

# Modelo de reconocimiento de plaga de trips en los cultivos del aguacate mediante las Redes Neuronales Convolucionales

## Avocado crop thirpc pest recognition model using convolutional neural

Joselyn Huamán Ampuero<sup>A</sup>, Marleny Peralta Ascue<sup>B</sup> y Julio Cesar Lloclli Champi<sup>C</sup>

**Resumen**—La producción de la palta desempeña un papel importante en la satisfacción de las necesidades nutricionales alimentaria a nivel mundial. Las enfermedades en las plantas es un fenómeno bastante común que dificulta la producción bruta y causa enormes pérdidas a los agricultores. En este contexto, la detección precoz de la enfermedad del TRIPS es esencial para la producción sana. Esta investigación es desarrollada en el modelo de ResNet18, un enfoque basado en redes neuronales convolucionales (CNN) para detectar enfermedad del TRIPS, dado que, ocasiona una pérdida total en la mayoría en las paltas en quitasol Abancay, en cuanto a, utilizando imágenes de las hojas de la palta (aguacate), este modelo se desempeña especialmente para el reconocimiento de enfermedad de esta, en el lugar de quitasol Abancay utilizando un novedoso aprendizaje profundo por medio de imágenes que conforman un conjunto de datos específicos de la región y se clasifica en dos clases como son Trips y Sanas de la palta, en rendimiento de ResNet18 se evalúa con una media de exactitud, precisión, recall del 99.24%, 98.94% y 99.29% respectivamente, en una validación de VGG-16 con una medición, precisión, recall 96.78%, 96.77% y 95.74% respectivamente, con una variación superior a la del modelo como VGG-16. ResNet18 puede ser útil en la detección de síntomas temprano de la enfermedad de TRIPS, lo que en última instancia conduce a una mayor producción de aguacate

**Palabras clave:** máximoRedes Neuronales Convolucionales (CNN), Trips, Enfermedades de la palta

**Abstract**— Avocado production plays an important role in meeting the world's nutritional food needs. Plant disease is a fairly common phenomenon that hampers gross production and causes huge losses to growers. In this context, early detection of TRIPS disease is essential for healthy production. This research is developed on the ResNet18 model, an approach based on convolutional neural networks (CNN) to detect TRIPS disease, since, it causes a total loss in most avocados in quitasol Abancay, as for, using images of avocado leaves, this model performs especially for the recognition of avocado disease, in the place of quitasol Abancay using a novel deep learning by means of images that conform a set of specific data of the region and is classified in two classes as they are Trips and Healthy of the avocado, in ResNet18 performance is evaluated with an average of accuracy, precision, recall of 99. 24%, 98.94% and 99.29% respectively, in a VGG-16 validation with a measurement, accuracy, recall 96.78%, 96.77% and 95.74% respectively, with a higher variation than the model as VGG-16. ResNet18 can be useful in detecting early symptoms of TRIPS disease, ultimately leading to higher avocado yield.

**Keywords:** Convolutional Neural Networks (CNN), Avocado diseases, Thrips, Avocado Disease.

## 1 INTRODUCCIÓN

La palta se cultiva en más de 20 países, principalmente en regiones tropicales y subtropicales [1]. Las enfermedades en la palta son uno de los principales conductores a la pérdida de la producción. La gravedad de las enfermedades de la palta es un parámetro importante para medirlas y pueda utilizarse para predecir el rendimiento y recomendar los tramientos correspondientes. El diagnóstico rápido y preciso

de la gravedad de la enfermedad ayudará a reducir pérdidas en el rendimiento, y su identificación de las enfermedades suele ser visualmente por el ojo humano de los agricultores alrededor del mundo.

La palta es un árbol, conocido en muchos países como la palta en (Quechua) avocado en (Inglés) pertenece a la familia laurácea su fruto puede alcanzar de un tamaño 2-4 cm en su etapa madura, entre las variedades tenemos Hass, Fuerte [2]. Así mismo, Las enfermedades en la palta son varias, el Trips

### Autores:

- ORCID iD** <https://orcid.org/0009-0000-1390-0890>  
Joselyn Huamán Ampuero, Universidad Nacional Micaela Bastidas de Apurímac-Perú, [161146@unamba.edu.pe](mailto:161146@unamba.edu.pe)
- ORCID iD** <https://orcid.org/0000-0002-0708-8565>  
Maleny Peralta Ascue, Universidad Nacional Micaela Bastidas de Apurímac-Perú, [mperalta@unamba.edu.pe](mailto:mperalta@unamba.edu.pe)
- ORCID iD** <https://orcid.org/0000-0001-7856-8702>  
Julio Cesar Lloclli Champi, Universidad Nacional Micaela Bastidas de Apurímac-Perú, [jilloccli@unamba.edu.pe](mailto:jilloccli@unamba.edu.pe)

[3], [4], ocasiona atrofia debido a inyección de la saliva y toxina en hojas y tallos tiernos, esto ocasiona aborto de las flores, ocasiona perdidas desde el 50% al 100% en su producción.

La oferta de la palta ha experimentado un crecimiento promedio anual a nivel mundial del 14% en los últimos cinco años. Los países de América, generaron exportaciones más significativas hasta el 66% del total a nivel mundial, tenemos a México liderando, seguido por República Dominicana y Perú [1]. Así mismo, el consumo de la palta se ha visto en crecimiento en todo el mundo en los últimos años, y la variedad de Hass es el más popular por los consumidores. Esta tendencia ha sido provocada en parte por los cambios en los hábitos dietéticos hacia productos más sanos, por otro lado, el mercado se ha ido familiarizando cada vez más con esta especie. La palta, conocido por su sabor, así como por sus numerosos beneficios para la salud y sus variados usos culinarios, tiene una gran versatilidad y adaptabilidad transcultural, la producción de la palta tiene una tendencia de crecimiento en un 7% con 8,4 millones de toneladas, uno de los productores es México haciendo una representación de 3,16% millones de toneladas, anuales, otro país que exporta es Perú con una tasa muy significativa de las 36,360 toneladas [3], [4], [5], así mismo, Apurímac exportaría durante los 5 años venideros, un total de 360 toneladas por campaña con destino hacia Europa [6], [7], la aparición de enfermedades en las plantas reviste una gran importancia, ya que repercute directamente en la cantidad y calidad, estas enfermedades se atribuyen a factores como hongos, bacterias virus, etc. La identificación y detección temprana de estas enfermedades permitiría aplicar medidas preventivas, así minimizando las pérdidas tanto productivas como económicas. En el pasado, la clasificación y detección de enfermedades dependía en gran medida de la observación visual por parte de expertos [8]. Sin embargo, este enfoque suele resultar poco práctico debido a falta de expertos en zonas remotas y a la lentitud del proceso. Como solución, la aparición de herramientas como análisis de imágenes ha demostrado eficaz para detección de enfermedades en las plantas. La enfermedad del Trips suele manifestarse síntomas específicos en las hojas, por lo que es factible emplearse diversos algoritmos de aprendizaje profundo y técnicas de procesamiento de imágenes para identificación y detección de esta enfermedad. En los últimos años, la agricultura sigue siendo un componente importante en nuestra economía [9]. A medida que la tecnología y la investigación han ido avanzando, se ha puesto de manifiesto que diversas enfermedades afectan la plantación de la palta, provocando una pérdida de el rendimiento de la calidad, como pérdidas de sus frutos. Este problema se ha convertido de preocupación en los agricultores. Las enfermedades del Trips en la palta afecta entre el 80% y al 100% de pérdida en las cosechas, lo que se traduce en una pérdida económica para

el agricultor como para el país. Entre ellas, las enfermedades de las hojas de las plantas desempeñan un papel importante en su producción agrícola. Por consiguiente, hacer frente a las enfermedades de la palta resulta crucial para el sector agrícola y la economía de nuestro país. El comportamiento dinámico de las redes neuronales ha cautivado a las comunidades científicas y tecnológica. Si afrontamos eficazmente este reto, podremos mejorar la calidad de la palta, reducir la prevalencia de cultivos enfermos y lograr mayores rendimientos. Este planteamiento no solo fortalecerá la economía, sino que también contribuye al avance de la agricultura. Para abordar este problema, se desarrolló un marco de aprendizaje profundo que combina dos modelos de algoritmos de aprendizaje profundo para reconocimiento de enfermedad del Trips. Las principales contribuciones de este trabajo se resumen en el apartado 1.1.

### 1.1 Trabajos relacionados

Para aplicar correctamente las medidas de control y gestionar las enfermedades de las plantas, es fundamental detectarlas a tiempo. Existe varios enfoques técnicos de reconocimiento de enfermedades en las plantas. Uno de los más comunes es la detección visual. Sin embargo, el proceso de identificación visual de las enfermedades en las plantas requiere mucho trabajo y es menos preciso. Una alternativa es realizar análisis de laboratorio, este método requiere mucho tiempo, conocimiento técnico e instalaciones de laboratorio [10]. Aparte de estos métodos convencionales, la IA también se ha utilizado para detectar enfermedades de las plantas en los últimos, décadas [11], [12]. Sin embargo, el reconocimiento de imágenes y las clasificaciones han progresado enormemente en los últimos años con el uso de Redes Neuronales Convolucionales (CNN) [8], [9].




Fig. 1. VVG-16 Estructura.

En 2023, Bhuiyan et al. Desarrollaron un modelo Banana SqueezeNet para detectar enfermedades del banano para lo cual utilizaron algunas redes neuronales como EfficientNetB0, MobileNetV3, ResNet-101, ResNet-50, InceptionNet-V3 y VGG16 mediante imágenes de las hojas del banano las enfermedades de Pestalotiopsis, Sigatoka y Cordona, así llegando a detectar temprana las enfermedades [13], por otra parte, en 2021 propusieron un modelo de predicción de pla-

gas en los cultivos de palto utilizando metodologías de aprendizaje automático como las plagas de Trips [14], detectar enfermedades de mango mediante las imágenes de la hoja, para ello tomaron las imágenes mediante las cámaras de celulares utilizaron VGG16, Leaflet, AlexNet así logrando con una precisión de 98.55% 99.50% y 99.45 [15]; desarrollo un modelo JutePestDetec basado en aprendizaje por transferencia para la identificación de plagas de yute, aplicaron los siguientes algoritmos como DenseNet, InceptionV3, MobileNetV2, VGG19 y ResNet50 [16], así, mismo, desarrollaron aplicativo web para la identificación de deficiencia de zing en naranjos mediante Redes Neuronales Convolucionales (CNN) utilizando Transfer Learning VGG16 [17].

En este trabajo, proponemos un modelo de comparación de 2 modelos como son; modelo VGG-16, y el modelo de ResNet18, para identificar la plaga de TRIPS en el aguacate mediante las hojas de la palta. Se realizó la comparación de dos modelos como son VGG-16 y ResNet18:

Las principales aportaciones de este estudio son:

- Recolección del conjunto de datos sobre la enfermedad de TRIPS de las hojas del aguacate.
- Reconocimiento de la plaga de TRIPS mediante imágenes de las hojas de la palta.

## 2 MATERIALES Y METODOLOGIA

### 2.1 Arquitectura de Redes Neuronales VGG-16.

El modelo VGG-16 es una arquitectura de Red Neuronal Convolutiva (CNN) por el Visual Geometry Group (VGG-16) de la Universidad de Oxford. Se caracteriza por su profundidad, que consta de 16 capas, incluidas 13 capas convolucionales y 3 capas complementarias conectadas. VGG-16 es reconocido por su simplicidad y eficacia, así como por su capacidad para lograr un sólido desempeño en varias tareas de visión artificial, incluida la clasificación de imágenes y reconocimiento de objetos. VGG-16 introduce un nuevo aspecto importante en el diseño de CNN, aumentando constantemente la profundidad de la red, agregando más capas convolucionales, lo cual es viable, debido al uso de filtros de 3x3 en todas las capas. Este diseño permite que el modelo aprenda representaciones jerárquicas de características visuales, lo que conduce a predicciones sólidas y precisas. A pesar de su simplicidad en comparación con arquitecturas más reconocidas recientemente, VGG-16 sigue siendo una opción popular para muchas aplicaciones de aprendizaje profundo debido a su versatilidad y excelente desempeño [18], [19].

### 2.2 Arquitectura de Resde Neuronales ResNet18

El modelo ResNet18 fue propuesto en Deep Residual Learning for image Recognitin por Kaiming he, Xiangyu Zhang, Shaoqig y Jaian Sum. La idea de los bloques residuales, apila capas adicionales en las redes neuronales profundas, las dos primeras capas de ResNet son las mismas que las de GoogLeNet de 7x7 las convolucionales con 64 canales de salida y un paso de 2 seguidas por 3x3 capa de agrupación máximo con un paso de 2. Hay cuatro capas convolucionales en cada módulo excluyendo 1x1. Junto con la primera 7x7

capa convoluconal y la final completamente conectada, hay 18 capas en total [15],[16].




Fig. 2. ResNet18 Estructura

### 2.3 Materiales

- Cámara fotográfica digital canon de 16.2 megapíxeles.
- Micro USB para almacenamiento de las imágenes.
- UBS Kingston de 32GB.
- Computadora con una tarjeta grafica de 2GB con una memoria de 32GB de RAM, sistema operativo Ubuntu 22.04.
- Registro de imágenes de las hojas del aguacate.
- Archivo con una extensión \*.py/ipynb

### 2.4 Tipo de nivel de investigación

La investigación es de tipo aplicado con nivel descriptivo.

### 2.5 Procedimiento de recolección de datos.

Primeramente, se realizó la recolección de las hojas de la palta, de este modo, se realizó la captura de imágenes de las hojas de la palta, ya que, estas imágenes representan el conjunto de datos que es conformado por imágenes digitales capturados por medio de una cámara digital, dichas imágenes representan dos clases tal como se describe en la tabla 01, así, las hojas que contiene la enfermedad de TRIPS y hojas Sanas, dado que, las imágenes se obtuvieron de los agricultores del sector de Quitasol de la provincia de Abancay departamento de Apurímac a una altitud de 2,377 msnm.. Haciendo un total de 3,012 imágenes de 2 clases: sanas, trips.

De la Fig 3 podemos visualizar las imágenes de las hojas de la palta con la enfermedad de Trips y por otra parte hojas sanas.



Fig. 3. Ejemplo del conjunto de datos de la palta cual conforma hojas sanas y con enfermedad de trips.

Para empezar, las hojas afectadas por la enfermedad se clasificaron según sus características con la ayuda de un especialista conocedor de esta enfermedad del Trips, así pues, se realizó la limpieza de los datos para posteriormente elimi-

nar las imágenes inconsistentes, las imágenes fueron capturados de tamaño 2,316 x 176, se realizó la reducción de imágenes a 250 x 250 para lo ello se utilizo un algoritmo, se dividió el conjunto de datos en entrenamiento, validación y prueba, se realizaron las distribuciones de la siguiente manera entrenamiento con 68%, validación con 22% y prueba con 10%.

TABLA 1

Número de Imágenes para cada clase de entrenamiento/validación/prueba

No. Clase	Nombre clase	Número de imágenes		
		Train	Valid	Test
0	TRIPS	1,170	257	117
1	Saludable	1,170	257	117
	Total	2,340	514	234

Se utilizó la técnica de aumentado de datos son: rotación, y escalado [20], [21], [22]. el proceso de aumentación tiene como objetivo de incrementar el número de imágenes de la palta a su vez ayudar a evitar el sobre ajuste.

## 2.6 Medición del desempeño

Métricas de evaluación, según Huerta-Mora et al. [23], las siguientes medidas para el rendimiento de nuestro modelo, Accuracy, la precisión, el Recall y F1-score, se utilizaron las siguientes ecuaciones.

$$\text{Precisión} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN}$$

$$\text{F1-Score} = 2 \frac{(\text{Recall} * \text{Precisión})}{(\text{Recall} + \text{Precisión})}$$

Donde TP, FP, FN y TN indican los valores verdaderos positivos, falsos positivos, falsos negativos y verdaderos negativos en la matriz de confusión, respectivamente.

- Se realizó la captura de imágenes mediante una cámara fotográfica digital Canon de 16.2 megapíxeles, para recolección del conjunto de datos de la palta.
- Se seleccionaron las imágenes según su clase, las clases sanas se consideraron con imágenes de hojas sanas, la clase trips con imágenes de las hojas con dicha enfermedad, se realizó la reducción de tamaño de imágenes utilizando algoritmo gaussiano.
- Se distribuyo en train con 1986 imágenes de hojas entre sanas y trips, valid 662 imágenes de hojas entre sanas y trips, test 364 imágenes de hojas entre sanas y trips.
- Se realizó entrenamiento de reconocimiento de enfermedades de la palta utilizando ResNet18 y VGG-16,

utilizando con extensión ipynb. El entrenamiento duro alrededor de 15 minutos con ResNet, y 5.23 minutos con VGG-16, el entrenamiento se utilizaron las siguientes herramientas y librerías con sus distintas versiones Python == 3.11, Torch ==1.12 + cuda 1.16 + Torchvision == 0.12, zip ==3.17, Opencv- Python == 4.8, Matplotlib, numpy.

- Se realizó las pruebas con 25 épocas para cada tipo de redes neuronales convolucionales.

## 3 RESULTADOS

### 3.1 Resultados evaluación

En la fig. 4 muestra la matriz de confusión, así, nuestro modelo VGG-16, llegando con un Accuracy de 96.78%, así mismo con una precisión de 96.77% y con Recall de 95.74%, de nuestras imágenes sanas fueron clasificados como incorrectas 9 de las imágenes fueron clasificados como Trrips y 12 imágenes con la enfermedad de trips fueron clasificados incorrectos, así el modelo VGG-16 predijo.

En la fig. 6 se muestra la matriz de confusión por el modelo

True	sanas	281	3
Label	trips	2	376
		sanas	trips
		Predict Label	

Fig. 4. Matriz de confusión del modelo VGG-16

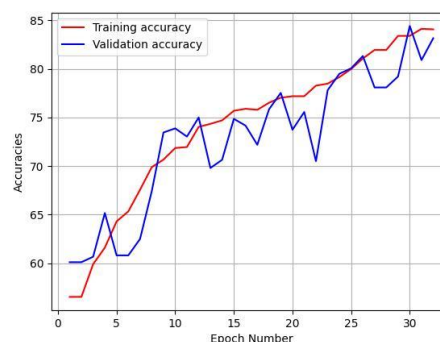


Fig. 5. Validación de Accuracy según modelo VGG-16

de ResNet18, que obtuvo un Accuracy de 99.24%, así mismo con una precisión de 98.94% y con una Recall de 99.29%, de los cuales 3 imágenes sanas fueron clasificadas incorrectas y 2 imágenes con la enfermedad de trips fueron predichas incorrectas según nuestro modelo ResNet18, obtuvo mejores resultados que el modelo VGG-16 según se muestra en la fig.4, así mismo, nos quedamos con el modelo ResNet18. Para este trabajo.

True Label	sanas	270	9
	trips	12	362
		sanas	trips
		Predict Label	

Fig. 7. Matriz de cofución según el modelo ResNet18

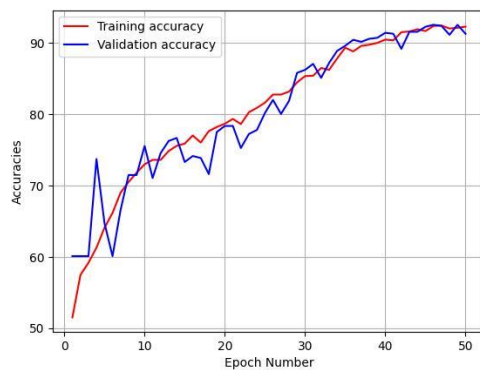


Fig. 8. Validación accuracy según el modelo ResNet18

TABLA 2.

Valores de las métricas de las arquitecturas de mejor rendimiento.

Modelo	Accuracy	Precision	Recall	F1-Score
ResNet18	99,24	98,94	99,29	99,12
VGG-16	96,78	96,77	95,74	96,26

Al comparar la exactitud de las arquitecturas, los mejores resultados que se obtuvo fue de ResNet18 con 99.24%.

Nuestro trabajo pretende crear un método cómodo de diagnosticar la enfermedad del TRIPS de la hoja de la palta. Los agricultores u otras partes interesados puedan tomar fotos de las hojas de la palta del campo utilizando el reconocimiento de imágenes puedan identificar dicha enfermedad en la palta en cuestión de segundos. Utilizando un enfoque diferente en el que detectaron plantas de la palta, la principal enfermedad del Trips. Utilizando métodos de aprendizaje automático.

Sin embargo, este trabajo sigue presentando algunas limitaciones. El conjunto de datos que se utilizó fue bastante pequeño. También hubiera sido mejor incluir imágenes de hajas de la palta de distintos departamentos del país, lo que ubriera aumentado la diversidad de los datos. En general, los enfoques actuales son razonablemente buenos para diagnosticar el Trips de la hoja de la palta, una enfermedad que se produce a muy temprana, y se espera mejorar en el futuro con más datos de entrenamiento.




Fig. 6. Predicción para las enfermedades de la palta por medio de las hojas.

Donde la curva 0.95 para nuestro modelo ResNet18 mientras que VGG-16 obtuvo 0.84 el error estándar es de 0.018 para ResNet18 donde 0.029 para VGG-16 para la significativa se obtuvo 3.2227 es significativa para nuestro experimento.

## 4 CONCLUSIONES Y RECOMENDACIONES

### 4.1 Conclusiones

La automatización en el sector agrícola es una necesidad para los agricultores de bajos recursos en vías de desarrollo, como Quitasol Abancay, Apurímac, Perú, están por muy detrás de los estándares actuales. El uso de inteligencia artificial en el análisis de enfermedades de las plantas ha cobrado importancia en los países de desarrollo en los últimos años, ya que ofrece un sistema inteligente que pueda funcionar en situaciones del mundo real, así, prestando apoyo a los agricultores no expertos, agro veterinarias y patologías. En este estudio, el objetivo de la arquitectura VGG-16 pueda identificar las enfermedades de TRIPS en las hojas del aguacate, especialmente en Abancay, Quitasol, se recopiló un conjunto de datos de 3900 imágenes de hojas infectadas y sanas de Abancay quitasol de los agricultores y se clasificaron manualmente en 2 clases de 1 con enfermedad de TRIPS una clase con hojas sanas. Las imágenes estaban de color en 3 canales, con un tamaño de 2304x1728x3, se redujo de tamaño a 276x156x3, para permitir el manejo de características, se redujeron para su entrenamiento en ResNet18 y VGG-16 ambos con modelo CNN. El modelo ResNet18 propuesto consta con cuatro pares conv-pool y dos capas densas totalmente conectadas. El modelo demuestra su precisión media del 99.24%. El rendimiento se validó mediante validaciones cruzadas. Este modelo se considera un punto de referencia para evaluar otras arquitecturas, complejas, de aprendizaje profundo. Mientras, VGG-16 mostró un resultado de 96.78% de rendimiento con comparación con ResNet18 de la última generación. Además, ResNet18 es eficiente en términos de exactitud, precisión, si no también de considerable reducción de tiempo de cálculo y complejidad al tener parámetros entrenables mucho más bajos. Las aplicaciones potenciales de la arquitectura VGG-16 en el diagnóstico de enfermedades en las plantas son numerosas, en modelos CNN como VGG-16 y ResNet18, puede ser una excelente adición a las funciones de procesamiento de imágenes para mejorar su capacidad de manejar imágenes de cualquier tipo.

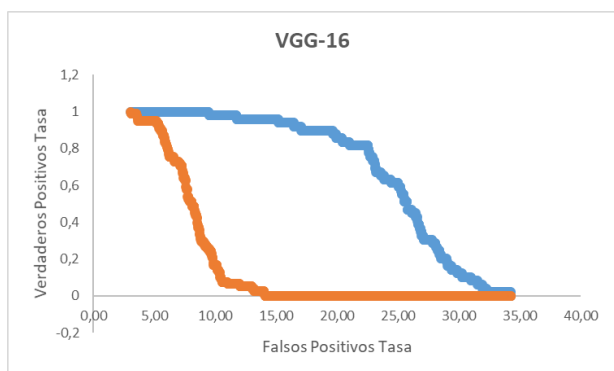


Fig. 9. ROC Curva para ResNet18

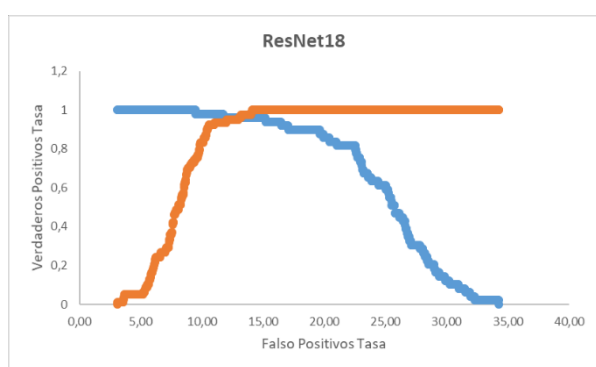


Fig. 10. ROC Curva para VGG-16

## 4.2 Recomendaciones

Por esto, este trabajo de investigación se recomienda utilizar una Base de Datos de la región de origen junto con la arquitectura de CNN ResNet18 para el desarrollo de reconocimiento de enfermedades de TRIPS, como herramienta de apoyo hacia los agricultores del sector de quitasol. Por los altos valores obtenidos en la experimentación.

## AGRADECIMIENTOS

Los reconocimientos a los agricultores de quitasol por aarnos facilitado acceso a las plantaciones de sus cultivos de la palta para la recolección y recopilación de las hojas de la palta para poder conformar nuestro Datasets el cual se uso para el entrenamiento de nuestro red neuronal y posteriormente para realizar nuestras pruebas.

Los autores desean agradecer a A, B, C. Este trabajo fue apoyado en parte por una subvención de XYZ (opcional)

## REFERENCIAS

- [1] P. A. Lta, "Análisis de 2015 - 2019," 2019.
- [2] Ministerio de Agricultura Pesca y Alimentación de España, "plan de manejo trips en el cultivo de aguacate hass," pp. 227–228.
- [3] J. A. López-Buenfil and J. G. Torres-Martínez, "Manual de Identificación de las Principales Plagas del Aguacate en México," p. 38, 2018.
- [4] P. Solís Calderón, *PLAN DE MANEJO DE TRIPS EN EL CULTIVO DEL AGUACATE HASS*. 2016. [Online]. Available: <http://hdl.handle.net/20.500.12324/33815>
- [5] A. Pe, "Latinoamérica lidera crecimiento mundial de la palta, con México, Perú, Chile y Colombia a la vanguardia," 31 julio del 2023. [Online]. Available: <https://agraria.pe/noticias/produccion-mundial-de-palta-alcanzo-las-8-4-millones-de-tone-32683#:~:text=a la vanguardia,Producción mundial de palta alcanzó las 8.4 millones de toneladas,entre el 2012 y 2022&text=México el principal productor global,y Perú>
- [6] N. de Prensa, "Exportación de palta supero las 36 mil toneladas en primer bimestre de 2024." [Online]. Available: <https://www.gob.pe/institucion/agromercado/noticias/930071-midagri-exportacion-de-palta-supero-las-36-mil-toneladas-en-primer-bimestre-de-2024>
- [7] G. R. Apurímac, "Apurímac exportará Palta a nivel internacional," 28 noviembre 2022. [Online]. Available: <https://www.gob.pe/institucion/regionapurimac/noticias/67481-0-apurimac-exportara-palta-a-nivel-internacional>
- [8] H. Afzaal *et al.*, "Detection of a potato disease (Early blight) using artificial intelligence," *Remote Sens.*, vol. 13, no. 3, pp. 1–17, 2021, doi: 10.3390/rs13030411.
- [9] C. C. Bonik, F. Akter, M. H. Rashid, and A. Sattar, "A Convolutional Neural Network Based Potato Leaf Diseases Detection Using Sequential Model," *2023 Int. Conf. Adv. Technol. ICONAT 2023*, no. April, 2023, doi: 10.1109/ICONAT57137.2023.10080063.
- [10] A. Ramcharan, P. McCloskey, K. Baranowski, and N. Mbilinyi, "A Mobile-Based Deep Learning Model for Cassava Disease Diagnosis," vol. 10, no. March, pp. 1–8, 2019, doi: 10.3389/fpls.2019.00272.
- [11] G. Kamdar, Jignesh and Jasani, M. and Jasani, Jash and John, Jeba Praba and John. J, "Artificial intelligence for plant disease detection: past, present, and future," pp. 223–238, 2021.
- [12] F. Coban, "The Role of the Media in International Relations: From the CNN Effect to the AI –Jazeera Effect," *J. Int. Relations Foreign Policy*, vol. 4, no. 2, pp. 45–61, 2016, doi: 10.15640/jirfp.v4n2a3.
- [13] M. A. B. Bhuiyan, H. M. Abdullah, S. E. Arman, S. Saminur Rahman, and K. Al Mahmud, "BananaSqueezeNet: A very fast, lightweight convolutional neural network for the diagnosis of three prominent banana leaf diseases," *Smart Agric. Technol.*, vol. 4, no. February, p. 100214, 2023, doi: 10.1016/j.atech.2023.100214.
- [14] C. A. S. ROBLES and I. D. P. C. CRUZ, "Modelo de predicción de plagas en el cultivo de palto utilizando metodología de aprendizaje automático supervisado, empresa Virú S.A., 2019-2021," pp. 1–60, 2021, [Online]. Available: [http://www.gonzalezcabeza.com/documentos/CRECIMIENTO\\_MICROBIANO.pdf](http://www.gonzalezcabeza.com/documentos/CRECIMIENTO_MICROBIANO.pdf)
- [15] R. A. Rizvee *et al.*, "LeafNet: A proficient convolutional neural network for detecting seven prominent mango leaf diseases," *J. Agric. Food Res.*, vol. 14, no. July, p. 100787, 2023, doi: 10.1016/j.jafr.2023.100787.
- [16] M. S. H. Talukder *et al.*, "JutePestDetect: An intelligent approach for jute pest identification using fine-tuned transfer learning," *Smart Agric. Technol.*, vol. 5, no. July, p. 100279, 2023, doi: 10.1016/j.atech.2023.100279.

- [17] F. D. E. I. Y. Arquitectura, "Shiane Lizceth Farfan Vergara," 2021.
- [18] W. A. Lozada-Portilla, M. J. Suarez-Barón, and E. Avendaño-Fernández, "Application of convolutional neural networks for detection of the late blight *Phytophthora infestans* in potato *Solanum tuberosum*," *Rev. U.D.C.A Actual. Divulg. Cient.*, vol. 24, no. 2, pp. 1–9, 2021, doi: 10.31910/rudca.v24.n2.2021.1917.
- [19] A. C. B. y L. F.-F. Olga Russakovsky\*, Jia Deng\*, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein, "Desafío de reconocimiento visual a gran escala de ImageNet." [Online]. Available: <https://www.image-net.org/challenges/LSVRC/index.php>
- [20] T. Bachlechner, B. P. Majumder, H. Mao, G. Cottrell, and J. McAuley, "ReZero is All You Need: Fast Convergence at Large Depth," *Proc. Mach. Learn. Res.*, vol. 161, no. 1, pp. 1352–1361, 2021.
- [21] K. H. and X. Z. and S. R. and J. Sun, "Deep Residual Learning for Image Recognition," *2016 IEEE Conf. Comput. Vis. Pattern Recognit.*, pp. 770–778, 2015, [Online]. Available: <https://api.semanticscholar.org/CorpusID:206594692>
- [22] D. P. H. and M. Salathe, "An open access repository of images on plant health to enable the development of mobile disease diagnostics," 2016, [Online]. Available: <https://arxiv.org/abs/1511.08060>
- [23] E. A. Huerta-mora, V. González-huitrón, H. Rodríguez-rangel, and L. E. Amabilis-sosa, "Detección de enfermedades foliares con arquitecturas de redes neuronales convolucionales," vol. 5, no. 1, pp. 18–40, 2020.

## BIOGRAFÍA

Primer Autor. Joselyn Huaman Ampuero, Bachiller en Ingeniería y Sistemas, Bachiller obtenido en la Universidad Nacional Micaela Bastidas de Apurímac en el año 2024.

Segundo autor. Marleny Peralta Ascue. Ingeniero de Sistemas, título obtenido en la Universidad Privada de Tacna, en el año 1999. Magister en Investigación Desarrollo e Informática; grado obtenido en la Universidad Nacional San Antonio Abad del Cusco en el año 2016. Docente Ordinario de la Universidad Tecnológica de los Andes y de la Universidad Nacional Micaela Bastidas de Apurímac.

Tercer autor. Julio Cesar Lloclli Champi. Ingeniero de Sistemas e Informática, Título obtenido en la Universidad Tecnológica de los Andes, en el año 2014. Magister en Ingeniería de Software, docente contratado en la Universidad Nacional Micaela Bastidas de Apurímac.