

# DISEÑO E IMPLEMENTACIÓN DE UN MODELO DE DEEP LEARNING PARA LA CLASIFICACIÓN DE PLAGAS EN EL JITOMATE

<sup>1</sup>Derlis Hernández Lara, dderlis-lara@tese.edu.mx

<sup>2</sup>Yaretzi Denisse Aragón Vera, 201910961@tese.edu.mx

<sup>3</sup>Emmanuel Tonatihu Juárez Velázquez, emmanuel.juarez@tese.edu.mx

<sup>4</sup>Jonathan Cristian Gómez Ferreyra, 201710066@tese.edu.mx

<sup>5</sup>Carlos Alfonso Trejo Villanueva, carlostrejo@tese.edu.mx

## RESUMEN

El reconocimiento de imágenes mediante aprendizaje automático se basa en la capacidad de los algoritmos para identificar patrones ocultos a partir de datos organizados y no organizados, a lo que se le conoce como aprendizaje supervisado. El enfoque más destacado es el Deep Learning, que emplea múltiples capas ocultas en un modelo que, en conjunto con hardware de Inteligencia Artificial robusto, como una GPU, pueden lograr un alto rendimiento en la clasificación a través de visión por computadora. Esta investigación se centra en implementar una arquitectura de Redes Neuronales Artificiales para identificar plagas en plantaciones de jitomate usando imágenes. Se aplicó la metodología de Design Thinking, que considera al usuario final, proporcionando una herramienta tecnológica para optimizar la producción agrícola. Los resultados preliminares sugieren que estas soluciones tienen un gran potencial para abordar necesidades reales mediante tecnologías emergentes y mejorar la toma de decisiones en la gestión agrícola, evitando pérdidas de producto.

## PALABRAS CLAVE

Agricultura  
Design Thinking  
Plagas en el tomate  
Visión artificial

## ABSTRACT

Machine learning image recognition relies on the ability of algorithms to identify hidden patterns from organized and unorganized data, referred to as supervised learning. The most prominent approach is Deep Learning, which employs multiple hidden layers in a model that, in conjunction with robust AI hardware such as a GPU, can achieve high performance in classification through computer vision. This research focuses on implementing an Artificial Neural Network architecture to identify pests in tomato plantations using images. Design Thinking methodology was applied, which considers the end user, providing a technological tool to optimize agricultural production. Preliminary results suggest that these solutions have great potential to address real needs through emerging technologies and improve decision making in agricultural management, avoiding product losses.

## KEYWORDS

Agriculture  
Design Thinking  
Pests in tomato  
Artificial vision

<sup>1</sup> Tecnológico Nacional de México – TESE / Universidad Politécnica de Texcoco / Docente.

<sup>2</sup> Tecnológico Nacional de México – Tecnológico de Estudios Superiores de Ecatepec / Estudiante.

<sup>3</sup> Tecnológico Nacional de México – TESE / Universidad Politécnica de Texcoco / Docente.

<sup>4</sup> Tecnológico Nacional de México – Tecnológico de Estudios Superiores de Ecatepec / Estudiante.

<sup>5</sup> Tecnológico Nacional de México – Tecnológico de Estudios Superiores de Ecatepec / Docente.



## I. INTRODUCCIÓN

La agricultura es la actividad relacionada con el aprovechamiento de especies vegetales cultivadas a cielo abierto en terrenos, predios, parcelas y huertos; del mismo modo, aquellas cultivadas en la agricultura protegida; con el fin de obtener alimentos para consumo humano y animal, así como para suministrar materias primas a la industria, incluye la producción de plantas ornamentales.

Cómo en toda industria el principal objetivo es tener el mejor producto y las mejores ganancias, por esto es importante monitorear la presencia de plagas y enfermedades, esto se refiere a la labor destinada a estimar la abundancia y distribución de las plagas y sus enemigos naturales en el cultivo a través de muestreos periódicos. La meta es determinar el momento de realizar medidas de control, ya sea aplicación de pesticidas, liberación de enemigos naturales u otras. A través de este manejo se intenta minimizar el daño de las plagas en la cosecha (INEGI, 2023).

El jitomate es una de las hortalizas más importantes cultivadas en huertos y también es conocido como tomate o tomatera (*Solanum lycopersicum*), es una planta perenne que se encuentra dentro de las hortalizas de fruto de la familia botánica de las Solanáceas, igual que la patata o papa, la berenjena y el pimiento. Es uno de los cultivos más importantes de México pues ocupa el décimo lugar a nivel mundial en superficie sembrada, esta especie hortícola es la más cultivada tanto a cielo abierto como en invernadero (ecoagricultor, 2012).

Durante el cultivo del tomate puede ser común que aparezcan algunas plagas como lo son: a) La mosca blanca (*Trialeurodes vaporariorum*), que es uno de los insectos que se encuentran en huertas y jardines y que se distinguen con facilidad, como se presenta en la Fig. 1 (a), esta es pequeña, midiendo entre 1 y 3 mm de largo (Díaz, 2015); b) Polilla del tomate (*Tuta absoluta*), lo síntomas que causa este lepidóptero son minas anchas que dejan intacta la epidermis, pero se pueden apreciar restos de excrementos en su interior, como se observa en la Fig. 1 (b) (Pérez, 2015); c) La araña roja o arañuela (*Tetranychus urticae*) que es un ácaro como se muestra en la Fig. 2, deja las hojas descoloridas con pequeños punteados y sedas. Aunque se llama comúnmente araña roja, también puede ser de color verde o amarillo (Muñoz, 2014).

Fig. 1. (a) *Mosca blanca*, (b) *Tuta absoluta*.



(a)



(b)

Fig. 2. *Araña roja o arañuela*.



Actualmente, la tecnología en la agricultura se aplica desde la instalación de sensores en los árboles, medir el terreno, programar el riego, determinar mediante un algoritmo la cantidad adecuada para fertilizar los cultivos, entre otros. La actualización constante del sector agrícola pasa por su «informatización», adaptando los aperos de labranza y la maquinaria a la inteligencia artificial para poder controlar y aprovechar sin desperdicio el cultivo (Ramón Fernández, 2020). Por lo anterior, a continuación, se presentan algunos antecedentes de sistemas de visión artificial en la agricultura.

Existen proyectos que permiten la identificación de enfermedades en el cultivo del cacao denominadas Moniliasis, apoyados de las tecnologías emergentes como la robótica y la visión artificial en la búsqueda de mejorar la vida del agricultor y su inmersión en las nuevas herramientas tecnológicas (Cárdenas Navarro, Rojas Martínez, Duarte Galeano, & Estupiñán Manrique, 2022). Por otro lado, en investigaciones previas se han implementado prototipos de sistemas de detección de malezas basados en hardware especializado (Zynq) y procesamiento de imágenes. Estos sistemas permiten detectar malezas en líneas entre cultivos, independientemente del tipo de cultivo y de su estado fenológico (Noguera, Leiva, Goñi, Vázquez, & Tosini, 2020).

Se han desarrollado trabajos con soluciones informáticas utilizando visión artificial para la detección de enfermedades en el cultivo de papa. Por lo tanto, los estudios se realizan directamente en el campo agrícola, que presenta una problemática en la detección de enfermedades (Morán Delgado, Quiranza Arciniega, & MSc. Carlitos, 2022). Hay sistemas con el objetivo de detectar la patología Sigatoka negra en el cultivo de banano, aplicando visión de computadora y técnicas de aprendizaje automático para el desarrollo de un aplicativo móvil que captura la imagen de la hoja y recomienda el tratamiento por lote aplicable, además de un aplicativo web para ofrecer seguimiento del tratamiento (Méndez León, Montaña Luzcando, & Ing. Bermeo Almeida, 2022).

Otros trabajos explican que la descripción de características es un proceso fundamental en el análisis de imágenes para la recuperación y clasificación basadas en el contenido, entre otras tareas en las que el descriptor de características de la imagen debe poder diferenciar imágenes similares de las disímiles según una medida de distancia. Aunque se han propuesto varios descriptores para una variedad de imágenes, el reto es su idoneidad para resolver eficientemente estas tareas.

Una propuesta es el conjunto de descriptores visuales estándar MPEG-7, con el fin de describir eficientemente plagas y enfermedades en imágenes de plantas de maíz. La selección de este cultivo radica en su importancia mundial para el consumo humano y animal. Los experimentos para consultas de búsqueda de similitud utilizando un conjunto de medidas de distancia, muestran que el Descriptor de Estructura de Color con la distancia Bray-Curtis es la más eficaz y proporciona una precisión del 68% en la mayoría de los casos (Manjarrez Sánchez, 2020).

Algunas investigaciones muestran métodos para la detección de plagas y enfermedades en la producción de café, utilizando imágenes multispectrales del satélite Landsat 8.

Esto permite considerar que el uso de imágenes Landsat por su resolución espectral y radiométrica es aceptable para el estudio del cultivo de café según lo observado en campo y lo obtenido en el procesamiento de la imagen, porque genera información sobre áreas cultivadas que apoyará en la toma de decisiones en la agricultura (Sánchez Méndez & Arguijo Hernández, 2018).

Después de los antecedentes presentados, se observa la pertinencia del desarrollo tecnológico propuesto para esta área de oportunidad. El objetivo de este trabajo es Diseñar un sistema de visión artificial para clasificar plagas en el jitomate, mediante el uso de herramientas de inteligencia artificial, con el fin de aportar un sistema que contribuya a la toma de decisiones en la producción de este fruto en el sector primario mexicano.

El Deep Learning, una de las técnicas más versátiles del Machine Learning (aprendizaje automático), se destaca por su capacidad para emular el procesamiento de información en las neuronas biológicas (Fig. 3) del cerebro (Moreno, 2016). Esta disciplina se fundamenta en las redes neuronales artificiales y encuentra una de sus aplicaciones más prominentes en el ámbito del reconocimiento de imágenes.

Como una herramienta de la inteligencia artificial, el Deep Learning desempeña un papel crucial en la implementación de algoritmos ampliamente utilizados en el campo de la visión artificial. Representa un enfoque de aprendizaje profundo, en el que los algoritmos adquieren conocimiento a través de un sólido fundamento matemático, tal como se ilustra en la Fig. 4, generando aproximaciones que se utilizan para resolver problemas específicos.

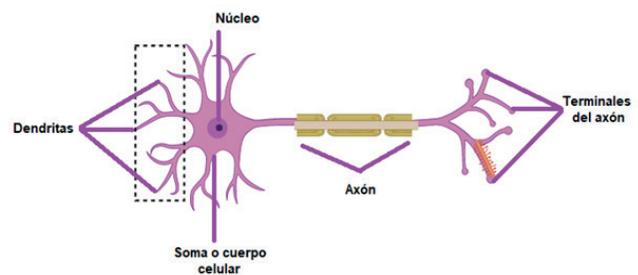


Fig. 3. Simplificación del funcionamiento de una neurona biológica.

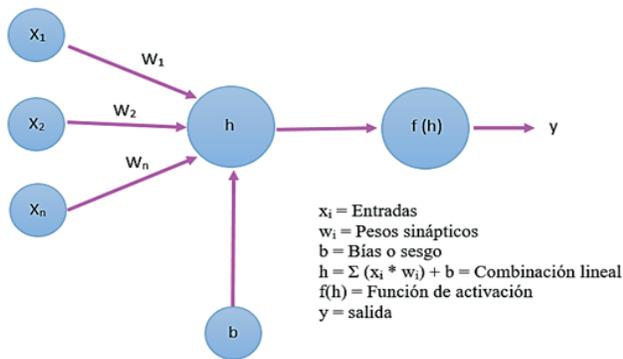


Fig. 4. Modelo matemático de una neurona artificial (Perceptrón).

## II. METODOLOGÍA

Para la obtención del diseño conceptual del prototipo se utilizó la metodología DT (del inglés Design Thinking), con la cual es sumamente importante el uso del análisis de datos para la resolución del problema. El DT considera tan importante el análisis y el raciocinio como la intuición para la resolución de problemas, permitiendo así construir ideas con base a la función del sistema y a las emociones de los usuarios. Esta herramienta gira alrededor de la experiencia de las personas, permitiendo ponerse en su lugar y obtener mejores resultados. El objetivo es satisfacer las necesidades sociales de una forma que sea tecnológicamente factible y comercialmente viable, permitiendo obtener mejores resultados, como se presenta en la Fig. 5 (AQUAE FUNDACIÓN, 2021).

Es importante tomar un enfoque en la problemática, en este caso las plagas que están afectando al jitomate, a veces los agricultores desconocen o llegan a confundirse entre una y otra plaga para su clasificación. Ayudar o aportar una herramienta dentro de esta área de oportunidad es importante porque existe un gran número de productores que sufren pérdidas en sus cosechas, con la propuesta de esta investigación se aportará una adecuada clasificación de las plagas con el fin de tomar mejores decisiones (Pomar, 2018).

Desarrollando el DT se obtuvo que un modelo de visión artificial con Deep Learning para la clasificación de plagas en el jitomate mediante imágenes del cultivo de estudio sería conveniente. Se optó por utilizar Python porque es un lenguaje de programación interpretado cuya filosofía hace hincapié en la legibilidad de su código y es multiparadigma, porque soporta parcialmente la orientación de objetos, programación imperativa y, en menor medida, programación funcional.



Fig. 5 Metodología Design Thinking.

El proceso de diseño se fundamentó en una serie de decisiones a lo largo de todo el proyecto para generar un producto adecuado a las necesidades del usuario. Este modelo está pensado para un uso fácil de entender para cualquier persona. Entonces, como ya se mencionó, la propuesta hará el reconocimiento de plagas mediante imágenes, el usuario tomará una foto del cultivo y se subirá a la nube, después se pasará al sistema para poder detectar si existen plagas en el huerto y su correcta clasificación. El proceso seguido se muestra en la Fig. 6.

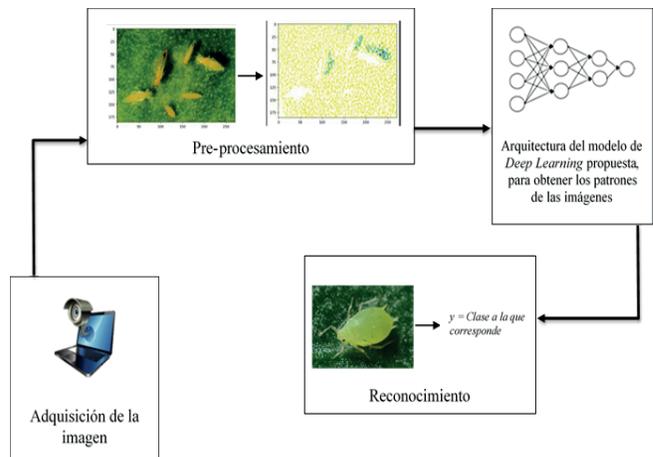


Fig. 6 Diagrama general del proceso seguido para el clasificador.

La propuesta clasifica entre 7 plagas como se muestra en la Tabla 1, haciendo uso de la visión artificial y como herramienta una computadora con mínimo 8 GB en RAM y procesador de 4 núcleos, con cámara, y programación en Python sobre Google Colaboratory con apoyo de Open-CV. Las características de las imágenes de entrada al modelo son las siguientes: formato .jpg, 224 x 224 píxeles, RGB.

La arquitectura propuesta está compuesta de ciertas etapas, en donde se realizó la generación de la base de datos (BD) con imágenes de plagas en el jitomate para hacer el entrenamiento del modelo de Deep Learning, al tener la BD se prosiguió a hacer el pre-procesamiento de los datos, para después realizar la creación y construcción del modelo. Una vez hecho lo anterior, se realizaron las pruebas pertinentes del modelo para validarlo y ver su funcionamiento. Como última etapa del sistema se adquiere la imagen mediante la cámara, la cual es procesada, mejorada y convertida al formato de color (RGB) adecuado para esta tarea, para posteriormente ser comparada con el modelo ya entrenado anteriormente, reconociéndola y obteniendo una salida (etiqueta de la plaga a la que pertenece la imagen).

Tabla 1. Base de datos para la clasificación del modelo.

| Plaga         | Número de imágenes |
|---------------|--------------------|
| Pulgón        | 230                |
| Mosca blanca  | 200                |
| Araña roja    | 266                |
| Heliotis      | 209                |
| Minador       | 230                |
| Tuta absoluta | 230                |
| Trips         | 230                |

Las imágenes utilizadas para el entrenamiento del clasificador de plagas fueron descargadas de diferentes fuentes de internet, estas son almacenadas en una carpeta y nombradas con números consecutivos, posteriormente la carpeta se carga en un servidor en la nube, el tamaño de las imágenes no se tomó en cuenta porque más adelante serán redimensionadas durante el proceso de conversión a vectores de datos, una vez procesadas las imágenes a vectores, se genera un nuevo archivo .csv en donde se almacenan los datos de las imágenes procesadas como su muestra en la Fig. 7, lo que se toma a consideración es la calidad de la imagen, en cuestión de que se distinga la plaga a identificar, debido a que al momento de ser procesadas se tomará en cuenta el color, la forma y la silueta.

En total se obtuvieron 7000 imágenes, divididas entre 7 clases como se presenta en la Fig. 8, de esta manera se cuenta con suficiente información para el modelo de entrenamiento y así no se presenten dificultades durante el aprendizaje.

| A        | B        | C        | D        | E        | F        | G        |
|----------|----------|----------|----------|----------|----------|----------|
| 5.84E-04 | 1.54E-03 | 0.00E+00 | 1.69E-03 | 2.61E-03 | 1.08E-03 | 8.77E-04 |
| 1.05E-03 | 2.03E-03 | 1.85E-04 | 8.61E-04 | 1.75E-03 | 1.69E-04 | 1.15E-03 |
| 1.37E-03 | 2.31E-03 | 4.77E-04 | 1.03E-03 | 1.92E-03 | 3.38E-04 | 1.40E-03 |
| 1.21E-03 | 2.11E-03 | 5.23E-04 | 6.15E-04 | 1.49E-03 | 4.61E-05 | 1.41E-03 |
| 1.12E-03 | 1.98E-03 | 6.15E-04 | 1.85E-04 | 1.01E-03 | 0.00E+00 | 7.23E-04 |
| 1.49E-03 | 2.32E-03 | 1.00E-03 | 4.92E-04 | 1.31E-03 | 4.61E-05 | 4.92E-04 |
| 1.46E-03 | 2.28E-03 | 9.23E-04 | 4.92E-04 | 1.29E-03 | 3.08E-05 | 8.77E-04 |
| 1.46E-03 | 2.28E-03 | 9.23E-04 | 4.92E-04 | 1.29E-03 | 3.08E-05 | 8.77E-04 |
| 7.69E-04 | 1.55E-03 | 3.38E-04 | 6.92E-04 | 1.48E-03 | 2.92E-04 | 4.46E-04 |
| 4.61E-05 | 7.54E-04 | 0.00E+00 | 4.46E-04 | 1.17E-03 | 1.23E-04 | 1.69E-04 |
| 2.77E-04 | 9.69E-04 | 6.15E-05 | 3.08E-04 | 1.01E-03 | 1.54E-05 | 2.77E-04 |
| 4.61E-04 | 1.15E-03 | 1.54E-04 | 4.31E-04 | 1.14E-03 | 3.08E-05 | 4.46E-04 |
| 1.38E-04 | 8.00E-04 | 0.00E+00 | 6.00E-04 | 1.28E-03 | 1.23E-04 | 7.23E-04 |
| 6.15E-05 | 7.07E-04 | 0.00E+00 | 7.23E-04 | 1.38E-03 | 2.77E-04 | 1.38E-03 |
| 2.92E-04 | 9.23E-04 | 6.15E-05 | 6.00E-04 | 1.26E-03 | 1.69E-04 | 1.60E-03 |
| 3.54E-04 | 9.69E-04 | 4.61E-05 | 4.92E-04 | 1.14E-03 | 3.08E-05 | 1.08E-03 |
| 5.38E-04 | 1.17E-03 | 9.23E-05 | 9.69E-04 | 1.63E-03 | 4.00E-04 | 9.07E-04 |
| 2.00E-04 | 1.08E-03 | 0.00E+00 | 9.69E-04 | 1.83E-03 | 7.07E-04 | 7.07E-04 |
| 6.61E-04 | 1.52E-03 | 3.69E-04 | 2.77E-04 | 1.14E-03 | 1.54E-05 | 0.00E+00 |
| 3.38E-04 | 1.20E-03 | 4.61E-05 | 5.69E-04 | 1.38E-03 | 2.77E-04 | 6.31E-04 |
| 1.45E-03 | 2.28E-03 | 1.12E-03 | 1.38E-04 | 9.53E-04 | 0.00E+00 | 3.08E-04 |

Fig. 7 Base de datos de imágenes de plagas del jitomate en formato vector.



Fig. 8 Base de datos de imágenes de plagas en el jitomate.

Con el objetivo de potenciar la eficacia del clasificador, se han realizado ajustes en los hiperparámetros clave, incluyendo las épocas de entrenamiento, el número de neuronas y las capas de aprendizaje, buscando intensificar la precisión del sistema, el modelo utilizado se presenta en la Fig. 9. A pesar del intento inicial de utilizar siluetas como método de identificación, se ha enfrentado el desafío de las variaciones en colores y tamaños de las plagas que han obstaculizado su detección. No obstante, se está continuando la investigación en torno a la viabilidad de emplear siluetas, dada la posibilidad de confusión con los colores de las hojas.

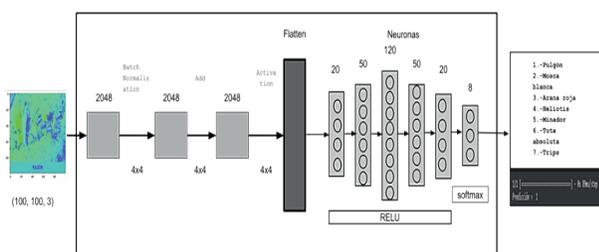


Fig. 9 Diagrama del resumen del modelo final (HSV).

A lo largo del proceso de entrenamiento del modelo se fueron realizando pruebas con varias propuestas y tipos de preprocesamiento de las imágenes utilizadas, con el fin de encontrar la arquitectura que mejores resultados generara, para ejemplificar estos experimentos se presenta la Tabla 2 que resume las principales pruebas obtenidas, en donde se muestran el número de capas, las escalas de color, las épocas y las métricas de cada propuesta trabajada.

Los hiperparámetros en vigor han conseguido superar un umbral del 85% de precisión, respaldados por 50 épocas de entrenamiento, tres capas y un total de 165 neuronas. Cabe destacar que se aprovecha la transferencia de conocimiento de la red neuronal convolucional MobileNetV2, y se aplican redimensionamientos en las imágenes de entrenamiento para optimizar el procesamiento.

En el proceso de entrenamiento, el 80% de las imágenes se destinan al aprendizaje y se les asignan las etiquetas correspondientes, mientras que el 20% restante se reserva para pruebas y validaciones. Para preservar la integridad de la transferencia de conocimiento, se mantienen congeladas las capas base. La etapa final involucra la prueba del modelo configurado, con una categorización de datos en «perdidos» y «logrados», lo cual permite una evaluación precisa de las métricas de validación durante el proceso de entrenamiento.

| Número de Capas   | Escala de color        | Épocas | Val. Entrenamiento               | Val. Validación                    |
|---|------------------------|--------|----------------------------------|------------------------------------|
| Dense = 30-act. relu<br>Dense = 60-act. relu<br>Dense = 90-act. relu<br>Dense = 120-act. relu<br>Dense = 90-act. relu<br>Dense = 60-act. relu<br>Dense = 30-act. relu<br>Dense = 8-act. softmax | Se utilizó escala Lab  | 40     | Acertamiento: 91%<br>Pérdida: 4% | Acertamiento: 50%<br>Pérdida: 80%  |
| Dense = 20-act. relu<br>Dense = 30-act. relu<br>Dense = 60-act. relu<br>Dense = 30-act. relu<br>Dense = 20-act. relu<br>Dense = 8-act. softmax  | Se utilizó escala LUV  | 60     | Acertamiento: 93%<br>Pérdida: 2% | Acertamiento: 50%<br>Pérdida: 95%  |
| Dense = 20-act. relu<br>Dense = 50-act. relu<br>Dense = 120-act. relu<br>Dense = 50-act. relu<br>Dense = 20-act. relu<br>Dense = 8-act. softmax   | Se utilizó escala HSV  | 50     | Acertamiento: 99%<br>Pérdida: 1% | Acertamiento: 67%<br>Pérdida: 65%  |
| Dense = 20-act. relu<br>Dense = 40-act. relu<br>Dense = 60-act. relu<br>Dense = 40-act. relu<br>Dense = 20-act. relu<br>Dense = 8-act. softmax  | Se utilizó escala Gray | 70     | Acertamiento: 99%<br>Pérdida: 1% | Acertamiento: 59%<br>Pérdida: 500% |

Tabla 2. Características y resultados de cada modelo propuesto en la fase de experimentación.

### III. RESULTADOS

Para una mejor comparación y/o validación de la efectividad del sistema se utilizan las métricas de precisión y error, en la gráfica de la precisión (Accuracy) aparecen dos líneas una determina los valores perdidos o las fallas que presentó el modelo durante su proceso de entrenamiento, así como la exactitud alcanzada tanto con los datos de entrenamiento, como los de prueba, también se presenta el error del modelo, este último sigue siendo grande para datos de test por la complejidad del problema como se presenta en la Fig. 10.

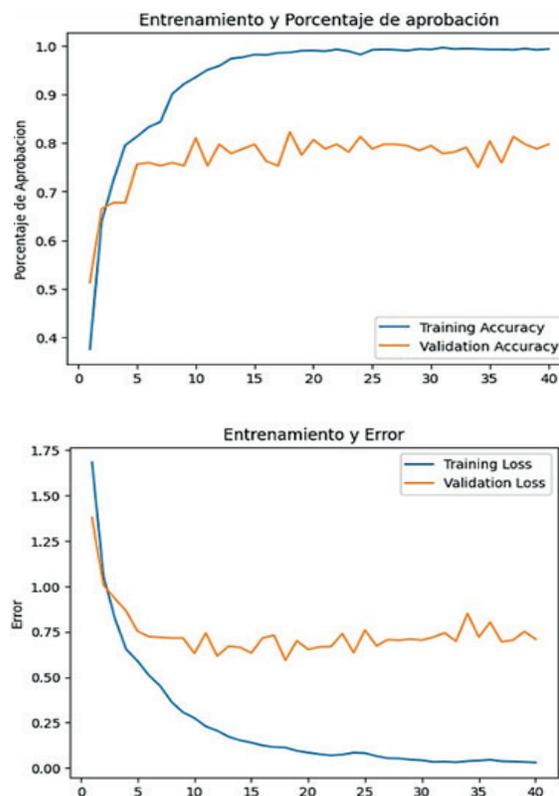


Fig. 10 Precisión del modelo propuesto para el clasificador de plagas en el jitomate.

Una vez que se ha alimentado el modelo con los datos necesarios y completado el proceso de entrenamiento, llega el momento de ponerlo a prueba. Se cargan imágenes desconocidas en el clasificador, y este utiliza su conocimiento previo para identificar similitudes con las características típicas de las plagas. Luego, realiza una evaluación para determinar a qué clase de plaga pertenece, en este caso, enfocándose en las amenazas que afectan a los jitomates en el cultivo. Una vez que se logra identificar la plaga, se presenta el nombre junto con la imagen de prueba que se había cargado. Los resultados muestran que más del 85% de las pruebas realizadas con imágenes externas y de prueba han sido acertadas, lo que demuestra un alto nivel de precisión, aunque, claro está, aún existen algunos errores ocasionales

La manera en que se presentan estos resultados es clave para que los usuarios puedan entenderlos fácilmente. Se muestran en la Fig. 11 imágenes que fueron utilizadas para realizar la predicción en el modelo entrenado. Es importante destacar que, sin importar el tamaño de la imagen original, esta se redimensiona de manera automática para que el proceso de predicción sea eficiente y produzca resultados óptimos.

En algunas pruebas se presentó un error del modelo, como se mencionó anteriormente, este modelo solo genera un 85% de aciertos, esto quiere decir que no siempre tendrá una predicción acertada. En la Fig. 12 se muestran algunos casos donde hubo falla en la clasificación, por ejemplo, con la imagen 35 de la base de datos.



Fig. 11 Resultados de la detección de plagas en algunas de las pruebas realizadas.

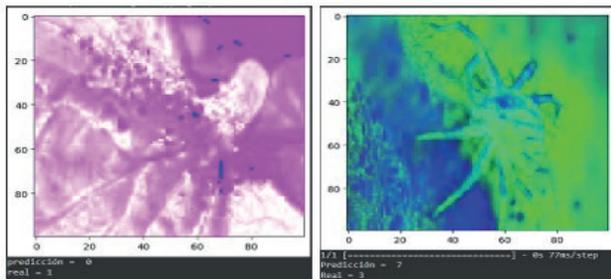


Fig. 12 Errores en la detección de plagas en algunas de las pruebas realizadas.

#### IV. CONCLUSIONES

Luego de un riguroso proceso de entrenamiento y pruebas exhaustivas del modelo propuesto, respaldado por las estadísticas meticulosamente calculadas, las conclusiones son claras: Las redes neuronales artificiales demuestran una gran capacidad para identificar con precisión prácticamente la totalidad de las imágenes de plagas, independientemente de si se basan en colores, tamaños o siluetas presentes en la base de datos de entrenamiento. Se ha logrado un nivel de precisión que ronda el 86% en todas las situaciones evaluadas. Sin embargo, con datos desconocidos aún hay que mejorar el error, para lo cual se sigue trabajando. En relación a la base de datos que contiene 7000 imágenes para las 7 clases de plagas, se observa que esta cantidad de información ha sido esencial para alcanzar la precisión esperada. Cabe mencionar que, en las pruebas, un factor recurrente que ha influido en algunas imperfecciones es la disponibilidad de datos estadísticos sólidos, los cuales amplían el alcance de la precisión y enriquecen la base de conocimientos.

Es importante resaltar que los resultados presentados son el producto de una prueba específica. Para cada análisis de los datos, se han realizado ajustes en la cantidad de imágenes utilizadas tanto para el entrenamiento como para las pruebas. No obstante, en todos los casos se ha mantenido la alta calidad de las estadísticas obtenidas, asegurando la validez y confiabilidad de la propuesta realizada.

#### REFERENCIAS BIBLIOGRÁFICAS

- Cárdenas Navarro, C. A., Rojas Martínez, L. G., Duarte Galeano, J. A., & Estupiñán Manrique, C. M. (2022). Sistema de procesamiento de imágenes y visión artificial, para el robot explorador de cultivos de cacao en Cimitarra, Santander. Santander, Colombia: Revista Tecnoacademia.
- Díaz, D. (15 de 05 de 2015). Agrohuerto. Obtenido de Todo sobre huertos: [https://www.agrohuerto.com/tomate-plagas-y-enfermedades-comunes/#Plagas\\_del\\_Tomate](https://www.agrohuerto.com/tomate-plagas-y-enfermedades-comunes/#Plagas_del_Tomate) ecoagricultor. (2012). Obtenido de Tienda ecológica: <https://www.ecoagricultor.com/plaga-tomate/>
- INEGI. (12 de ENERO de 2023). Instituto Nacional de Estadística y Geografía. Obtenido de INEGI-Agricultura: <https://www.inegi.org.mx/temas/agricultura/>
- Manjarrez Sánchez, J. (agosto de 2020). An Assessment of MPEG-7 Visual Descriptors for Images of Maize Plagues and Diseases. *IEEE Latin America Transactions*, 18(8), 1487-1494.
- Mari Soledad. (18 de 06 de 2021). intive. Obtenido de <https://intive.com/es/careers/las-5-etapas-del-design-thinking-y-sus-tecnicas>
- Méndez León, K. D., Montaña Luzcando, K. Y., & Ing. Bermeo Almeida, O. X. (2022). Implementación de una aplicación web y móvil basado en visión por computadora para el control de la enfermedad Sigatoka negra en el cultivo del banano en la hacienda Los Ángeles. Milagro, Ecuador: Universidad Agraria del Ecuador.
- Morán Delgado, D. C., Quiranza Arciniega, A. A., & MSc. Carlitos, G. (2022). Visión Artificial para la detección de enfermedades en el cultivo de papa. Tulcan, Ecuador: Universidad Politécnica Estatal del Carchi.
- Moreno, R. A. (28 de Octubre de 2016). Xataka. Obtenido de Deep learning: qué es y por qué va a ser una tecnología clave en el futuro de la inteligencia artificial: <https://www.xataka.com/robotica-e-ia/deep-learning-que-es-y-por-que-va-a-ser-una-tecnologia-clave-en-el-futuro-de-la-inteligencia-artificial>
- Muñoz, L. (14 de 05 de 2014). Agrohuerto. Obtenido de Todo sobre huertos: <https://www.agrohuerto.com/combatar-la-arana-roja-en-el-huerto-ecologico/>
- Noguera, J., Leiva, L., Goñi, O., Vázquez, M., & Tosini, M. (2020). Prototipo de Sistemas de Detección de Malezas en Cultivos Basado en SoC. Tandil, Argentina: Congreso Argentino de Sistemas Embebidos.
- Torres, D. (10 de 05 de 2022). HubSpot. Obtenido de <https://blog.hubspot.es/marketing/design-thinking>