con la influencia de una solución de machine learning en la ciudad de Trujillo en el año 2019. • Determinar el nivel de especificidad del reconocimiento de plagas para plantones de arándano con la influencia de una solución de machine learning en la ciudad de Trujillo en el año 2019. • Definir el grado de certeza del reconocimiento de plagas para plantones de arándano con una solución de machine learning en la ciudad de Trujillo en el año 2019. 	<p>RECONOCIMIENTO DE PLAGAS PARA PLANTONES DE ARÁNDANO, TRUJILLO 2019</p>	<p>La muestra es de 10 evaluadores que trabajan en el fundo "Agromorín" de la empresa Danper, seleccionados por su disponibilidad.</p>

Anexo nro. 2. Matriz de operacionalización de variables

VARIABLE INDEPENDIENTE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIONES	INDICADORES
Solución de machine learning	Enfoque que consiste en el desarrollo de un modelo formado por las suposiciones de la solución de un problema determinado de manera explícita. Este modelo se utiliza para crear un algoritmo que aprenda y razone acerca del problema por sí solo. (Basado en Winn y Bishop, 2019)	Para medir la solución de machine learning se debe tener en cuenta las características de calidad de un modelo de software según la ISO/IEC 25010, las cuales son: adecuación funcional y usabilidad. (Basado en Haslinda et al., 2015)	Adecuación funcional	Completitud funcional
				Corrección funcional
			Usabilidad	Capacidad de aprendizaje
				Capacidad para ser usado
VARIABLE DEPENDIENTE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIONES	INDICADORES
Reconocimiento de plagas para plantones de arándano	El reconocimiento de plagas es un proceso de descubrimiento, identificación y comprensión de patrones o rasgos a partir de los cuales se determina qué tipo de plaga afecta a la planta del arándano. (Basado en Calonge y De la Fuente, 1999)	El reconocimiento de plagas es medido con las siguientes dimensiones: sensibilidad y especificidad. (Basado en Petrellis, 2019)	Sensibilidad	Verdaderos positivos
				Falsos negativos
			Especificidad	Verdaderos negativos
				Falsos positivos

Anexo nro. 3. Matriz de validación de instrumento.

MATRIZ DE VALIDACIÓN

VARIABLE	DIMENSIÓN	INDICADOR	INSTRUMENTO	CRITERIOS DE EVALUACIÓN				OBSERVACIONES Y/O RECOMENDACIONES
				RELACIÓN ENTRE LA VARIABLE Y LA DIMENSIÓN		RELACIÓN ENTRE LA DIMENSIÓN Y EL INDICADOR		
				SÍ	NO	SÍ	NO	
<i>Reconocimiento de plagas para platonos de arándano</i>	<i>Sensibilidad</i>	<i>Verdaderos positivos</i>	<i>Ficha de observación Nro.1</i>	X		X		
		<i>Falsos negativos</i>		X		X		
	<i>Especificidad</i>	<i>Verdaderos negativos</i>		X		X		
		<i>Falsos positivos</i>		X		X		

MATRIZ DE VALIDACIÓN DE INSTRUMENTO

NOMBRE DEL INSTRUMENTO: Ficha de observación Nro. 1

OBJETIVO: Recoger datos para hallar los valores necesarios para las mediciones pre test y post test de los indicadores de la variable dependiente.

APELLIDOS Y NOMBRES DEL EVALUADOR:

SALDAÑA CABRERA RAUL FERNANDO

GRADO ACADÉMICO DEL EVALUADOR:

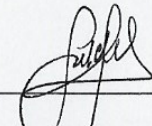
MAGISTER EN ADMINISTRACIÓN DE EMPRESAS POR LA UNIVERSIDAD DEL PACÍFICO

VALORACIÓN:

Aprobado Desaprobado

41074256

DNI



DANPER MULLILLO SAC

Raúl Saldaña C.
GERENTE DE TI
TECNOLOGÍAS DE LA INFORMACIÓN

Anexo nro. 4. Ficha de observación.

Anexo nro. 4 A. Descripción del instrumento.

Nombre	Ficha de observación
Objetivo	<p>Recoger datos para hallar los valores necesarios para las mediciones pre test y post test de los indicadores de la variable dependiente.</p>
Procedimiento	<p>Se seguirán los siguientes pasos:</p> <ol style="list-style-type: none"> 1. Se procede a mostrar la imagen de la hoja a analizar. 2. Se anota la respuesta que puede ser: Heliothis, Argyrotaenia o Sin plaga. 3. Se calcula el valor de los indicadores para cada caso de prueba realizado.
Público objetivo	Investigador

Anexo nro. 4 B. Diseño del instrumento.

FICHA DE OBSERVACIÓN

Nombre y apellidos del personal de pruebas: _____

Fecha y hora de la prueba: _____

Instrucciones:

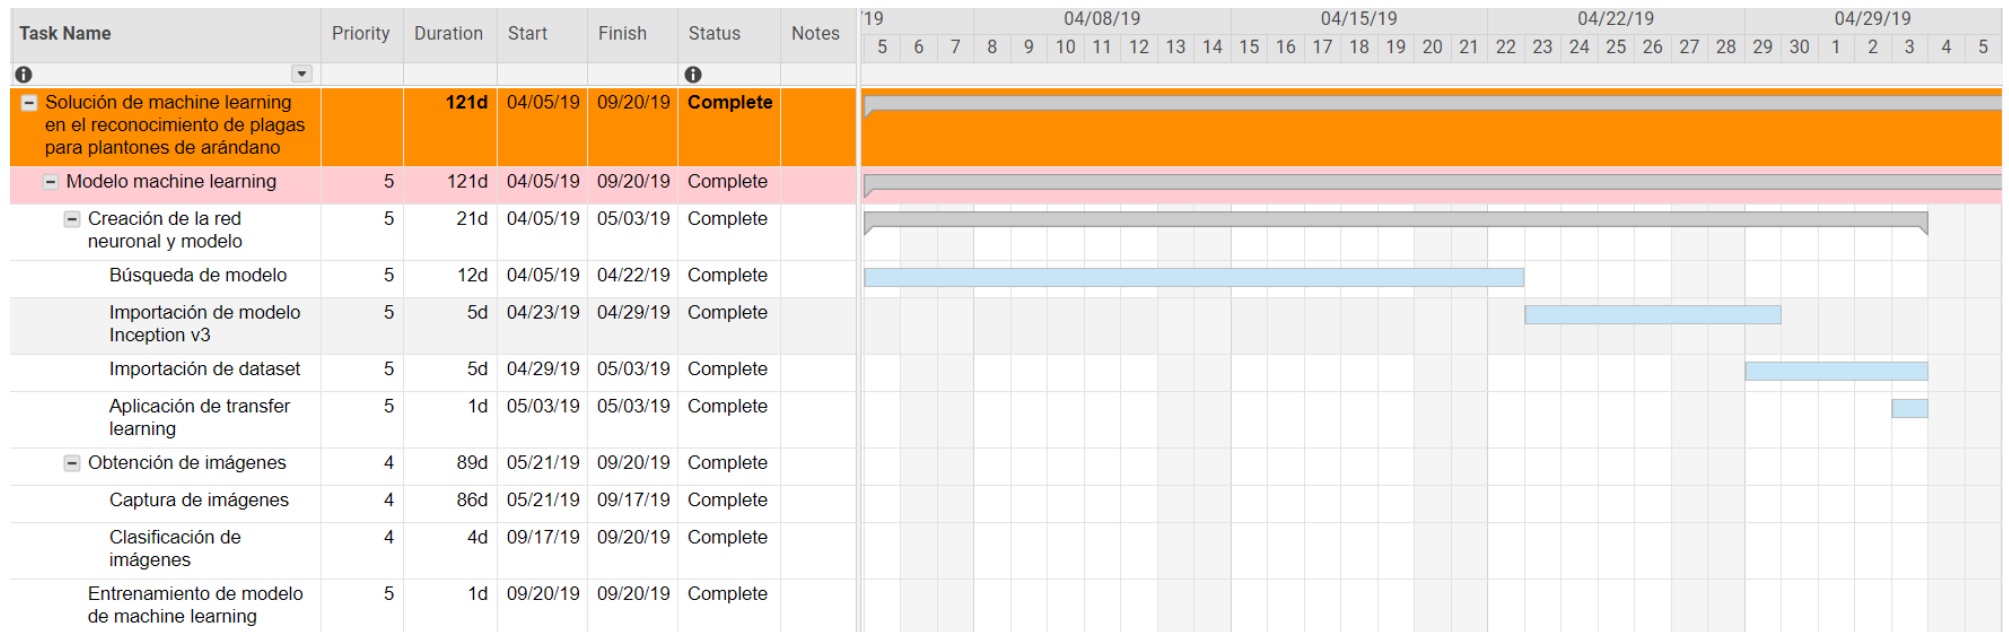
1. Analizar la hoja de la planta del arándano.
2. Anotar la plaga que se ha reconocido:

Nro. de reconocimiento	Experto	Resultado	Indicador
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			
11			
12			
13			
14			
15			
16			
17			
18			
19			
20			

Indicador	VP	FN	VN	FP				
<table border="1" style="width: 100%; height: 100%;"> <tr> <td style="width: 50%; text-align: center;">Evaluador</td> <td style="width: 50%;"></td> </tr> <tr> <td style="width: 50%; text-align: center;">Evaluador 1</td> <td style="width: 50%;"></td> </tr> </table>	Evaluador		Evaluador 1					
Evaluador								
Evaluador 1								

Anexo nro. 5. Documentación de metodología de software SCRUM

Diagrama de Gantt



Task Name	Priority	Duration	Start	Finish	Status	Notes	05/13/19							05/20/19							05/27/19							06/03/19							06/10/19						
							15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	1	2	3	4	5	6	7	8	9	10	11	12	13	14				
							i																																		
- Publicación del modelo	4	1d	09/20/19	09/20/19	Complete																																				
Creación de Web Service	4	1d	09/20/19	09/20/19	Complete																																				
Publicación de Web Service	4	1d	09/20/19	09/20/19	Complete																																				
- Aplicación móvil	3	28d	05/15/19	06/21/19	Complete																																				
- Login	2	6d	05/15/19	05/22/19	Complete																																				
Diseño de la interfaz	2	4d	05/15/19	05/20/19	Complete																																				
Autenticación de usuario	2	2d	05/19/19	05/20/19	Complete																																				
Gestión de roles y permisos	2	2d	05/21/19	05/22/19	Complete																																				
- Listado de reconocimientos	3	5d	05/23/19	05/29/19	Complete																																				
Diseño de la interfaz	3	3d	05/23/19	05/27/19	Complete																																				
Obtención de listado de reconocimientos	3	3d	05/27/19	05/29/19	Complete																																				
- Reconocimiento de plaga	5	11d	05/30/19	06/13/19	Complete																																				
Diseño de la interfaz	5	3d	05/30/19	06/03/19	Complete																																				
Captura de imagen	5	3d	06/03/19	06/05/19	Complete																																				
Selección de imagen de la galería	5	3d	06/06/19	06/10/19	Complete																																				
Mostrar resultado	5	3d	06/08/19	06/11/19	Complete																																				

Task Name	Priority	Duration	Start	Finish	Status	Notes	Gantt Chart																											
							15/27/19	30	31	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
Reconocimiento de plaga	5	11d	05/30/19	06/13/19	Complete		[Task bar from 05/30/19 to 06/13/19]																											
Diseño de la interfaz	5	3d	05/30/19	06/03/19	Complete		[Task bar from 05/30/19 to 06/03/19]																											
Captura de imagen	5	3d	06/03/19	06/05/19	Complete		[Task bar from 06/03/19 to 06/05/19]																											
Selección de imagen de la galería	5	3d	06/06/19	06/10/19	Complete		[Task bar from 06/06/19 to 06/10/19]																											
Mostrar resultado	5	3d	06/08/19	06/11/19	Complete		[Task bar from 06/08/19 to 06/11/19]																											
Mostrar descripción de la plaga reconocida	5	3d	06/11/19	06/13/19	Complete		[Task bar from 06/11/19 to 06/13/19]																											
Guardar reconocimiento	3	3d	06/14/19	06/18/19	Complete		[Task bar from 06/14/19 to 06/18/19]																											
Carga de imagen al servidor de archivos	3	2d	06/14/19	06/17/19	Complete		[Task bar from 06/14/19 to 06/17/19]																											
Guardar reconocimiento	3	3d	06/16/19	06/18/19	Complete		[Task bar from 06/16/19 to 06/18/19]																											
Validar reconocimiento guardado	3	4d	06/18/19	06/21/19	Complete		[Task bar from 06/18/19 to 06/21/19]																											
Diseño de interfaz	3	2d	06/18/19	06/19/19	Complete		[Task bar from 06/18/19 to 06/19/19]																											
Lista de reconocimientos filtrados por: Pendiente, Validado y Descartado	3	2d	06/20/19	06/21/19	Complete		[Task bar from 06/20/19 to 06/21/19]																											

Historias de usuario

Identificador (ID) de la historia	Rol	Característica / Funcionalidad	Razón / Resultado	Historia de Usuario
HUP01	Usuario	Capturar o adjuntar una fotografía de una planta infectada	Reconocer la plaga encontrada en la fotografía.	COMO Usuario QUIERO Capturar o adjuntar una fotografía de una planta infectada PARA Reconocer la plaga encontrada en la fotografía.

Identificador (ID) de la historia	Rol	Característica / Funcionalidad	Razón / Resultado	Historia de Usuario
HUS01	Usuario	Registrarme en la aplicación	Realizar reconocimientos de plagas	COMO Usuario QUIERO Registrarme en la aplicación PARA Realizar reconocimientos de plagas
HUS02	Usuario	Ingresar a la aplicación a través de un usuario y contraseña	Tener acceso a mi historial de reconocimientos	COMO Usuario quiero Ingresar a la aplicación a través de un usuario y contraseña para Tener acceso a mi historial de reconocimientos
HUS03	Usuario	Guardar reconocimientos de plagas	Tener un historial	COMO Usuario quiero Guardar reconocimientos de plagas para Tener un historial
HUS04	Usuario	Ver mi historial de reconocimientos	Revisarlo cuando lo necesite.	COMO Usuario quiero Ver mi historial de reconocimientos para Revisarlo cuando lo necesite.
HUS05	Usuario	Cerrar sesión	Salir de la aplicación.	COMO Usuario quiero Cerrar sesión para Salir de la aplicación.

Identificador (ID) de la historia	Rol	Característica / Funcionalidad	Razón / Resultado	Historia de Usuario
HUE01	Experto	Ver la lista de reconocimientos guardados por los usuarios	Validar los resultados de la aplicación	COMO Experto QUIERO Ver la lista de reconocimientos guardados por los usuarios PARA Validar los resultados de la aplicación

Plan de pruebas

Nombre del proyecto	Solución de Machine Learning en el reconocimiento	Navegador/App:	Croplague
No. Caso de prueba	1	Versión:	1.0
Escrito por	Renzo Delgado Pajares, Gloria Obeso Li	Descripción:	Aplicación móvil para reconocer Heliothis y Argyrotaenia en la planta del
Probado por	Noé Solier, Lerner Castro	Probado en:	Xiaomi Redmi Note 7 / Android 9.0

Historia de Usuario	Prueba #	Acción	Resultados esperados	Resultados actuales	Aprobado	Observaciones
Como usuario quiero capturar o adjuntar una fotografía de una planta infectada para reconocer la plaga encontrada en la fotografía.	Características	Capturar o adjuntar una fotografía de una planta infectada				
	Caso Prueba 1	Capturar una fotografía de una planta infectada con reconocimiento exitoso				
	Paso 1	Hacer clic en la opción Cámara	Debe acceder a la cámara del dispositivo	Accede a la cámara del dispositivo	SI	
	Paso 2	Realizar la captura de la imagen	Debe mostrar la fotografía capturada	Muestra la fotografía capturada	SI	
	Paso 3	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Procesando imagen"	Muestra el mensaje de carga: "Procesando imagen"	SI	
			Debe mostrar como resultado la plaga reconocida (Heliothis o Argyrotaenia) incluyendo su porcentaje de exactitud en una barra horizontal donde a más porcentaje, más relleno de color verde tendrá, y viceversa.	Muestra una barra horizontal donde a más porcentaje de exactitud, más relleno de color verde tiene.	SI	
			Debe mostrar una descripción de la plaga reconocida.	Muestra una descripción de la plaga reconocida.	SI	
			Debe mostrar tratamientos contra la plaga reconocida.	Muestra tratamientos contra la plaga reconocida.	SI	
	Caso Prueba 2	Adjuntar una fotografía de una planta infectada con reconocimiento exitoso				
	Paso 1	Hacer clic en la opción Galería	Debe acceder a la galería del dispositivo	Permite acceder a la galería del dispositivo	SI	
	Paso 2	Hacer clic en la foto deseada	La foto seleccionada debe sombrearse	Sombrea la foto seleccionada	SI	
	Paso 3	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Procesando imagen"	Muestra el mensaje de carga: "Procesando imagen"	SI	
			Debe mostrar como resultado la plaga reconocida (Heliothis o Argyrotaenia) incluyendo su porcentaje de exactitud en una barra horizontal donde a más porcentaje, más relleno de color verde tendrá, y viceversa.	Muestra una barra horizontal donde a más porcentaje de exactitud, más relleno de color verde tiene.	SI	
			Debe mostrar una descripción de la plaga reconocida.	Muestra una descripción de la plaga reconocida.	SI	
			Debe mostrar tratamientos contra la plaga reconocida.	Muestra tratamientos contra la plaga reconocida.	SI	
	Caso Prueba 3	Capturar una fotografía de una planta infectada con reconocimiento fallido				
	Paso 1	Hacer clic en la opción Cámara	Debe acceder a la cámara del dispositivo	Permite acceder a la cámara del dispositivo	SI	
	Paso 2	Realizar la captura de la imagen	Debe mostrar la fotografía capturada	Muestra la fotografía capturada	SI	
	Paso 3	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Cargando"	Muestra el mensaje de carga: "Cargando"	SI	
			Debe mostrar el mensaje: "No se ha detectado presencia de plaga"	Muestra el mensaje de carga: "No se ha detectado presencia de plaga"	SI	
	Caso Prueba 4	Adjuntar una fotografía de una planta infectada con reconocimiento fallido				
	Paso 1	Hacer clic en la opción Galería	Debe acceder a la galería del dispositivo	Permite acceder a la galería del dispositivo	SI	
	Paso 2	Hacer clic en la foto deseada	La foto seleccionada debe sombrearse	Sombrea la foto seleccionada	SI	
	Paso 3	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Cargando"	Muestra el mensaje de carga: "Cargando"	SI	
Debe mostrar el mensaje: "No se ha detectado presencia de plaga"			Muestra el mensaje de carga: "No se ha detectado presencia de plaga"	SI		

Nombre del proyecto	Solución de Machine Learning en el reconocimiento de plagas para	Navegador/App:	Croplague
No. Caso de prueba	2	Versión:	2.0
Escrito por	Renzo Delgado Pajares, Gloria Obeso Li	Descripción:	Aplicación móvil para reconocer Heliothis y Argyrotaenia en la planta del
Probado por	Noé Solier, Lerner Castro	Probado en:	Xiaomi Redmi Note 7 / Android 9.0

Historia de Usuario	Prueba #	Acción	Resultados esperados	Resultados actuales	Aprobado	Observaciones
Como usuario quiero capturar o adjuntar una fotografía de una planta infectada para reconocer la plaga encontrada en la fotografía.	Características					
	Capturar o adjuntar una fotografía de una planta infectada					
	Caso Prueba 1					
	Capturar una fotografía de una planta infectada con reconocimiento exitoso					
	Paso 1	Hacer clic en el botón con el ícono de imagen	Debe mostrar las opciones "Cámara" y "Galería"	Muestra las opciones "Cámara" y "Galería".	SI	
	Paso 2	Hacer clic en la opción "Cámara"	Debe abrir la cámara del celular			
	Paso 3	Realizar la captura de la imagen	Debe mostrar la fotografía capturada	Muestra la fotografía capturada	SI	
	Paso 4	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Cargando"	Muestra el mensaje de carga: "Cargando"	SI	
			Debe mostrar como resultado la plaga reconocida (Heliothis o Argyrotaenia) incluyendo su porcentaje de exactitud en una barra horizontal donde a más porcentaje, más relleno de color verde tendrá, y viceversa.	Muestra una barra horizontal donde a más porcentaje de exactitud, más relleno de color verde tiene.	SI	
			Debe mostrar una descripción de la plaga reconocida.	Muestra una descripción de la plaga reconocida.	SI	
			Debe mostrar tratamientos contra la plaga reconocida.	Muestra tratamientos contra la plaga reconocida.	SI	
	Caso Prueba 2					
	Adjuntar una fotografía de una planta infectada con reconocimiento exitoso					
	Paso 1	Hacer clic en la opción Galería	Debe acceder a la galería del dispositivo	Permite acceder a la galería del dispositivo	SI	
	Paso 2	Hacer clic en la foto deseada	La foto seleccionada debe sombrearse	Sombrea la foto seleccionada	SI	
	Paso 3	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Cargando"	Muestra el mensaje de carga: "Cargando"	SI	
			Debe mostrar como resultado la plaga reconocida (Heliothis o Argyrotaenia) incluyendo su porcentaje de exactitud en una barra horizontal donde a más porcentaje, más relleno de color verde tendrá, y viceversa.	Muestra una barra horizontal donde a más porcentaje de exactitud, más relleno de color verde tiene.	SI	
			Debe mostrar una descripción de la plaga reconocida.	Muestra una descripción de la plaga reconocida.	SI	
			Debe mostrar tratamientos contra la plaga reconocida.	Muestra tratamientos contra la plaga reconocida.	SI	
	Caso Prueba 3					
	Capturar una fotografía de una planta infectada con reconocimiento fallido					
	Paso 1	Hacer clic en la opción Cámara	Debe acceder a la cámara del dispositivo	Permite acceder a la cámara del dispositivo	SI	
	Paso 2	Realizar la captura de la imagen	Debe mostrar la fotografía capturada	Muestra la fotografía capturada	SI	
	Paso 3	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Cargando"	Muestra el mensaje de carga: "Cargando"	SI	
Debe mostrar el mensaje: "No se ha detectado presencia de plaga"			Muestra el mensaje de carga: "No se ha detectado presencia de plaga"	SI		
Caso Prueba 4						
Adjuntar una fotografía de una planta infectada con reconocimiento fallido						
Paso 1	Hacer clic en la opción Galería	Debe acceder a la galería del dispositivo	Permite acceder a la galería del dispositivo	SI		
Paso 2	Hacer clic en la foto deseada	La foto seleccionada debe sombrearse	Sombrea la foto seleccionada	SI		
Paso 3	Hacer clic en la opción Confirmar	Debe mostrar el mensaje de carga: "Cargando"	Muestra el mensaje de carga: "Cargando"	SI		
		Debe mostrar el mensaje: "No se ha detectado presencia de plaga"	Muestra el mensaje de carga: "No se ha detectado presencia de plaga"	SI		

Nombre del proyecto	Solución de Machine Learning en el reconocimiento de plagas para plantones de	Navegador/App:	Croplague
No. Caso de prueba	1	Versión:	1.0
Escrito por	Renzo Delgado Pajares, Gloria Obeso Li	Descripción:	Aplicación móvil para reconocer Heliothis y Argyrotaenia en la planta del arándano
Probado por	Noé Solier, Lerner Castro	Probado en:	Xiaomi Redmi Note 7 / Android 9.0

Historia de Usuario	Prueba #	Acción	Resultados esperados	Resultados actuales	Aprobado	Observaciones	
Como usuario quiero registrarme en la aplicación para realizar reconocimientos de plagas	Características Registrarme en la aplicación						
	Caso Prueba 1 Ingresar correo electrónico, nombre de usuario y contraseña						
	Paso 1	Ingresar correo electrónico	Debe permitir un correo electrónico válido.	Permite ingresar un correo electrónico válido	SI		
	Paso 2	Ingresar nombre de usuario	Debe permitir un nombre de usuario.	Permite ingresar un nombre de usuario	SI		
	Paso 3	Ingresar contraseña	Debe permitir una contraseña mínimo de 6 caracteres.	Permite ingresar una contraseña	SI		
	Paso 4	Repetir contraseña	Debe permitir la misma contraseña ingresada anteriormente.	Permite ingresar contraseña ingresada anteriormente	SI		
	Paso 5	Hacer clic en la opción Registrarse	Debe mostrar el menú principal	Muestra el menú principal	SI		
	Caso Prueba 2 Ingresar correo electrónico, nombre de usuario y contraseña en blanco						
	Paso 1	No ingresa correo electrónico	Debe mostrar un mensaje: "Ingresar un Email".	Muestra el mensaje: "Ingresar un Email".	SI		
	Paso 2	No ingresa nombre de usuario	Debe mostrar un mensaje: "Ingresar un Nombre".	Muestra el mensaje: "Ingresar un Nombre".	SI		
	Paso 3	No ingresa contraseña	Debe mostrar un mensaje: "Ingrese una Contraseña".	Muestra el mensaje: "Ingrese una Contraseña".	SI		
	Paso 4	No repite contraseña	Debe mostrar un mensaje: "Repita la contraseña".	Muestra el mensaje: "Repita la contraseña".	SI		
	Paso 5	Hacer clic en la opción Registrarse	No debe permitir el registro de nuevo usuario.	No permite el registro de nuevo usuario	SI		
	Caso Prueba 3 Ingresar correo electrónico, nombre de usuario y contraseña no válido						
	Paso 1	Ingresar correo electrónico no válido	Debe mostrar un mensaje: "Ocurrió un error al registrar el usuario"	Muestra el mensaje: "Ocurrió un error al registrar el usuario"	SI		
	Paso 2	Ingresar contraseña no válida	Debe mostrar un mensaje: "Ocurrió un error al registrar el usuario"	Muestra el mensaje: "Ocurrió un error al registrar el usuario"	SI		
	Paso 3	La contraseña repetida no coincide	Debe mostrar un mensaje: "Las contraseñas no coinciden"	Muestra el mensaje: "Las contraseñas no coinciden".	SI		
	Paso 4	Haga clic en la opción Registrarse	No debe permitir el registro de nuevo usuario.	No permite el registro de nuevo usuario	SI		
	Como usuario quiero ingresar a la aplicación a través de un usuario y contraseña para tener acceso a mi historial de reconocimientos	Características Ingresar a la aplicación a través de un correo electrónico y contraseña					
		Caso Prueba 1 Ingresar correo electrónico y contraseña correcta					
Paso 1		Ingresar correo electrónico correcto	Debe permitir un correo electrónico válido, registrado en la aplicación	Permite ingresar un correo electrónico registrado en la aplicación	SI		
Paso 2		Ingresar contraseña correcta	Debe permitir una contraseña válida	Permite ingresar una contraseña	SI		
Paso 3		Hacer clic en la opción Iniciar sesión	Debe mostrar el menú principal	Muestra el menú principal	SI		
Caso Prueba 2 Ingresar correo electrónico y contraseña incorrecta							
Paso 1		Ingresar correo electrónico incorrecto	Debe mostrar el mensaje: "Ocurrió un error al iniciar sesión"	Muestra mensaje: "Ocurrió un error al iniciar sesión"			
Paso 2		Ingresar contraseña incorrecta	Debe mostrar el mensaje: "Ocurrió un error al iniciar sesión"	Muestra mensaje: "Ocurrió un error al iniciar sesión"			
Paso 3		Hacer clic en la opción Iniciar sesión	No debe permitir el inicio de sesión	No permite el inicio de sesión			
Caso Prueba 3 Ingresar correo electrónico y contraseña en blanco							
Paso 1		No ingresa correo electrónico	Debe mostrar el mensaje: "Ingrese su usuario"	Muestra mensaje: "Ingrese su usuario"	SI		
Paso 2		No ingresa contraseña	Debe mostrar el mensaje: "ingrese su contraseña"	Muestra mensaje: "Ingrese su contraseña"	SI		
Paso 3		Hacer clic en la opción Iniciar sesión	No debe permitir el inicio de sesión	No permite el inicio de sesión	SI		

Como usuario quiero guardar reconocimientos de plagas para tener un historial	Características Guardar reconocimientos de plagas					
	Caso Prueba 1 Guardado de reconocimiento exitoso					
	Paso 1	Hacer clic en la opción Guardar reconocimiento	Debe mostrar un mensaje de: "Guardando"	Muestra el mensaje: "Guardando"	SI	
			Debe mostrar un mensaje de: "Reconocimiento guardado"	Muestra el mensaje: "Reconocimiento guardado"	SI	
	Caso Prueba 2 Guardado de reconocimiento fallido					
Paso 1	Hacer clic en la opción Guardar reconocimiento	Debe mostrar un mensaje de: "Guardando"	Muestra el mensaje: "Guardando"	SI		
		Debe mostrar un mensaje de: "No se pudo guardar el reconocimiento"	Muestra el mensaje: "No se pudo guardar el reconocimiento"	SI		
Como usuario quiero ver mi historial de reconocimientos para revisarlo cuando lo necesite	Características Ver historial de reconocimientos					
	Caso Prueba 1 Ver historia de reconocimientos exitoso					
	Paso 1	Acceder a la aplicación	Debe mostrar los reconocimientos con la fotografía, nombre de la plaga reconocida y la fecha en formato: Día de Mes Año, Hora (Minutos y Segundos)	Muestra los reconocimientos con la fotografía, nombre de la plaga reconocida y la fecha en formato: Día de Mes Año, Hora (Minutos y Segundos)	SI	
	Paso 1	Hacer clic en el reconocimiento	Debe mostrar la fotografía del reconocimiento, el porcentaje de exactitud, descripción de la plaga y tratamiento contra la plaga.	Muestra la fotografía del reconocimiento, el porcentaje de exactitud, descripción de la plaga y tratamiento contra la plaga.	SI	
	Caso Prueba 2 Ver historial de reconocimientos fallido					
	Paso 1	Acceder a la aplicación	Debe mostrar un mensaje de error: "Ocurrió un error al cargar los reconocimientos".	Muestra un mensaje de error: "Ocurrió un error al cargar los reconocimientos".	SI	
	Caso Prueba 3 No hay reconocimientos					
Paso 1	Acceder a la aplicación	Debe mostrar un mensaje: "Aún no has analizado ninguna imagen"	Muestra el mensaje: "Aún no has analizado ninguna imagen"	SI		
Como usuario quiero cerrar sesión para salir de la aplicación	Características Cerrar sesión					
	Caso Prueba 1 Cerrar sesión					
	Paso 1	Hacer clic en el menú colapsado (símbolo de tres puntos)	Debe mostrar un pequeño menú con las opciones: "Configuración" y "Salir"	Muestra un pequeño menú con las opciones: "Configuración"	SI	
	Paso 2	Hacer clic en la opción Salir	Debe mostrar el mensaje: ¿Desea salir de la aplicación? Con las opciones: Aceptar / No	Muestra el mensaje: ¿Desea salir de la aplicación? Con las opciones: Aceptar / No	SI	
	Paso 3	Hacer clic en la opción Aceptar	Debe mostrar la pantalla de inicio de sesión	Muestra la pantalla de inicio de sesión	SI	

Nombre del proyecto	Solución de Machine Learning en el reconocimiento de plagas para plantones de arándano	Navegador/App:	Croplague
No. Caso de prueba	1	Versión:	1.0
Escrito por	Renzo Delgado Pajares, Gloria Obeso Li	Descripción:	Aplicación móvil para reconocer Heliothis y Argyrotaenia en la planta del arándano
Probado por	Noé Solier, Lerner Castro	Probado en:	Xiaomi Redmi Note 7 / Android 9.0

Historia de Usuario	Prueba #	Acción	Resultados esperados	Resultados actuales	Aprobado	Observaciones
Como experto quiero ver la lista de reconocimientos guardados por los usuarios para validar los resultados de la aplicación	Características Ver la lista de reconocimientos guardados por los usuarios					
	Caso Prueba 1 Ver la lista de reconocimientos guardados					
	Paso 1	Iniciar sesión con un usuario con el rol de experto agrónomo.	Debe iniciar la aplicación	Inicia la aplicación	SI	
	Paso 2	Hacer clic en el menú colapsado (símbolo de tres puntos alineados verticalmente ubicado en la parte de arriba-derecha).	Debe mostrar la opción Validar	Muestra la opción Validar	SI	
	Paso 3	Hacer clic en la opción "Validar".	Debe mostrar la lista de reconocimientos guardados	Muestra la lista de reconocimientos guardados	SI	
	Paso 4	Hacer clic en el reconocimiento a validar.	Debe mostrar la imagen del reconocimiento a validar en grande	Muestra la imagen del reconocimiento a validar en grande	SI	
	Paso 5	Hacer clic en la opción Heliothis / Argyrotaenia / Descartar	Debe mostrar un mensaje: ¿Desea confirmar validación?	Muestra un mensaje: ¿Desea confirmar validación?	SI	
	Paso 6	Hacer clic en SÍ / NO	Debe mostrar la lista de reconocimiento guardados restantes a validar	Muestra la lista de reconocimiento guardados restantes a validar	SI	Deben mostrarse dos pestañas más en donde se guarden los reconocimientos que ya han sido validados y los descartados.

Detalles de la implementación

Tarea	Pasos	Fases
1. Modelo machine learning	1.1.Creación de la red neuronal y modelo	1.1.1. Búsqueda de modelo
		1.1.2. Importación de modelo
		1.1.3. Importación de dataset
		1.1.4. Aplicación de transfer learning
	1.2.Obtención de imágenes	1.2.1. Captura de imágenes
		1.2.2. Clasificación de imágenes
	1.3.Entrenamiento	
	1.4.Publicación del modelo	1.4.1. Creación de Web Service
1.4.2. Publicación de Web Service		
2. Aplicación móvil	2.1.Login	
	2.2.Listado de reconocimiento	
	2.3.Reconocimiento de plaga	
	2.4.Guardar reconocimiento	
	2.5.Validar reconocimiento guardado	

1. Modelo machine learning

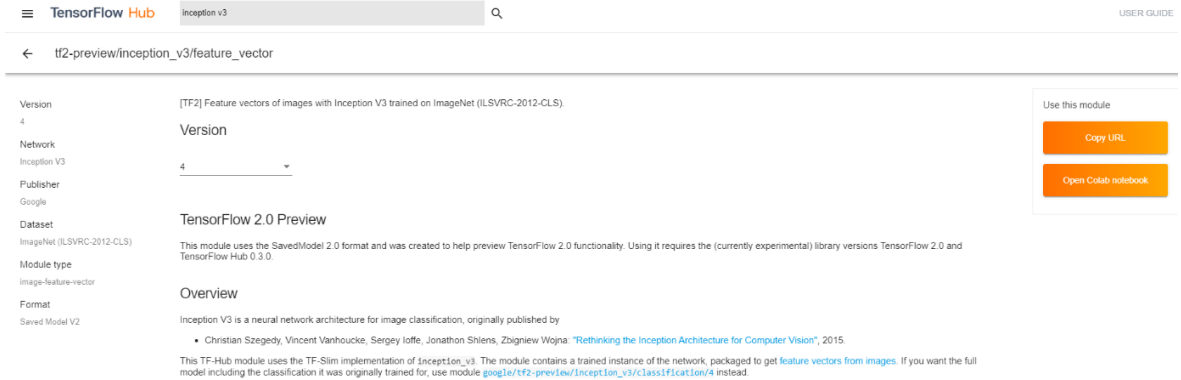
1.1. Creación de la red neuronal y modelo

1.1.1. Búsqueda de modelo

Para desarrollar la solución de machine learning, se decidió utilizar la técnica de transfer learning, que consiste en utilizar un modelo de red neuronal pre entrenado, con la finalidad de ahorrar recursos de hardware y a la vez tener mejores resultados.

Gracias a que esta técnica permite reusar un modelo que ya “aprendió” a reconocer otros tipos de objetos, con unos pequeños ajustes podemos aprovechar y utilizar este modelo para complementar el entrenamiento de la red neuronal que se desea implementar para reconocer plagas.

El modelo que se decidió utilizar fue Inception v3, el cual es un modelo de reconocimiento de imágenes muy utilizado que ya ha sido entrenado con la base de datos ImageNet. Inception v3 demuestra un buen desempeño en sus resultados, por lo cual se eligió para aplicarle transfer learning.



The screenshot shows the TensorFlow Hub page for the model 'tf2-preview/inception_v3/feature_vector'. The page includes a search bar, a navigation menu, and a main content area with the following details:

- Version:** 4
- Network:** Inception V3
- Publisher:** Google
- Dataset:** ImageNet (ILSVRC-2012-CLS)
- Module type:** Image-feature-vector
- Format:** Saved Model V2

The main content area contains the following text:

[TF2] Feature vectors of images with Inception V3 trained on ImageNet (ILSVRC-2012-CLS)

Version

4

TensorFlow 2.0 Preview

This module uses the SavedModel 2.0 format and was created to help preview TensorFlow 2.0 functionality. Using it requires the (currently experimental) library versions TensorFlow 2.0 and TensorFlow Hub 0.3.0.

Overview

Inception V3 is a neural network architecture for image classification, originally published by

- Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, Zbigniew Wojna: "Rethinking the Inception Architecture for Computer Vision", 2015.

This TF-Hub module uses the TF-Slim implementation of Inception_v3. The module contains a trained instance of the network, packaged to get feature vectors from images. If you want the full model including the classification it was originally trained for, use module [google/tf2-preview/inception_v3/classification/4](#) instead.

On the right side, there are two buttons: "Copy URL" and "Open Colab notebook".

El modelo se obtuvo de la plataforma Tensorflow-Hub, la cual es un repositorio de modelos de machine learning que pueden ser utilizados con la librería Tensorflow, la cual fue la elegida para desarrollar el modelo de la solución.

```
24 CLASSIFIER_URL = "https://tfhub.dev/google/tf2-preview/inception_v3/feature_vector/4"
25
26
27 def main():
28     #Transfer learning
29     feature_extractor = hub.KerasLayer(CLASSIFIER_URL,
30                                     input_shape=(TAM_IMG, TAM_IMG, 3))
31     feature_extractor.trainable = False
32
```

1.1.2. Importación del modelo

Se hace la importación del modelo Inception v3 para poder trabajar sobre sus capas y aplicar transfer learning. Esto se logra a través de la URL provista por Tensorflow Hub, la cual permite importar el modelo en Tensorflow (Python). En la documentación del modelo Inception v3 se indica que el tamaño de las imágenes debe ser de 299 x 299 píxeles por lo que se redimensionaron a esta resolución. Es importante especificar que las capas del modelo importado no serán entrenadas nuevamente, para ello se utilizó la propiedad "trainable", la cual inicializada con valor "false" indica que esta sección del modelo no se verá alterada en la fase de entrenamiento.

1.1.3. Importación de dataset

Se asignan las rutas de las carpetas que contienen las imágenes del dataset a las variables correspondientes. Se tienen dos grupos de imágenes, el grupo de entrenamiento y el grupo de validación, las cuales sirven para comprobar que la red neuronal se encuentra aprendiendo y así indica el porcentaje de exactitud de los resultados. En este caso se tienen las carpetas “training” y “validation” dentro de las cuales están las carpetas: “argyrotaenia”, “heliiothis” y “saludable”.

```
33 #Ruta_Subdirectorios
34 #Train
35 train_heliiothis_dir = os.path.join(DIR_ENTRENAMIENTO, 'argyrotaenia')
36 train_argyrotaenia_dir = os.path.join(DIR_ENTRENAMIENTO, 'heliiothis')
37 train_saludable_dir = os.path.join(DIR_ENTRENAMIENTO, 'saludable')
38
39 #Validation
40 val_heliiothis_dir = os.path.join(DIR_VALIDACION, 'argyrotaenia')
41 val_argyrotaenia_dir = os.path.join(DIR_VALIDACION, 'heliiothis')
42 val_saludable_dir = os.path.join(DIR_VALIDACION, 'saludable')
43
44 #Obtenemos el conteo de la cantidad de imagenes de cada subdirectorio
45 num_train_heliiothis = len(os.listdir(train_heliiothis_dir))
46 num_train_argyrotaenia = len(os.listdir(train_argyrotaenia_dir))
47 num_train_saludable = len(os.listdir(train_saludable_dir))
48
49 num_val_heliiothis = len(os.listdir(val_heliiothis_dir))
50 num_val_argyrotaenia = len(os.listdir(val_argyrotaenia_dir))
51 num_val_saludable = len(os.listdir(val_saludable_dir))
52
53
54 total_train = num_train_argyrotaenia + num_train_heliiothis + num_train_saludable
55 total_val = num_val_argyrotaenia + num_val_heliiothis + num_train_saludable
56
57 #Imprimir Cantidad de imagenes de cada subdirectorio
58 print('Total de imágenes de Heliiothis: ', num_train_heliiothis)
59 print('Total de imágenes de Argyrotaenia: ', num_train_argyrotaenia)
60 print('Total de imágenes de Saludable: ', num_train_saludable)
61
```

```

62     #GENERAR IMAGENES DE ENTRENAMIENTO
63
64     image_gen_train = ImageDataGenerator(
65         rescale=1. / 255)
66
67     train_data_gen = image_gen_train.flow_from_directory(batch_size=BATCH_SIZE,
68                                                         directory=DIR_ENTRENAMIENTO,
69                                                         shuffle=True,
70                                                         target_size=(TAM_IMG, TAM_IMG),
71                                                         class_mode='binary')
72
73     print(train_data_gen)
74
75     #GENERAR IMAGENES DE VALIDACIÓN
76
77     image_gen_val = ImageDataGenerator(rescale=1. / 255)
78
79     val_data_gen = image_gen_val.flow_from_directory(batch_size=BATCH_SIZE,
80                                                     directory=DIR_VALIDACION,
81                                                     target_size=(TAM_IMG, TAM_IMG),
82                                                     class_mode='binary')
    
```

1.1.4. Aplicación de transfer learning

Se aplica transfer learning agregando las ultimas capas con los nuevos grupos de imágenes a reconocer.

```

84     #Definición del modelo
85     model = tf.keras.models.Sequential([
86         feature_extractor,
87         tf.keras.layers.Dense(3, activation='softmax')
88     ])
89
90
91     #Compilar el modelo
92     model.compile(optimizer='adam',
93                 loss='sparse_categorical_crossentropy',
94                 metrics=['accuracy'])
95
96     model.summary()
97
98     #Entrenar modelo
99     history = model.fit_generator(
100         train_data_gen,
101         steps_per_epoch=int(np.ceil(total_train / float(BATCH_SIZE))),
102         epochs=EPOCHS,
103         validation_data=val_data_gen,
104         validation_steps=int(np.ceil(total_val / float(BATCH_SIZE)))
105     )
106
    
```

Para el entrenamiento se consideraron 15 iteraciones, cantidad necesaria para que la red muestre resultados óptimos.

Aquí, podemos observar cómo en cada iteración, el porcentaje de exactitud tanto del entrenamiento como la validación incrementa, mientras el porcentaje de pérdida disminuye.

```
Epoch 15/15
1/17 [>.....] - ETA: 31s - loss: 0.2444 - acc: 0.9062
2/17 [==>.....] - ETA: 29s - loss: 0.2915 - acc: 0.9062
3/17 [====>.....] - ETA: 27s - loss: 0.2693 - acc: 0.9167
4/17 [=====>.....] - ETA: 24s - loss: 0.3119 - acc: 0.8862
5/17 [=====>.....] - ETA: 22s - loss: 0.2990 - acc: 0.8903
6/17 [=====>.....] - ETA: 21s - loss: 0.2855 - acc: 0.8984
7/17 [=====>.....] - ETA: 19s - loss: 0.2726 - acc: 0.9041
8/17 [=====>.....] - ETA: 17s - loss: 0.2757 - acc: 0.9004
9/17 [=====>.....] - ETA: 15s - loss: 0.2692 - acc: 0.9046
10/17 [=====>.....] - ETA: 13s - loss: 0.2649 - acc: 0.9079
11/17 [=====>.....] - ETA: 11s - loss: 0.2600 - acc: 0.9107
12/17 [=====>.....] - ETA: 9s - loss: 0.2608 - acc: 0.9129
13/17 [=====>.....] - ETA: 7s - loss: 0.2673 - acc: 0.9075
14/17 [=====>.....] - ETA: 5s - loss: 0.2602 - acc: 0.9120
15/17 [=====>.....] - ETA: 3s - loss: 0.2569 - acc: 0.9137
16/17 [=====>.....] - ETA: 1s - loss: 0.2583 - acc: 0.9132
17/17 [=====>.....] - 56s 3s/step - loss: 0.2550 - acc: 0.9165 - val_loss: 0.3073 - val_acc: 0.8790
```

1.2. Obtención de imágenes

1.2.1. Captura de imágenes

Las imágenes fueron capturadas en el día en un horario de 8-10 am y nos enfocamos sólo en las hojas de la planta de arándano. Se utilizó la cámara de los equipos de gama media Xiaomi Redmi Note 6 y iPhone 7. La captura se realizó a una distancia de la hoja de aproximadamente 5 cm. aunque luego las imágenes fueron cortadas para enfocarnos solo en las hojas y evitar fondos. Se capturaron 1247 imágenes en total, entre imágenes con la plaga *Argyrotaenia*, *Heliothis* e imágenes de hojas saludables.

1.2.2. Clasificación de imágenes

Para la clasificación de imágenes se requirió la ayuda de un experto en el tema, los cuales fueron Noé Solier y Lerner Castro, ingenieros agrónomos que trabajan en el fundo “Agromorín” de la empresa Danper. De las imágenes capturadas, para el entrenamiento se utilizaron 165 para *Argyrotaenia*, 215 para *Heliothis* y 159 para Saludable; mientras que para validación se

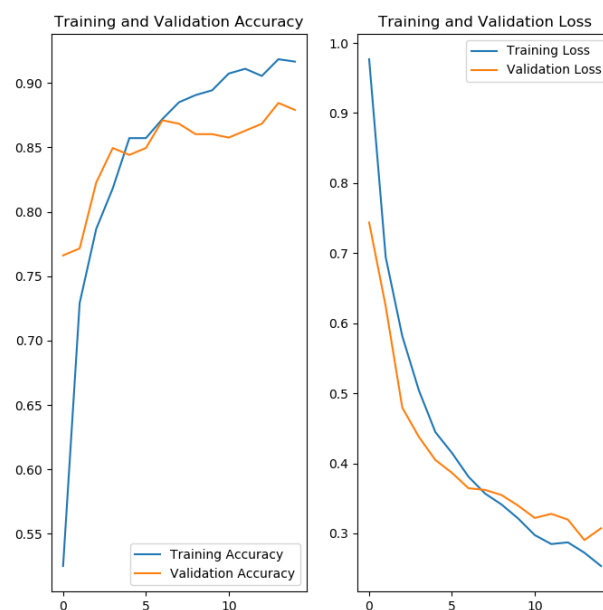
utilizaron 89 para *Argyrotaenia*, 118 para *Heliothis* y 101 para Saludable. Para las pruebas se utilizaron en total 200 imágenes entre *Argyrotaenia*, *Heliothis* y Saludable las cuales se repartieron 20 para cada evaluador.

1.3. Entrenamiento

Para el entrenamiento se consideraron 15 iteraciones, cantidad necesaria para que la red muestre resultados óptimos.

Aquí, podemos observar cómo en cada iteración, el porcentaje de exactitud tanto del entrenamiento como la validación incrementa, mientras el porcentaje de pérdida disminuye.

```
Epoch 15/15
1/17 [>.....] - ETA: 31s - loss: 0.2444 - acc: 0.9062
2/17 [=>.....] - ETA: 29s - loss: 0.2915 - acc: 0.9062
3/17 [====>.....] - ETA: 27s - loss: 0.2693 - acc: 0.9167
4/17 [=====>.....] - ETA: 24s - loss: 0.3119 - acc: 0.8862
5/17 [=====>.....] - ETA: 22s - loss: 0.2990 - acc: 0.8903
6/17 [=====>.....] - ETA: 21s - loss: 0.2855 - acc: 0.8984
7/17 [=====>.....] - ETA: 19s - loss: 0.2726 - acc: 0.9041
8/17 [=====>.....] - ETA: 17s - loss: 0.2757 - acc: 0.9004
9/17 [=====>.....] - ETA: 15s - loss: 0.2692 - acc: 0.9046
10/17 [=====>.....] - ETA: 13s - loss: 0.2649 - acc: 0.9079
11/17 [=====>.....] - ETA: 11s - loss: 0.2600 - acc: 0.9107
12/17 [=====>.....] - ETA: 9s - loss: 0.2608 - acc: 0.9129
13/17 [=====>.....] - ETA: 7s - loss: 0.2673 - acc: 0.9075
14/17 [=====>.....] - ETA: 5s - loss: 0.2602 - acc: 0.9120
15/17 [=====>.....] - ETA: 3s - loss: 0.2569 - acc: 0.9137
16/17 [=====>.....] - ETA: 1s - loss: 0.2583 - acc: 0.9132
17/17 [=====>.....] - 56s 3s/step - loss: 0.2550 - acc: 0.9165 - val_loss: 0.3073 - val_acc: 0.8790
```



1.4. Publicación del modelo

1.4.1. Creación de Web Service

Para la creación del web service que permite exponer el api de reconocimiento de plagas de arándano, se utilizó el micro-framework de Python Flask.

El web service recibe la imagen a reconocer en formato base64, el cual es decodificado y redimensionado a 299 x 299 pixeles para así ser validado con el modelo entrenado.

Los resultados son devueltos en formato JSON con los porcentajes de exactitud para cada uno de los posibles resultados.

```
19 def get_model():
20     global model
21     global graph
22     model = load_model('plagas_arandano_inception.h5', custom_objects={'KerasLayer':hub.KerasLayer})
23     graph = tf.get_default_graph()
24     print('* Model Loaded')
25
26
27 def preprocess_image(image, target_size):
28     if image.mode != "RGB":
29         image = image.convert("RGB")
30     image = image.resize(target_size)
31     image = img_to_array(image)
32     image = np.expand_dims(image, axis=0)
33     image = image/255
34     return image
35
36 def preprocess_input(x):
37     x /= 255.
38     x -= 0.5
39     x *= 2.
40     return x
41
```

```
54 @app.route('/predict', methods=['POST'])
55 def predict():
56     message = request.get_json(force=True)
57     encoded = message["image64"]
58     decoded = base64.b64decode(encoded)
59     image = Image.open(io.BytesIO(decoded))
60
61     processed_image = preprocess_image(image, target_size=(299,299))
62
63     prediction = model.predict(processed_image).tolist()
64
65     response = {
66         'prediccion': {
67             'argyrotaenia': prediction[0][0],
68             'heliiothis': prediction[0][1],
69             'saludable': prediction[0][2]
70         }
71     }
72     return jsonify(response)
```

1.4.2. Publicación de Web Service

```
C:\Users\Renzo\Desktop\Tesis\Keras\Flask\servicio_inception>gcloud app deploy
Services to deploy:

descriptor: [C:\Users\Renzo\Desktop\Tesis\Keras\Flask\servicio_inception\app.yaml]
source: [C:\Users\Renzo\Desktop\Tesis\Keras\Flask\servicio_inception]
target project: [inception3tesis]
target service: [default]
target version: [20191006t215030]
target url: [https://inceptionv3tesis.appspot.com]

Do you want to continue (Y/n)?
```

Utilizando la consola de administración de Google Cloud, se ejecuta el comando “gcloud app deploy” para iniciar la publicación del web service en la plataforma app engine.

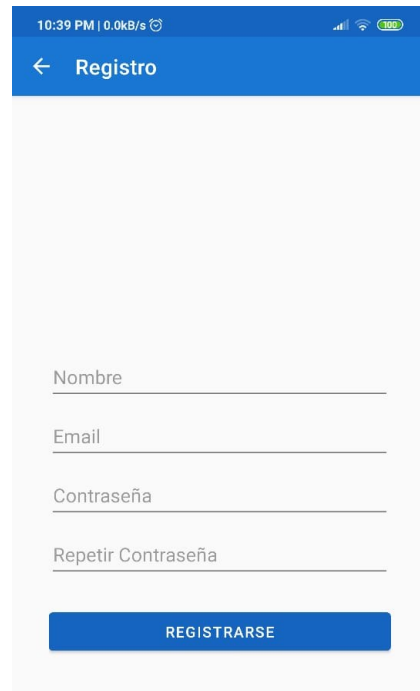
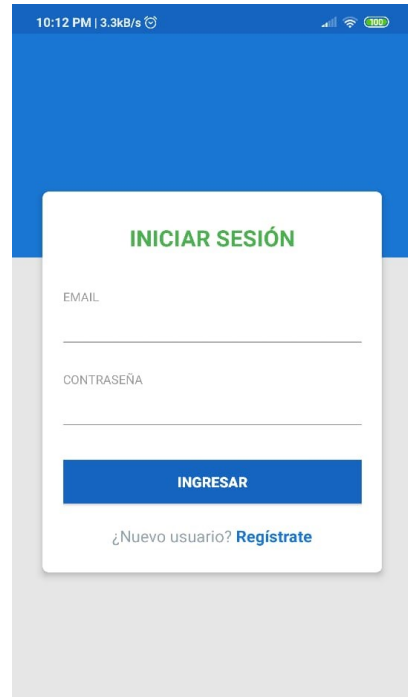
```
C: > Users > Renzo > Desktop > Tesis > Keras > Flask > servicio_inception > ! app.yaml
1  runtime: python
2  env: flex
3  entrypoint: gunicorn -b :$PORT main:app
4
5  runtime_config:
6    python_version: 3
7  manual_scaling:
8    instances: 1
9  resources:
10   cpu: 1
11   memory_gb: 2
12   disk_size_gb: 10
```

Primero se configuran los parámetros a utilizar en el servidor los cuales son: versión 3.6 de Python, y los datos base del servidor. Asimismo, se incluye un txt con la lista de librerías a ser instaladas en el servidor.

```
requirements.txt: Bloc de notas
Archivo Edición Formato Ver Ayuda
tensorflow==1.13.1
Flask==0.12.4
numpy==1.16.4
tensorflow-hub==0.4.0
Pillow==6.0.0
tf-nightly==1.14.1.dev20190518
tf-estimator-nightly==1.14.0.dev2019051801
click==6.7
itsdangerous==0.24
Jinja2==2.10
MarkupSafe==1.0
Werkzeug==0.14.1
gunicorn
```

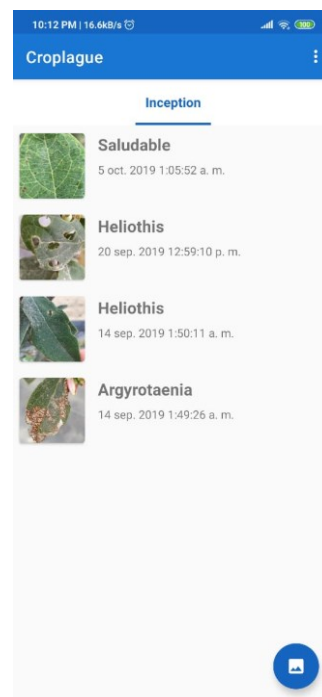

2. Aplicación Móvil

2.1. Login




Tipo de usuario	Permisos
Administrador	Puede validar los reconocimientos guardados por los usuarios.
Evaluador	Puede reconocer plagas y guardar los reconocimientos que desee.

2.2. Listado de reconocimiento




2.3. Reconocimiento de plaga



Resultado

Argyrotaenia




Características

Los huevos apenas ovipositados, presentan un color crema - amarillo, son aplanados y de forma ovalada - alargada, eclosionan en un promedio de 9 días.

Su ciclo tiene una duración entre 30 a 59 días. Las larvas desde sus primeros instares unen mediante hilos de seda las hojas o las vainas, las cuales les sirven de refugio, desde donde empiezan a alimentarse a partir de la epidermis de las vainas.

En su estado adulto tiene una longevidad de 5.8 ± 1.3 días, con una longitud promedio de 6.4 mm y 16.8 mm de expansión alar.

Se caracteriza porque en reposo semeja la silueta de una campana y además se puede llegar a observar en la parte dorsal de las alas anteriores una mancha que semeja a una "T".



2.4. Guardar reconocimiento



2.5. Validar reconocimiento guardado

