

Diseño de una Red Neuronal Convolutiva, para la Clasificación de Hojas de Plantas de Tomate Rojo Inyectadas con el Parásito del Tizón Tardío

MSC. Elmar Montiel Jiménez
Division de Ingeniería Electromecánica
Instituto TECNM Campus Libres y
Universidad DAVINCI.
elmar.mj@libres.tecnm.mx
emontiel21@udavinci.edu.mx

MC. Román Pérez Saldaña
Division de Ingeniería Sistemas
Atomotrices
Instituto Tecnológico Nacional de
México Campus Libres.
Libres Puebla, Mexico.
roman.ps@libres.tecnm.mx

MI. Guillermo Cordova Morales
Division de Ingeniería Electromecánica
Instituto Tecnológico Nacional de
México Campus Libres.
Libres Puebla, Mexico.
guillermo.cm@libres.tecnm.mx

Resumen— De acuerdo a expertos e investigadores en el área de la agricultura, el parásito del Tizón Tardío infecta a las hojas del tomate, de una forma voraz, y en pocos días pueden llegar a infectar grandes cantidades de plantas en invernaderos, derivado de estas problemáticas que afectan a miles de productores de tomate rojo bajo invernadero en México, surge la necesidad de crear herramientas de software, que permitan auxiliar en la detección oportuna del parásito del Tizón Tardío en las primeras apariciones sobre las hojas, como es el caso del presente artículo que describe los resultados obtenidos de la implementación de la metodología utilizada para el diseño de una Red Neuronal Convolutiva o CNN (por sus siglas en inglés), que permite clasificar imágenes de hojas de tomate rojo saludables a un 100% y hojas infectadas con el parásito del Tizón Tardío a un 98%, a partir de las pruebas reales de validación respecto al número de épocas de entrenamiento, para la creación de la Red Neuronal Convolutiva se utilizó un conjunto de datos de entrenamiento de 2000 imágenes de hojas de tomate rojo infectadas con Tizón Tardío y 1525 imágenes de hojas de tomate saludable.

Palabras clave— Red Neuronal Convolutiva, Parásito del Tizón Tardío, Planta de Tomate Rojo.

Abstract— According to experts and researchers in the area of agriculture, the Late Blight parasite voraciously infects tomato leaves, and in a few days can infect large numbers of plants in greenhouses, derived from these problems. that affect thousands of greenhouse red tomato producers in Mexico, the need arises to create computer tools that allow assistance in the timely detection of the Late Blight parasite in the first appearances on the leaves, as is the case in this paper. which describes the results obtained from the implementation of the methodology used for the design of a Convolutional Neural Network or CNN (for its acronym in English), which allows classifying images of 100% healthy red tomato leaves and leaves infected with the tomato parasite. Late Blight at 98%, based on real validation tests regarding the number of training epochs, for the creation of the Convolutional Neural Network a training data set of 2000 images of red tomato leaves infected with Late Blight and 1525 images of healthy tomato leaves.

Keywords— Red Neural Convolutional, Late Blight, Red Tomato Plant

I. INTRODUCCIÓN

La agricultura es el pilar de la economía en muchos países del mundo, entre ellos México. Factores como el cambio climático, el crecimiento de la población y la seguridad

alimentaria impulsan a la industria agroalimentaria a buscar enfoques innovadores para mejorar el rendimiento de los cultivos. La Inteligencia Artificial emerge como parte esencial de la evolución tecnológica de la agroindustria, podemos encontrar tantas aplicaciones como cultivos y labores existen en el campo, desde aplicaciones para la identificación temprana de enfermedades y evaluación de daños, control de malezas, hasta el uso de robots para la cosecha de frutas y hortalizas, análisis de información satelital, gestión de los recursos agronómicos y monitoreo del ganado. Un gran abanico de modelos predictivos para mejorar la toma de decisiones agronómicas, detección de deficiencias nutricionales en los cultivos, entre otras aplicaciones de relevancia.[1].

Actualmente en México, el jitomate o tomate mexicano (tomate rojo), es uno de los cultivos más rentables para el país, ha registrado un crecimiento promedio de 9.5% en los últimos 10 años, ya que al cierre de 2020 se obtuvo un volumen de 3.27 millones de toneladas, en una superficie de más de 45,000 hectáreas y un consumo per cápita de 13.4 kilogramos, se trata de la hortaliza más cultivable tanto para consumo nacional como para exportación ya que se produce en todos los estados del país, la producción la encabeza el estado de Sinaloa, que aporta el 20% del volumen nacional, seguido de San Luis Potosí, Michoacán, Zacatecas y Jalisco [2].

Uno de los factores negativos presentes en la producción de tomate rojo a gran escala, son las enfermedades que se presentan en la etapa de producción, como es el caso del Tizón Temprano causado por *A. Solani* también conocida como mancha por *Alternaria* puede afectar las plántulas, pero generalmente se observa en plantas más viejas y es especialmente grave en plantas con poco vigor. Las plantas infectadas con este hongo pueden mostrar anillos oscuros o círculos concéntricos en los tallos, hojas más viejas y frutos; sin embargo, la infección de las hojas es el síntoma más común, los síntomas iniciales del tizón temprano aparecen en las hojas como pequeñas lesiones negras o marrones de 1 a 2 mm y, en condiciones ambientales favorables, las lesiones crecen y pueden rodearse por un halo amarillo [3].

De la importancia actual que tiene la producción de tomate rojo en México y de las experiencias vividas por los encargados de la siembra y cosecha en los invernaderos del Instituto Tecnológico Superior de Libres, Puebla, sobre el manejo y control de plagas y enfermedades, surge la necesidad de crear herramientas computacionales con CNN que auxilien con la clasificación de hojas saludables y hojas infectadas con el parásito del Tizón Tardío y que permitan una detección

oportuna de los primeros síntomas que manifiestan la aparición del parásito del Tizón Tardío.

El presente artículo está integrado en cinco apartados, el segundo apartado encontramos el análisis del estado del arte en donde se realizó un análisis de los principales proyectos encontrados relacionados a la temática de la presente investigación, en el tercer apartado se describe la metodología utilizada para la realización e implementación de la CNN, en el cuarto apartado se realiza un análisis de los resultados obtenidos al realizar las pruebas de validación sobre el entrenamiento a distintas épocas, en el último apartado se encuentran las conclusiones, recomendaciones y trabajos futuros que se pueden derivar de la presente investigación.

II. ANALISIS DEL ESTADO DEL ARTE

A continuación, se presenta un resumen de las principales fuentes de información utilizadas como apoyo, para la realización del presente proyecto de investigación:

A. Detección y clasificación de enfermedades en el tomate mediante Deep Learning y Computer Vision [4]

Se utilizan dos redes neuronales pre-entrenadas (*transfer learning*), para hacer la detección de la hoja de tomate (primera: *Faster Mask R-CNN*) y luego a partir de la detección, realizar la clasificación de la enfermedad (segunda: red neuronal convolucional), tomando como entrada el área de la imagen donde se encuentra la hoja, luego de realizar la clasificación el sistema desarrollado proporciona información de los síntomas asociados a la enfermedad, como también como proceder con la prevención y el tratamiento a seguir en tiempo real.

B. Deep Learning Techniques in Tomato Plant [5]

Aquí se examinan 38 trabajos de investigación que aplicaron técnicas de aprendizaje profundo a varios problemas de investigación en la planta de tomate. Se examinamos las áreas de investigación de plantas de tomate donde se aplica el aprendizaje profundo, se aplican técnicas de preprocesamiento de datos, se utilizan técnicas de transferencia de aprendizaje y aumento de datos.

C. A Tomato Leaf Diseases Classification Method Based on Deep Learning [6]

Toman las hojas de tomate como objetos experimentales y utiliza el método de aprendizaje profundo para extraer las características de la enfermedad en la superficie de la hoja, incluidas las tres especies más comunes (tizón, tizón tardío y enfermedad del enrollamiento amarillo de la hoja). Después del aprendizaje iterativo continuo, la red puede predecir la categoría de cada cuadro de enfermedad.

D. View of Detection of disease in tomato plant using Deep Learning Technique [7]

Se propone un enfoque de visión por computadora para identificar la enfermedad capturando las imágenes de las hojas y detectar la posibilidad de las enfermedades. Se utiliza un clasificador de aprendizaje profundo para tomar una decisión sólida que cubra una amplia variedad de apariencias de hojas. La arquitectura compacta de aprendizaje profundo, que es *MobileNet V2*, se ha ajustado para detectar tres tipos de enfermedades del tomate.

E. View of Detection of disease in tomato plant using Deep Learning Techniques [8]

Tiene como objetivo desarrollar un mecanismo automatizado para detectar enfermedades en tierras cultivadas. Técnicas de *deep learning*, concretamente con *deep learning*: *R-CNN* más rápido con extractor de funciones profundas: *ResNet50*, se utiliza para detectar y clasificar las enfermedades del tomate en las plantas. Entrenó y probó el sistema propuesto con nuestro conjunto de datos de tomate, que tiene 1090 imágenes completas de las etapas temprana, media y final de la enfermedad del tomate.

Las investigaciones recientes, analizadas anteriormente sobre detección y clasificación de enfermedades, utilizando CNN'S, la mayoría muestran una solución a partir del entrenamiento de cientos de imágenes de hojas de plantas de tomate rojo infectadas con el parásito del Tizón Tardío y hojas saludables, muestran alta efectividad y robustes a la hora de ponerlas a prueba en los espacios como invernadero y/o parcelas.

III. METODOLOGÍA

En la Figura 1, se describe la metodología utilizada para el desarrollo y diseño de la CNN, que tenga la capacidad de clasificar imágenes de hojas de tomate rojo infectadas con el parásito del Tizón Tardío y las hojas de tomate saludable, en la descripción se detalla, desde la búsqueda del conjunto de imágenes que se utilizaron para el entrenamiento de la CNN hasta la creación del algoritmo resultante implementado en Python además de las pruebas de funcionamiento y validación de las distintas configuraciones de entrenamiento, que se ejecutaron para medir la efectividad de la red.

En la siguiente lista se describen cada uno de las etapas desarrolladas durante la metodología y el cual también se puede observar en la Figura 1.

Etapa 1: Búsqueda del conjunto de imágenes de hojas de tomate saludable y con Tizon Tardion.

Después de realizar el análisis del estado del arte, se procede a la búsqueda de bases de datos que contengan información de imágenes de hojas de plantas de tomate rojo saludable y con el parásito del Tizón Tardío y por consecuente se decidió utilizar la base de imágenes que ofrece la plataforma *kaggle*[9], la cual contiene imágenes con varias categorías de enfermedades de las hojas de tomate rojo, incluyendo el Tizón Tardío y además podemos encontrar hojas saludables como se puede observar en la Figura 2.

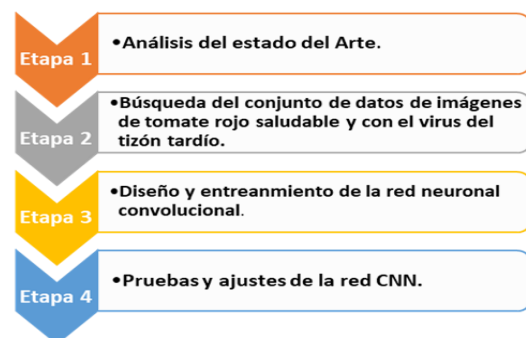


Fig. 1. Metodología utilizada para dar solución a la problemática planteada.

Etapa 2: Búsqueda del conjunto de imágenes de hojas de tomate saludable y con Tizon Tardion.

Como segunda etapa se realizó el diseño y entrenamiento de la estructura de la CNN, toda la programación de los algoritmos se realizó en el entorno de Jupyter de Python y con la ayuda de las herramientas de Deep Learning de Tensorflow.



Fig. 2. Conjunto de imágenes ejemplo obtenido de la plataforma kaggle.

Para poder realizar el entrenamiento de la CNN se realizó una distribución en carpetas de las imágenes obtenidas de la base de datos, como lo aconsejan algunos expertos en estas áreas [10], en la siguiente Tabla 1 se muestra el número de imágenes y como se realizó la distribución.

Etapa 3: Diseño y entrenamiento de la CNN

Como tercera etapa se realizó el diseño y entrenamiento de la estructura de la CNN, toda la programación de los algoritmos se realizó en el entorno de Jupyter de Python y con la ayuda de las herramientas de Deep Learning de Tensorflow.

Para poder realizar el entrenamiento de la CNN se realizó una distribución en carpetas de las imágenes obtenidas de la base de datos, como lo aconsejan algunos expertos en estas áreas [10], en la Tabla 1 se muestra el número de imágenes y como se realizó la distribución.

TABLA 1. NUMERO DE IMÁGENES PARA EL ENTRENAMIENTO Y VALIDACIÓN DE LA RED NEURONAL CONVOLUCIONAL

Imagen	No. Total, de Imágenes	Imágenes de Entrenamiento 80%	Imágenes de Validación 20%
Planta con Tizón Tardío	2000	1527	482
Planta Saludable	1525	1207	318

Etapa 3: Diseño y entrenamiento de la CNN.

Como tercera etapa se procedió a diseñar y entrenar la CNN, toda la programación de los algoritmos se realizó en el entorno de Jupyter de Python y con la ayuda de las herramientas de Deep Learning de Tensorflow.

Para poder realizar el entrenamiento de la CNN se creó una distribución especial en carpetas las imágenes obtenidas de la base de datos, como lo aconsejan algunos expertos en estas áreas [10] del diseño de CNN's, como se mostró en la Tabla 1 el número de imágenes utilizadas para cada categoría de entrenamiento y validación.

Una vez terminada la clasificación de las imágenes en carpetas y subcarpetas, se procedió con la creación de un algoritmo en el entorno de Jupyter de Python que permita diseñar y entrenar la CNN, el pseudocódigo generado de describe en el Cuadro 1.

CUADRO 1. Pseudocódigo del diseño y entrenamiento de la CNN.

```

i. Incluir librerías de tensorflow, keras, matplotlib, y numpy.
ii. Redimensionar las imágenes a un tamaño de (224, 224).
ii. Realizar aumento de datos, del conjunto de imágenes de
entrenamiento y validación, con los siguientes
parámetros:
    a. Rango de cambio de rotación = 5
    b. Rango de cambio de ancho = 0.2
    c. Rango de cambio de altura = 0.2
    d. Rango de cambio de inclinado = 0.2
    e. Rango de zoom = 0.2
    f. Re escala = 1./255
v. Validación del número de clases existentes en el conjunto
de imágenes de entrenamiento.
v. Diseño del modelo de la red neuronal en Tensor Flow con
los siguientes parámetros.
    a. Capa 1: Conv2D (Filtro=8, Tamaño del kernel = (3,
    3), función de activación = 'Relu', tamaño de la
    imagen de entrada (224, 224, 3)).
    b. Capa 2: MaxPooling2D (Tamaño del pool = (2, 2),
    no. de pasos=2).
    c. Capa 3: Conv2D (Filtro=16, Tamaño del kernel =
    (3, 3), función de activación = 'Relu').
    d. Capa 4: MaxPooling2D (Tamaño del pool = (2, 2),
    no. de pasos=2).
    e. Capa 5: Conv2D (Filtro=32, Tamaño del kernel =
    (3, 3), función de activación = 'Relu').
    f. Capa 6: MaxPooling2D (Tamaño del pool = (2, 2),
    no. de pasos=2).
    g. Aplanamos capas.
    h. Capa 7: Densidad de la red (64, función de
    activación = 'relu').
    i. Capa 8: última capa (número de classes, tipo de
    activación = 'softmax')
vi. Diseño del compilador:
    a. Optimizador Adam (Tasa de aprendizaje = 0.0001)
    b. Función entropía cruzada entre las etiquetas y las
    predicciones (from_logits = True).
    c. Tipo de métrica ['accuracy'].
ii. Entrenamiento de la Red Neuronal:
    a. Tamaño del Lote = 32
    b. Generador de muestras de entrenamiento,
    c. Rango de cambio de rotación = 5
    d. Pasos por época = Generador de muestras de
    entrenamiento // Tamaño del Lote,
    e. Épocas=20,
    f. Generador de muestras de validación,
    g. Pasos por validación = Generador de muestras de
    validación // Tamaño del Lote,
    h. Aleatorio = verdadero
    
```

En la Figura 3 se aprecia el modelo de la CNN diseñado, con los datos que se describieron en el algoritmo anterior y también se aprecia el número de capas y nodos que se tienen que entrenar y validar.

```

Model: "sequential"
Layer (type)                Output Shape                Param #
-----
conv2d (Conv2D)             (None, 222, 222, 8)        224
max_pooling2d (MaxPooling2D) (None, 111, 111, 8)        0
conv2d_1 (Conv2D)           (None, 109, 109, 16)       1168
max_pooling2d_1 (MaxPooling2D) (None, 54, 54, 16)         0
conv2d_2 (Conv2D)           (None, 52, 52, 32)         4640
max_pooling2d_2 (MaxPooling2D) (None, 26, 26, 32)         0
flatten (Flatten)           (None, 21632)               0
dense (Dense)               (None, 64)                  1384512
dense_1 (Dense)            (None, 2)                   130
-----
Total params: 1,390,674
Trainable params: 1,390,674
Non-trainable params: 0
    
```

Fig. 3. Modelo de la CNN diseñado.

Etapa 4: Pruebas y ajustes de la red CNN.

En esta etapa cuatro de la investigación, se desarrollaron las pruebas, de los ajustes necesarios del número de épocas de entrenamiento de la CNN diseñada, lo cual permite realizar un análisis del mejor funcionamiento de la red, de donde se observarán el comportamiento de los parámetros de error enteramiento y validación, así como las pruebas reales con imágenes de hojas de tomate rojo con Tizón Tardío y hojas saludables.

En la Tabla 2 se muestran los resultados obtenidos de las pruebas realizadas con distintos números de épocas de la CNN diseñada, el peor comportamiento de la red fue con 10 épocas, ya que obtuvo un 97.62% de efectividad, un 0.06% de error de aprendizaje, y un 92% de validación con el Tizón Tardío

Además del resultado descrito en Tabla 2, se puede realizar un análisis, que el mejor comportamiento de la CNN diseñada, fue cuando se ejecutó con 60 épocas, arrojando un 99.60% de efectividad de entrenamiento y un 0.02% de error de validación, además un 98% de validación de las imágenes con Tizón Tardío.

TABLA 2. VALORES OBTENIDOS CON DISTINTAS EPOCAS DE ENTRENAMIENTO

No. de épocas	%Efectividad	% Error de aprendizaje	%Validación imágenes Saludables	%Validación imágenes con Tizón
10	97.62	0.06	100	92
20	98.62	0.04	100	94
30	99.37	0.03	100	97
40	99.50	0.03	100	96
50	99.50	0.02	100	97
60	99.60	0.02	100	98

Cuando se integró un entrenamiento con 70 épocas se observa, que existe un sobre entrenamiento de la CNN, debido a que comienza a bajar el porcentaje de prueba de validación con las imágenes de hojas de jitomate con tizón tardío, por tal

motivo se tomó la decisión de no seguir el entrenamiento con 80, 90 y 100 épocas.

De la información obtenida en la Tabla 2, también deduce que la CNN diseñada es capaz de clasificar al 100% las imágenes de plantas saludables en cualquier nivel de entrenamiento y al 98% imágenes de plantas con Tizón Tardío.

IV. RESULTADOS

Una vez finalizadas las corridas con distintos valores de épocas de entrenamiento sobre la CNN diseñada, gracias a sus graficas de entrenamiento y las pruebas sobre imágenes reales hojas de jitomate saludables y con tizón tardío, se concluyó, que el mejor desempeño fue con 60 épocas y lo cual se corrobora en la Tabla 2, además en la Figura 4 se observa el resultado de las gráficas de entrenamiento y validación.




Fig. 4 Graficas de entrenamiento y validación con 60 épocas

En la Figura 5 se observa el resultado de la aplicación real de una muestra aleatoria de 40 imágenes de hojas de plantas de tomate rojo saludables, y al ejecutar el algoritmo de la Red CNN, el resultado obtenido es del 100% como “Plantas Saludables” y 0% de imágenes “Plantas con Tizón”, con lo cual se puede analizar que el entrenamiento y el número de imágenes utilizadas para el entrenamiento fue el adecuado.



Fig. 5 Resultado de validación de la red neuronal convolucional con imágenes de hojas saludables.

En la Figura 6 se puede apreciar el resultado de la aplicación real de una muestra aleatoria de 40 imágenes de hojas de plantas de tomate rojo infectadas con el parasito del

Tizón Tardío, y al ejecutar el algoritmo de la CNN, el resultado obtenido es del 98% como “Plantas con Tizón” y 2% de imágenes identificadas como Plantas Saludables”, con lo cual se puede determinar que existe aún un pequeño error de clasificación de la CNN diseñada y se podría mejorar con un mayor conjunto de imágenes que contengan el parasito del Tizón Tardío.

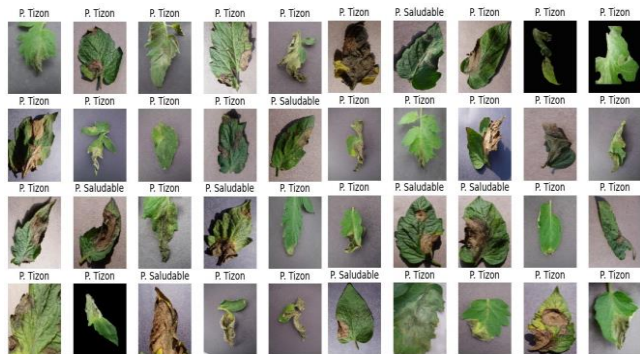


Fig 6. Resultado de validación de la red neuronal convolucional con imágenes de hojas infectadas con Tizón Tardío.

V. CONCLUSIONES

El potencial actual de las CNN, ha permitido a una gran cantidad de investigadores, expertos y empresas, crear soluciones robustas y eficaces en beneficio del ser humano, como es el caso de la presente investigación, como apoyo a mejorar el control y detección oportuna del Tizón Tardío en hojas de tomate rojo.

La CNN diseñada y entrenada fue capaz de realizar una clasificación máxima entre imágenes de hojas de tomate rojo “saludables” (100%) y “hojas con Tizón Tardío” (98%), por lo que se observo que, con cualquier caso de nivel de épocas, siempre se reconoció en su totalidad las imágenes saludables.

Al realizar pruebas reales con imágenes en distintas épocas de entrenamiento con la CNN se observó también que, aunque la validación otorgada por Tensorflow fuera alta en el reconocimiento del Tizón, no significa que el porcentaje de reconocimiento con imágenes reales es el mismo, por lo regular es 2% más bajo.

Para mejora el rendimiento de la CNN diseñada en la clasificación “hojas con Tizón Tardío” se recomienda utilizar una mayor cantidad de imágenes, ya que en la presente investigación se utilizaron cerca de 1527 imágenes para el entrenamiento además utilizar otra configuración de las capas ocultas.

Como trabajo futuro de la presente investigación, es la implementación de la red CNN diseñada, sobre un dron, que permita a los encargados del invernadero ubicado en las

instalaciones del TECNM campus Libres, auxiliar en la supervisión e inspección diaria de las hojas de jitomate.

REFERENCIAS

- [1] "La inteligencia artificial al servicio de la agricultura", *Agronet.gov.co*, 2022. [Online]. Available: <https://www.agronet.gov.co/Noticias/Paginas/La-inteligencia-artificial-al-servicio-de-la-agricultura.aspx>. [Accessed: 05- Sep- 2022].
- [2] K. México, "Tizón temprano / Koppert México", *Koppert.mx*, 2022. [Online]. Available: <https://www.koppert.mx/retos/control-de-enfermedades/tizon-temprano/>. [Accessed: 05- Sep- 2022].
- [3] S. Rural, "México, referente mundial en el cultivo y exportación de jitomate: Agricultura", *gob.mx*, 2022. [Online]. Available: <https://www.gob.mx/agricultura/prensa/mexico-referente-mundial-en-el-cultivo-y-exportacion-de-jitomate-agricultura>. [Accessed: 05- Sep- 2022].
- [4] S. Valenzuela Cámara, "Detección y clasificación de enfermedades en el tomate mediante Deep Learning y Computer Vision", *Mastria, Universidad Nacional de La Plata Facultad de Informática*, 2022.
- [5] S. Mohana Saranya, R. Rajalaxmi, R. Prabavathi, T. Suganya, S. Mohanapriya and T. Tamilselvi, "Deep Learning Techniques in Tomato Plant – A Review", *Journal of Physics: Conference Series*, vol. 1767, no. 1, p. 012010, 2021. Available: <https://iopscience.iop.org/article/10.1088/1742-6596/1767/1/012010/meta>
- [6] J. Ding, L. Fudong and Y. Yuequan, "A Tomato Leaf Diseases Classification Method Based on Deep Learning", *IEEE EXPLORE*, no. 1948-9439, pp. 1-6, 2020.
- [7] S. Zaki, M. Asyraf Zulkifley, M. Mohd Stofa, N. Kamari and N. Ayuni Mohamed, "Classification of tomato leaf diseases using MobileNet v2", *IAES International Journal of Artificial Intelligence (IJ-AI)*, vol. 9, no. 2, p. 290, 2020. Available: <http://download.garuda.kemdikbud.go.id/article.php?article=1541849&val=151&title=Classification%20of%20tomato%20leaf%20diseases%20using%20MobileNet%20v2>. [Accessed 6 September 2022].
- [8] S. Kumar, "View of Detection of disease in tomato plant using Deep Learning Techniques", *Modern-journals.com*, 2022. [Online]. Available: <http://www.modern-journals.com/index.php/ijma/article/view/374/319>. [Accessed: 06- Sep- 2022].
- [9] Kaggle. "Find open datasets and machine learning projects | Kaggle". *kaggle: your machine learning and data science community*. <https://www.kaggle.com/datasets> (accedido el 14 de septiembre de 2022).
- [10] V. Nithyashree. "Image classification | Step-by-Step guide for Image Classification". *Analytics Vidhya*. <https://www.analyticsvidhya.com/blog/2021/07/step-by-step-guide-for-image-classification-on-custom-datasets/> /accedido el 21 de septiembre de 2022