

UNIVERSIDAD PERUANA UNIÓN

ESCUELA DE POSGRADO

Unidad de Posgrado de Ingeniería y Arquitectura.



**Estimación de la Gravedad en Enfermedades en los Cultivos
del Aguacate Basado en Imágenes Mediante Redes Neuronales
Convolucionales**

Trabajo de Investigación para obtener el Grado Académico de Maestro(a) en
Ingeniería de Sistemas con mención en Ingeniería de Software

Autor:

Julio Cesar Lloclli Champi

Asesor:

Mag. Abel Angel Sullon Macalupu

Lima, 03 de febrero del 2025

DECLARACIÓN JURADA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

Yo (Abel Angel Sullon Macalupu), docente de la Escuela Profesional de Ingeniería de Sistemas, Campus Juliaca, Ingeniería y Arquitectura, Escuela de Posgrado de la Universidad Peruana Unión.

DECLARO:

Que la presente investigación titulada: **“ESTIMACIÓN DE LA GRAVEDAD EN ENFERMEDADES EN LOS CULTIVOS DEL AGUACATE BASADO EN IMÁGENES MEDIANTE REDES NEURONALES CONVOLUCIONALES”** del (los) autor (autores) (Julio Cesar Lloclli Champi) tiene un índice de similitud de 3 % verificable en el informe del programa Turnitin, y fue realizada en la Universidad Peruana Unión bajo mi dirección.

En tal sentido asumo la responsabilidad que corresponde ante cualquier falsedad u omisión de los documentos como de la información aportada, firmo la presente declaración en la ciudad de Ñana, Lima, a los 24 días del mes de Febrero del año 2025.



Abel Angel Sullun Macalupu

ACTA DE SUSTENTACIÓN DE TRABAJO DE INVESTIGACIÓN

En Lima, Ñaña, Villa unión a 3 días del mes de febrero del año 2025, siendo las 11:20 horas, se reunieron de forma online sincrónica, bajo la dirección del presidente del jurado, Mg. Junior Israel Pacheco Espinoza, el secretario PhD. Javier Linkolk López Gonzales; los demás miembros: Dr. Juan Jesus Soria Quijaite, Mg. Esteban Tocto Cano y asesor, Mg. Abel Angel Sullón Macalupu, con el propósito de administrar el acto académico de sustentación de trabajo de investigación de maestría titulada "Estimación de la Gravedad en Enfermedades en los Cultivos del Aguacate Basado en Imágenes Mediante Redes Neuronales Convolucionales", conducente a la obtención del grado de Magíster en Ingeniería de Sistemas con mención en Ingeniería de Software.

El presidente inició el acto académico de sustentación invitando al candidato a hacer uso del tiempo determinado para su exposición. Concluida la exposición, el presidente invitó a los demás miembros del jurado a efectuar las preguntas, cuestionamientos y aclaraciones pertinentes, los cuales fueron absueltos por el candidato. Luego se produjo un receso para las deliberaciones y la emisión del dictaminador del jurado. Posteriormente, el jurado procedió a dejar constancia escrita sobre la evaluación en la presente acta, con el dictamen siguiente:

Candidato: Julio Cesar Lloclli Champi

CALIFICACIÓN	ESCALAS			Mérito
	Vigesimal	Literal	Cualitativa	
Aprobado	16	B	Bueno	Muy Bueno

Finalmente, el presidente del jurado invitó a los candidatos a ponerse de pie, para recibir la evaluación final. Además, el presidente del jurado concluyó el acto académico de sustentación, procediéndose a registrar las firmas respectivas.


Presidente


Secretario


Asesor


Miembro


Miembro


Candidato

Contenido

I.	Introducción.....	5
II.	trabajos relacionados.....	6
III.	Metodología.....	7
	3.1 DataSets.....	7
	3.2 CNN Arquitectura	8
	3.3 ResNet18.....	9
	3.4 evaluación métrica	9
IV.	Experimentación de resultados y discusiones	10
	4.1 Detalles del entrenamiento resultados.....	10
	4.2 Clasificación de resultados.....	10
V.	Conclusiones	12

Estimación de la Gravedad en Enfermedades en los Cultivos del Aguacate Basado en Imágenes Mediante Redes Neuronales Convolucionales

*Image-Based Disease Severity Estimation in Avocado Crops Using Convolutional Neural Networks*Paper

Resumen — La agricultura desempeña un papel vital, importante en el desarrollo y el crecimiento económico mundial. Cuando los cultivos se ven afectados por enfermedades repercute negativamente en los recursos económicos mediante la producción agrícola de una nación. La detección temprana de estas enfermedades puede minimizar la pérdida de los agricultores y mejorar la producción. En este estudio, proponemos dos modelos existentes como son Redes Neuronales Convolucionales (CNN) y ResNet18 ambas de aprendizaje profunda, diseñado para predecir automáticamente las enfermedades de las hojas del aguacate Hass, el marco de trabajo abarca la recopilación de imágenes, selección de imágenes, clasificación de enfermedades. Empleando un enfoque combinando dos modelos bien establecidos (CNN, ResNet18) para generar clasificaciones, en enfoque aprovecha el concepto de visión por computadora para la predicción final, para entrenar y evaluar, generamos un conjunto de datos a través de las hojas del aguacate utilizando una cámara fotográfica canon de 16 megapíxeles: las cuales conforman de Ácaro Cristalino, Antracnosis, Araña Marrón y hojas sanas, conformando imágenes de hojas de aguacate de 1300 imágenes de cada clase, se realizó data aumentación de 35%. Para entrenar y evaluar ResNet18 alcanzando una precisión global del 94.14%, y una F1-score del 94.33% se llevó a cabo un estudio de validación exhaustivo con el conjunto de datos de aguacate (4 clases), respectivamente. Estos resultados experimentales confirman que proporciona una detección y predicción más eficaz y precisa de las enfermedades del aguacate, lo que lo convierte en un candidato prometedor para aplicaciones prácticas.

Abstract — Agriculture plays a vital, important role in global economic growth and development. When crops are affected by diseases it has a negative impact on economic resources through a nation's agricultural production. Early detection of these diseases can minimize farmers' loss and improve production. In this study, we propose two existing models such as Convolutional Neural Networks (CNN) and ResNet18 both deep learning models, designed to automatically predict avocado leaf diseases Hass, the framework encompasses image collection, image selection, disease classification, and disease classification. Employing an approach combining two well-established models (CNN, Res-Net18) to generate classifications, the approach leverages the concept of computer vision for final prediction, to train and evaluate, we generated a dataset across avocado leaves using a 16-megapixel canon camera: comprising of Crystal Mite, Anthrocnose, Brown Spider and healthy leaves, comprising water-cat leaf images of 1300 images of each class, 35% data enhancement was performed. To train and evaluate ResNet18 reaching an overall accuracy of 94.14%, and an F1-score of 94.33%, a comprehensive validation study was carried out with the avocado dataset (4 classes), respectively. These experimental results confirm that it provides more efficient and accurate detection and prediction of avocado diseases, making it a promising candidate for practical applications.

Palabras Clave - Aprendizaje profundo Redes neuronales convolucionales(CNN); Antracnosis; Ácaro cristalino; Araña marrón; Enfermedades del aguacate.

Keywords - Deep learning Convolutional neural networks (CNN); Anthrocnosis; Crystalline mite; Brown spider; Avocado diseases; Avocado diseases.

I. INTRODUCCIÓN

La agricultura es la base de toda civilización para garantizar la alimentación en el mundo. Así mismo, la economía mundial se mueve gracias a la agricultura [1] [2]. Así mismo, más de 250 millones de personas se enfrentan inseguridad alimentaria y algunos están al borde de la inanición [3], en los últimos años, las enfermedades en las plantas se ha incrementado debido al desgaste de la tierra causados de desechos que produce la sobrepoblación [4]. Los agricultores enfrentan a enormes pérdidas debido a las infecciones de las enfermedades en las plantas. El aguacate (avocado y/o palta) es producido por un árbol, perteneciente a la familia de lauráceas, su tamaño varía entre 2 a 4cm en su etapa de madurez, entre las variedades más apetecibles por los consumidores tenemos Hass y Fuerte [5] [6]. Por otra parte, la palta experimenta un crecimiento de un 14% en la demanda a nivel mundial. Según, Ministerio de Desarrollo Agrario [7] [8], Perú exporta más de 36 mil toneladas de palta esto representa un crecimiento de 79.2%, Así mismo, según Gobierno Regional de Apurímac exportara durante cinco años alrededor de 360 toneladas por temporada con destino a Unión Europea [9]. La aparición de enfermedades en las plantas reviste una gran importancia, ya que repercute directamente en su calidad y cantidad. Estas enfermedades pueden atribuirse a factores como hongos, bacterias, virus, entre otros, existe una variedad de enfermedades en el aguacate [10], entre las enfermedades tenemos: Araña Cristalino (*Oligonychus perseae*) [11] [12], Ácaro marrón (*Oligonychus punicea*) [13], Trips [5], Anthracnose es causado por especies de género *Colletotrichum* [14],

Propopulvinaria pyriformis [15], Olygonichus punicae [16], Nipaecoccus nipae [17], Roña [18], Negrilla [16], Rosellia [19], Verticilosis [20]. El método tradicional de reconocer las enfermedades en las plantas de aguacate es muy costoso debido al tiempo y lo complicado, son ineficientes. En este sentido, la necesidad de sistemas de reconocimiento de enfermedades con precisión y eficaz para la detección de enfermedades mediante las hojas del aguacate en una etapa temprana, para proteger las plantaciones de su degradación producción de calidad. Entre otros. La calidad de la producción del fruto se degrada, perdida, debido a las enfermedades.

Este método tradicional, consistía en observar los síntomas, manchas mediante el ojo humano, de inspeccionar las enfermedades, esto conlleva consultar a los expertos. Sin embargo, los especialistas no siempre están disponibles, esto hace que este proceso sea inconveniente y a su vez genera costos adicionales en la producción [21]. Es por ello que este método de identificar enfermedades sea ineficiente debido a las limitadas capacidades de la percepción del ojo humano es poco práctico en grandes cantidades de plantaciones del aguacate, esto ampliaría en el área de la investigación, así en el campo del aprendizaje automático y la visión por computadora [22]. La mayoría de las enfermedades del aguacate son afectadas por medio de las hojas y, por lo tanto, las hojas se convierten en una fuente base de la información para detectar enfermedades [10], como se analiza en [23] la detección temprana de enfermedades en aguacate será útil para maximizar la producción y así mejorar la calidad de los productos.

Para la detección de partes infectadas en las hojas de las plantas [24]. Si afrontamos eficazmente este reto, podremos mejorar la calidad del aguacate, reducir la prevalencia de cultivos enfermos y lograr mayores rendimientos. Este planteamiento no solo fortalece, a economía, sino que también contribuye al avance de la agricultura. Para abordar este problema, hemos desarrollado un aprendizaje profundo combinamos dos modelos de aprendizaje profundo, en el campo de procesamiento de imágenes para extraer características fundamentales utilizando, como se ilustra en la Fig. 1. Las principales contribuciones de este trabajo se resumen a continuación:

- Se desarrolló un marco de aprendizaje profundo para así lograr una predicción eficiente y precisa de la enfermedad, que abarca un enfoque híbrido que combina el aprendizaje profundo CNN.
- Para mejorar la precisión de la predicción de enfermedades propuesto de la hoja de aguacate mediante la arquitectura de modelo ResNet18 y CNN.
- Recolección del conjunto de datos sobre las enfermedades de Acarro marrón, Araña Cristalino, Antrocnosis y sanas.




Figure 1. Modelo del sistema Propuesto.

II. TRABAJOS RELACIONADOS.

Los investigadores en el ámbito de procesamiento de imágenes, el aprendizaje profundo (Deep Learning) como los algoritmos de aprendizaje profundo. Está creciendo en adecuar un método eficaz y eficiente para la detección y el diagnóstico de enfermedades temprano en las hojas de las plantas, lo ha dado lugar a avances significativos, para identificar enfermedades en las hojas de aguacate, los trabajos en reconocimiento de enfermedad en aguacate son muy escasos o nulas.

Se describen las enfermedades de la palta: Oligonychus perseae [13] esta enfermedad causa daños significativos en las hojas iniciando la colonización se alimenta de las hojas tiernas, Protopulvinaria Pyriformis [15] se encarga de provocar la pudrición de la raíz del aguacate es conocido como aguacatero se

encuentra en zonas húmedas, *Olygonichus Punicae* [25] se alimenta del follaje, así introduciendo sus estiletas en los tejidos de la palta provocando manchas rojizas, *Nipaecoccus nipae*, Trips [5] esta enfermedad inicia en las hojas muy tiernas provocando la caída de los flores de la palta puede llegar a perder hasta el 100% de la producción, Antrocnosis [26] esta enfermedad se encuentra en las frutas como en las hojas su daño puede perderse hasta en 50% de su producción se crea manchas en el fruto en la hoja mancha de color marrón, Roña [18] ataca a fruto, hojas en los frutos desde recién polinizado, hasta completamente formado ocasionando pérdidas en gran manera, Anillamiento del pedúnculo, Negrilla [16] esta enfermedad es causada por un hongo *Pseudocercospora* que produce daños en pro y pos cosecha, Rosellina [19] esta enfermedad es causada por las que se translocación por la planta, Verticilosis.

Rizvee et al. [27] introdujeron un sistema LeafNet basado en redes neuronales convolucionales para detectar enfermedades mediante imágenes de las hojas del mango, entrenaron reconocimiento de patrones de enfermedad específicas de la región de las imágenes para casi todas las enfermedades, Bhuiyan et al. [28] propusieron utilizar aprendizaje profundo y optimización bayesiana para diagnosticar enfermedades mediante imágenes de la hojas del plátano, aplicaron modelo BananaSqueezeNet. Los resultados obtenidos son satisfactorios con una precisión de 96.25%, Hasan et al. [23] propusieron un modelo de aprendizaje automático y visión por computadora basado en los síntomas de las hojas de la manzana segmentaron la región enferma de la imagen utilizando $L^*a^*b^*$ vecinos más cercano, extrajeron características, utilizaron conjunto de datos Plant Village logrando obtener el 98.63%, Ding et al. [29] propusieron dos esquemas integrados ResNet18 CBAM para la clasificación de enfermedades por dos ramas recortadas aleatoriamente en las hojas de la manzana, experimentaron con 4479 imágenes así logrando una precisión de 95.2% y 97.2%. Kumari et al [30] se ha aplicado un enfoque de segmentación que utiliza la agrupación de K-means para extraer características como área, el color y la textura de las muestras de imágenes.

Por el aguacate, Campos-Ferreira & Gonzáles-Camacho [31] implementaron un modelo de aprendizaje automático CNN, entrenado y validado, para identificar frutos sanos de aguacate transformado imágenes de color RGB, para reconocer 2 tipos de enfermedades, roña y antrocnosis así alcanzando una precisión de 80%, El cultivo de aguacate enfrenta varios problemas, es decir, enfermedades en las hojas, ocasionando reducción en la producción y aumenta los costos de producción. La detección temprana de las enfermedades de las hojas de aguacate es un área prometedora para los investigadores.

III. METODOLOGÍA

A continuación, se describe la metodología del estudio con un breve análisis de las técnicas de recolección y procesamiento de datos. Luego, se describe el modelo de aprendizaje profundo ResNet18 y el modelo CNN propuesto [32] [33], las arquitecturas se implementaron en Python usando PyTorch [34]. Los experimentos se realizaron en una computadora de 64 bits con sistema operativo Ubuntu 22.04 LTS, AMD @ Ryzen 5 2600 3.4ghz con 6 núcleos 3,9 Ghz, con 16 Gb de RAM, Nvidia GeForce GTX 1650 Gráfica (GPU). Fig.1 ilustra el flujo de trabajo total que se ha utilizado en esta investigación.

3.1 DataSets

Para alcanzar los objetivos de este estudio, se recolectaron hojas de aguacate de la comunidad de Valle San Gabriel, Abancay, Apurímac, Perú. conformado imágenes de tres enfermedades del aguacate de la variedad de Hass, entre ellas Ácaro Cristalino, Antrocnosis, Araña Marrón, así como hojas sanas, lo que mantiene de tamaños iguales. El procesamiento de datos aumentación, escala aleatorio y rotación en el rango de 0,50 a 95 en las direcciones horizontal y vertical, aumento de posición de las imágenes se giran 45°, 135°, 225° y 315°, así como voltear horizontal y verticalmente, para ofrecer un aspecto más realista, RGB de tres canales (azul, rojo, verde) se representa por su valor, los modelos CNN y ResNet18 a aprender características más robusto. Los modelos funcionan mejor cuando el conjunto de datos de entrada es lo más grande posible, ya que así se reduce la probabilidad de sobreajuste, capaz de identificar con precisión las enfermedades de aguacate.




Figure 2. ejemplo del conjunto de datos de las hojas del aguacate con sus respectivas condiciones, (a) Ácarro Cristalino (b) Anthrosea (c) Araña Marron (d) sanas.

El conjunto de datos consta de 1.300 imágenes de hojas de aguacate individuales capturadas con una cámara fotográfica Canon 16.0 megapíxeles del Valle San Gabriel. El fondo de las imágenes de las hojas enfermas puede causar sesgos y errores en el entrenamiento del modelo, este conjunto de datos proporciona imágenes con el fondo verde esperanza. Además, El estudio experimental del marco propuesto emplea un conjunto de datos dividido aleatoriamente, con un 78% asignado al entrenamiento y un 22% a la validación. Además, se asigna a las pruebas, que representa el 10% de los datos. La distribución de imágenes por clases utilizada en el estudio experimental.

3.2 CNN Arquitectura

Las CNN son una de las principales técnicas utilizadas hoy en día para el reconocimiento de patrones en imágenes [35]. Las CNN se dividen en dos partes, Convolutiva es responsable de extraer características y la capa de agrupación se encarga de reducir las dimensiones de una imagen [36]. El modelo CNN, datos de entrada y salida por tres capas principales capa convolutiva, agrupación y de conexión, se define del siguiente modo.

$$M_{ijz}^{n+1} = \sum_{r=1}^{k_n} \sum_{s=1}^{k_n} \sum_{k=1}^{d_n} W_{rsk}^{(z,n)} h_{1+r-1,j+s-1,k}^{(n)} \quad (1)$$

Durante el proceso de entrenamiento los valores numéricos se organizan en matrices de unidades estructurales en tres dimensiones que conforman rojo, verde y azul, conocidos como filtros o kernels, las dimensiones de filtro en cada capa sería $k_n \times k_n \times d_n$. La profundidad de la salida resultante de la capa convolutiva depende del número de filtros que se realiza en la imagen, no por las dimensiones de la capa de entrada o del filtro.




Figure 3 Ejemplo de CNN imagen adaptada de Baldominos [36]

3.3 ResNet18.

El modelo ResNet18 fue propuesto en Deep Residual learning for image Recognitin por Keiming he, Xiangyu Zhang, apila capas adicionales en las redes neuronales profundas, las 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 con capas de agrupación máxima con un paso de 2. Hay 4 capas convolucionales en cada módulo excluyendo 1x1. Junto con la primera 7x7 y la final completamente conectada, hay 18 capas en total [27] [37].

En este estudio, se clasificaron 3 enfermedades de las hojas del aguacate. La entrada a la red es una imagen RGB de tres canales de 240x240. Tras la extracción de características y el muestreo descendente, se obtuvo un mapa de características de nx5x8x8 (n es el tamaño de un mini lote). Tras la agrupación de medidas




Figure 4. Ejemplo de ResNet-imagen adaptada de Kaiming

y el muestreo descendente, el tamaño del mapa de características se reduce a nx5x1x1 antes de enviarlo al clasificador SotfMax. Por último, se determinan la probabilidad de predicción la etiqueta y la precisión.

3.4 evaluación métrica

Para evaluar el marco propuesto, se utilizan las métricas principales, el accuracy, Precision, Recall y F1-Score. El accuracy proporciona una medida general de la capacidad del modelo para predecir correctamente los casos de clase. La precisión evalúa la capacidad del modelo para evitar etiquetas como positiva, una instancia negativa, calcula el cociente entre los verdaderos positivos y la suma de verdaderos positivos y falsos positivos. Recall mide la capacidad del modelo para identificar casos positivos, representa por la relación entre verdaderos positivos y la suma de verdaderos positivos y falsos negativos. Por último, F1-Score es una media armónica ponderada de la recuperación y la precisión, que indica el porcentaje de predicciones positivas correctas, y las características operativas del receptor (ROC). Para calcular, la precisión. Todas estas métricas evalúan el rendimiento de la clasificación, estas medidas, la evaluación de la clasificación, se calculan a de imagen. Las definiciones matemáticas de estas métricas se derivan de la matriz de confusión multclasificación, que representa a continuación:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1-score = 2 \times \frac{(Recall * Precision)}{(Recall + Precision)} \quad (5)$$

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

IV. EXPERIMENTACIÓN DE RESULTADOS Y DISCUCIONES

4.1 Detalles del entrenamiento resultados.

Se emplearon modelos de aprendizaje profundo, incluyendo ResNet18 [38] y CNN [35]. Permite comparación directa utilizando el mismo conjunto de datos de entrada.

TABLE I. CONFIGURACIÓN PARA EL ENTRENAMIENTO.

Configuración del Entrenamiento	
Optimizador	Adam, SGD
función de pérdida	cross-entropy
Mini batches	64
Número de épocas	70

Los optimizadores determinan como actualizar los pesos del modelo durante el entrenamiento, mientras que las funciones de perdida determinan como se penalizara el modelo en predicciones erróneas. El número de épocas determina el número de veces que el modelo se enfrenta a todo el conjunto de datos de entrenamiento. El Mini batch determina el número de ejemplos de entrenamiento utilizadas en cada iteración de entrenamiento. En este trabajo utilizamos los optimizadores Adam y SGD y la función de perdida de entropía, el número de épocas se fijó en 70, y el tamaño de mini batches en 64. Durante los experimentos así mejorar el entrenamiento y el rendimiento.

TABLE II. RESULTADOS DE LA EVALUACIÓN DE LA PREDICCIÓN DE CLASIFICACIÓN POR CLASE PARA LA PREDICCIÓN DE ENFERMEDADES DE A HOJA DEL AGUACATE DEL MODELO CNN Y RESNET18. PARA LA TAREA DE EVALUACIÓN SOLO SE UTILIZÓ IMÁGENES DE PRUEBA.

Segmentación del modelo	Evaluación Métrica (%)			
	Accuracy	Precision	Recall	F1-score
CNN	88.09	70.97	75.90	74.75
ResNet18	92.87	94.14	94.33	94.33

4.2 Clasificación de resultados.

Para evaluar la etapa de clasificación, las imágenes se introdujeron directamente en el proceso de extracción de características para obtener las características profundas de nivel. Para ello, se utilizaron dos modelos populares de Inteligencia Artificial profunda, a saber, CNN, ResNet18. Se utilizaron para la predicción final de las enfermedades de la hoja de aguacate. Los resultados de la evaluación para cada clase se consolidan en la tabla 2.




Figure 5. perdida y precisión de CNN sobre el conjunto de datos de entrenamiento y validación




Figure 6. Rendimiento de evaluación de clasificación propuesto representado por la matriz de confusión (a) CNN, y (b) ResNet18.

Como se indica la tabla 2, el modelo de ResNet18 obtuvo los mejores resultados de clasificación para las enfermedades de la hoja del aguacate, del 92.87%, 94.14%, 94.33%, 94.33% para la clasificación, precisión, Recall y la F1-score en todas las clases. Los resultados más bajos se observan en la clase sana, lo que puede atribuirse al número de limitado de imágenes de esa categoría. En especial, el F1-score es la más fiable para evaluar el rendimiento global, teniendo en cuenta su capacidad para corregir los desequilibrios de clase. Sin embargo, en este estudio se utilizaron métricas de evaluación ponderadas para determinar la tasa de contribución de cada clase. Todas las métricas de evaluación se realizaron utilizaron, la matriz de confusión representada en la, Figura 6 muestra la matriz de confusión.

TABLE III. SE ENCONTRÓ EN LA EXPERIMENTACIÓN, SEGÚN LAS ENFERMEDADES DE MEDIDAS SE LOGRÓ OBTENER COMO SE MUESTRA EN LA TABLA.

Matriz de observación								
clases	Medidas para CNN				Medidas para ReNet18			
	TP	TN	FP	FN	TP	TN	FP	FN
Ácaro Cristalino	12	70	1	9	13	115	2	1
Antrocnosis	27	64	0	2	29	99	2	4
Araña Marrón	22	70	1	0	18	103	3	2
Sanas	20	72	9	0	20	97	3	3




Figure 7. Rendimiento de la evaluación de clasificación representada por métricas de confusión: (a) CNN, (b) ResNet18

V. CONCLUSIONES

La predicción precoz de las plantas de aguacate desempeña un papel fundamental para salvar las cosechas y mejorar la calidad. En este estudio presentar un novedoso marco basado en Inteligencia Artificial para predecir las enfermedades de las hojas del aguacate en un escenario de clasificación múltiples: de las enfermedades Sanas, Araña Marrón, Antrocnosis, Ácaro Cristalino. Además, evaluamos la ejecución y el rendimiento de predicción de la CNN, y ResNet18.

TABLE IV. RESULTADOS DE LA EVALUACIÓN COMPARATIVA INDIRECTA DEL MODELO CNN Y RESNET18 MODELOS DE IA EXISTENTES EN LA BIBLIOGRAFÍA.

Planta	Dataset	Modelo	Métricas de Evaluación			
			Accuracy	Precisión	Recall	F1-score
Aguacate	Planta Aguacate	CNN	88%	90%	99%	94%
Aguacate	Planta Aguacate	ResNet	93%	94%	94%	94%

Utilizando conjunto de datos de aguacate. Nuestro estudio propuso dos modelos ResNet18 demuestra unos resultados de predicción notable, la clasificación de características de conjunto mediante capas. Creemos que este modelo es muy prometedor como candidatos para nuevas pruebas con diferentes conjuntos de datos, ofreciendo al sector agricultor y proporcionar soluciones de servicios inteligentes también al sector privado

- [1] X. Hong, Q. Chen, and N. Wang, "The impact of digital inclusive finance on the agricultural factor mismatch of agriculture-related enterprises," *Financ. Res. Lett.*, vol. 59, p. 104774, Jan. 2024, doi: 10.1016/J.FRL.2023.104774.
- [2] S. Tanner, M. Ben-Hur, E. Argaman, and I. Kutra, "The effects of soil properties and aggregation on sensitivity to erosion by water and wind in two Mediterranean soils," *CATENA*, vol. 221, p. 106787, Feb. 2023, doi: 10.1016/J.CATENA.2022.106787.
- [3] A. Guterres, "Informe mundial sobre la crisis alimentarias 2023." [Online]. Available: <https://www.fsinplatform.org/global-report-food-crises-2023>
- [4] H. Duan, T. R. Miller, G. Liu, and V. W. Y. Tam, "Construction debris becomes growing concern of growing cities," *Waste Manag.*, vol. 83, pp. 1–5, Jan. 2019, doi: 10.1016/J.WASMAN.2018.10.044.
- [5] 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>
- [6] L. Caicedo, E. V. Devia, T. Bacca, and A. Carabali, "Daños ocasionados por el perforador del aguacate *Heilipus lauri* Boheman (Coleoptera: Curculionidae) en Tolima (Colombia)," *Cienc. Tecnol. Agropecu.*, vol. 11, no. 2, pp. 129–136, 2010, doi: 10.21930/rcta.vol11_num2_art:203.
- [7] 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>
- [8] J. C. L. CARRASCO, "Exportaciones peruanas de palta comienzan el 2023 de manera acelerada," 2023. [Online]. Available: <https://agraria.pe/noticias/exportaciones-peruanas-de-palta-comienzan-el-2023-de-manera--31133>
- [9] G. R. Apurímac, "Apurímac exportará Palta a nivel internacional," 28 noviembre 2022. [Online]. Available: <https://www.gob.pe/institucion/regionapurimac/noticias/674810-apurimac-exportara-palta-a-nivel-internacional>
- [10] J. A. López-Buenfil and J. G. Torres-Martínez, "Manual de Identificación de las

Principales Plagas del Aguacate en México,” p. 38, 2018.

- [11] C. Tenerife, “Araña cristalina del aguacate,” 2017.
- [12] V. Hugo, H. Pérez, M. Jacqueline, and G. Luna, “ANÁLISIS ESPACIAL DE LAS POBLACIONES DE ARAÑA ROJA (*Olygonichus punicae* Hirst) Y SU DAÑO EN EL CULTIVO DEL AGUACATE, EN EL ESTADO DE MÉXICO,” pp. 8–9, 2018.
- [13] J. R. Boyero, E. Calderón, and J. M. Vela, “Presencia del ácaro marrón (*Oligonychus punicae*) en los cultivos de aguacate del sur de España,” *Agrícola Vergel*, no. January, pp. 245–248, 2014.
- [14] Nelson Scot, “Anthracnose of Avocado,” p. 6, 2008, [Online]. Available: <http://www.ctahr.hawaii.edu/freepubs>
- [15] T. Tecnológica, A. Beltráa, A. Soto, I. Agroforestal, and U. P. De, “O rnamementales,” 2013.
- [16] E. Rodríguez Polanco, P. J. Tamayo, J. Reina Noreña, and É. H. Varón Devia, “La peca o mancha negra del aguacate: síntomas y estrategias de manejo,” *La peca o mancha negra del aguacate síntomas y estrategias manejo*, no. February 2021, 2020, doi: 10.21930/agrosavia.nbook.7404432.
- [17] E. Fuentes, S. Perera, E. Peña-Darias, A. Piedra-Buena, and E. Hernández-Suárez, “Incidencia y control de la cochinilla del aguacate (*Nipaecoccus nipae* (Maskell)) una nueva plaga en los cultivos de aguacate en Canarias,” *Agrícola Vergel*, vol. 410, p. 1, 2018, [Online]. Available: https://www.edicioneslav.es/wp-content/uploads/2018/06/AGRÍCOLA-VERGEL-Núm-410_-E.-Hernández.pdf
- [18] F. J. Marroquín-Pimentel, “FACTORES QUE FAVORECEN LA INCIDENCIA DE ROÑA (*Sphaceloma perseae* Jenk,” *Rev. Chapingo Ser. Hortic.*, vol. 5, no. Gallegos 1983, pp. 309–312, 1999, [Online]. Available: http://www.avocadosource.com/WAC4/WAC4_p309.pdf
- [19] R. Adolph, “Toxinas de *Rosellinia necatrix* asociadas a la podredumbre blanca del aguacate,” pp. 1–23, 2016.
- [20] E. Campos, J. Ayala, J. Andrés, and M. Espindola, “Propagación de aguacate,” *Secr. Agric. Ganad. Desarro. Rural. Pesca Y Aliment.*, pp. 1–56, 2012, [Online]. Available: https://www.gob.mx/cms/uploads/attachment/file/232194/Propagacion_de_aguacate.pdf
- [21] T. Theodoridis and J. Kraemer, “Detection and Classification of Leaf Diseases Using K-means-based Segmentation and Neural-networks-based Classification,” 2011.
- [22] M. Riley, M. Williamson, and O. Maloy, “Diagnóstico de enfermedades en Plantas,” *Plant Heal. Instr.*, 2002, [Online]. Available: <https://www.apsnet.org/edcenter/disimpactmngmnt/casestudies/Pages/DiagnosticoEnfermedadesPlantas.aspx%0Ainternal-pdf://1312/DiagnosticoEnfermedadesPlantas.html>
- [23] S. Hasan, S. Jahan, and M. I. Islam, “Disease detection of apple leaf with combination of color segmentation and modified DWT,” *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 9, pp. 7212–7224, 2022, doi: 10.1016/j.jksuci.2022.07.004.
- [24] K. R. Gavhale, U. Gawande, and K. O. Hajari, “Unhealthy region of citrus leaf detection using image processing techniques,” *2014 Int. Conf. Conver. Technol. I2CT 2014*, no. July, 2014, doi: 10.1109/I2CT.2014.7092035.
- [25] E. Cerna, M. H. Badii, Y. Ochoa, L. Aguirre, and J. Landeros, “TABLA DE VIDA DE *Oligonychus punicae* Hirst (Acari : Tetranychidae) EN HOJAS DE AGUACATE (*Persea americana* Mill) VARIEDAD HASS , FUERTE Y CRIOLLO,” *Univerisidad y Cienc. Trópico Húmedo*, vol. 25, no. 2, pp. 133–140, 2009.
- [26] Á. M. Gil, *Guía de gestión integrada de Plagas. Aguacate*. 2021.

- [27] 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.
- [28] 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.
- [29] R. Ding *et al.*, "Improved ResNet Based Apple Leaf Diseases Identification," *IFAC-PapersOnLine*, vol. 55, no. 32, pp. 78–82, 2022, doi: 10.1016/j.ifacol.2022.11.118.
- [30] G. Kumari, cap. Usha y Jeevan Prasad, S. y Mounika, "Detección de enfermedades de las hojas: extracción de características con agrupamiento de K-medias y clasificación con ANN," pp. 1095–1098, 2019, doi: 10.1109/ICCMC.2019.8819750.
- [31] U. E. Campos-Ferreira and J. M. González-Camacho, "CONVOLUTIONAL NEURAL NETWORK CLASSIFIER FOR IDENTIFYING DISEASES OF AVOCADO FRUIT (*Persea americana* Mill.) FROM DIGITAL IMAGES," *Agrociencia*, vol. 55, no. 8, pp. 695–709, 2021, doi: 10.47163/agrociencia.v55i8.2662.
- [32] T. F. Gonzalez, "Handbook of approximation algorithms and metaheuristics," *Handb. Approx. Algorithms Metaheuristics*, pp. 1–1432, 2007, doi: 10.1201/9781420010749.
- [33] H. Eldem, E. Ülker, and O. Y. Işıklı, "Alexnet architecture variations with transfer learning for classification of wound images," *Eng. Sci. Technol. an Int. J.*, vol. 45, no. March, 2023, doi: 10.1016/j.jestch.2023.101490.
- [34] David Beazley and B. K. Jones, *Python Cookbook: 3rd Edition*. 2013.
- [35] S. M. and N. Z. J. Zuluaga-Gomez, Z. Al Masry, K. Benaggoune, "A CNN-based methodology for breast cancer diagnosis using thermal images," *Comput. Methods Biomech. Biomed. Eng. Imaging I& Vis.*, vol. 9, pp. 131--145, 2021, doi: 10.1080/21681163.2020.1824685.
- [36] A. Baldominos, Y. Saez, and P. Isasi, "Evolutionary convolutional neural networks: An application to handwriting recognition," *Neurocomputing*, vol. 283, pp. 38–52, Mar. 2018, doi: 10.1016/J.NEUCOM.2017.12.049.
- [37] 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.
- [38] 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.