

Redes neuronales artificiales para la detección de plagas en cultivo de jitomate bajo invernadero

E. Berra Villaseñor^{*1}, M. Pérez Castañeda¹, J. R. Cuautle Parodi¹,

¹Cuerpo académico de ingeniería aplicada, Universidad del Valle de Puebla, 3 Sur 5904, Colonia "El Cerrito",
C.P. 72440,

eduardo.berra@uvp.edu.mx

Área de participación: Sistemas Computacionales

Resumen

Las estrategias de detección y clasificación de plagas por las cuales se apuesta en su mayoría en la producción hortícola bajo invernadero, radican en recorridos visuales y en diagnósticos proporcionados en base a experiencia. El presente trabajo tiene como objetivo principal, el desarrollo y entrenamiento de una red neuronal artificial en conjunto con la toma de video mediante un robot móvil teledirigido, para la detección y clasificación de patrones en cultivos de jitomate bajo invernadero, para su validación se utilizaron imágenes de tres plagas comunes para este cultivo tomadas de un invernadero familiar, así como una zona de exclusión de hojas sin plaga, el desarrollo del método se enfoca en el uso de la red neuronal artificial bajo el modelo Keras con visión artificial, así como el uso de entrenamiento con CPU y aceleración de entrenamiento de redes neuronales artificiales mediante hardware Intel® Neural Compute Stick 2, midiendo los tiempos de entrenamiento y el porcentaje de detección de las plagas mediante la red neuronal artificial previamente entrenada.

Palabras clave: Entrenamiento redes neuronales artificiales, detección y clasificación de plagas, visión artificial.

Abstract

The strategies for detection and classification of pests which are mostly committed to horticultural production under greenhouse, lie in visual tours and diagnoses provided based on experience. The present work has as main objective, the development and training of an artificial neural network in conjunction with the video capture by means of a remote-controlled mobile robot, for the detection and classification of patterns in tomato crops under greenhouse, for its validation images were used of three common pests for this crop taken from a family greenhouse, as well as a pest-free leaf exclusion zone, the development of the method focuses on the use of the artificial neural network under the Keras model with artificial vision, as well as the use of training with CPU and acceleration of training of artificial neural networks using Intel® Neural Compute Stick 2 hardware, measuring training times and the percentage of pest detection through the previously trained artificial neural network.

Key words: RNA training, pest detection and classification, Keras, artificial vision.

Introducción

Las tecnologías para la detección de plagas mediante las redes neuronales artificiales se han visto beneficiadas en la última década por el avance en tecnologías de los dispositivos de hardware (Vega, Cortez, Huayna, Loayza, & Naupari, 2009), que permiten cada vez más acelerar los algoritmos, con menos consumo de energía y a bajo costo, gracias a esto los modelos de redes neuronales artificiales brindan hoy en día diversas soluciones, una de ellas de mayor relevancia es la que involucra el uso de visión artificial mediante cámaras de alta resolución para clasificar y detectar patrones de plagas.

Estas técnicas de detección y clasificación tienen un gran auge en la actividad humana, tal es el caso de la agricultura en cuyos procesos se manejan muchas actividades de detección y clasificación, tanto de las labores programadas para la atención del cultivo como en la recolección de la cosecha.

Se puede destacar que la actividad más importante para todos los países es la mejora de la producción agrícola (OCDE/FAO, 2017), esto conlleva a superar los métodos tradicionales de la producción agrícola que en su mayoría es regionalizada, debido a esto las nuevas tecnologías de agricultura como la agricultura de precisión y la robótica ofrecen formas para realizar estas mejoras de manera genérica basadas en análisis de

datos, una de ellas es mediante el manejo y prevención de plagas, las cuales menguan la producción y dañan a su vez la calidad del producto, ya que existen factores como el uso de pesticidas de manera inadecuada, cosechas mal desarrolladas e incluso con pérdidas totales de los cultivos por los daños generados por la plaga.

Esta detección de plagas se puede llevar a cabo mediante los patrones visuales que presenta el cultivo en particular (Arivazhagan, Newlin Shebiah, Ananthi, & Vishnu Varthini, 2013), la detección automática de los patrones que generan las plagas en las plantas del cultivo es una prioridad de investigación para los diversos desarrollos sobre detección y clasificación de plagas, ya que los beneficios que aporta el monitoreo automático de los campos tiene un impacto tanto en el tratamiento como en la prevención de las mismas.

Las técnicas de detección de plagas en cultivos bajo invernadero adoptadas en México, se basan en inspecciones visuales y recorridos de los técnicos sobre el área que cubre el invernadero, estos recorridos fitosanitarios son programados de acuerdo al cultivo y tienen como fin determinar los siguientes aspectos:

- 1.- Conocer el estado sanitario del cultivo.
- 2.- El estado y evolución de la plaga.
- 3.- Aplicar las medidas correctivas para eliminarla.

Los métodos convencionales de detección de plagas tienen carencias particulares que notoriamente afectan a tener un control más estricto del problema, tales carencias radican en la imposibilidad de proporcionar la categoría de infestación, densidad y determinación de la etapa en la cual se encuentra (Mou, Zhao, & Zhou, 2009).

La correcta y temprana detección de plagas permitirá al agricultor tomar las acciones adecuadas para mejorar su producción y calidad en el cultivo, así como evitar los daños por el mal uso de pesticidas e incluso seleccionar métodos alternativos orgánicos para el tratamiento de la plaga.

Es entonces que se propone el entrenamiento de una red neuronal artificial para la detección y clasificación de tres tipos de plagas en un cultivo de jitomate bajo invernadero que, mediante el uso de CPU, así como de hardware para la aceleración de Intel® Neural Compute Stick 2 y que, en conjunto con un robot móvil teledirigido, dotado de dos cámaras permita la detección, mediante análisis de patrones en las imágenes de las hojas del cultivo.

Marco Teórico

En México, la agricultura protegida ("horticultura protegida") se encuentra en crecimiento (Juárez-López et al., 2012), el crecimiento exponencial de las tierras cultivadas de esta manera se puede notar según SAGARPA, en un crecimiento de 10,000 hectáreas en 2008 a las 320,000 para 2019, de igual manera la producción de hortalizas para las familias en México es un recurso valioso para la seguridad alimentaria, por lo que los métodos como el cultivo en traspatio tradicionales en zonas como Oaxaca y Puebla toman una gran relevancia (Bonilla-Aparicio, Hernández-Sánchez, Mendieta-Sánchez, & Herrera-Fuentes, 2005).

El abaratamiento de elementos de invernadero como las mallas, los plásticos y otros con los que se ha mejorado la producción de tras patio, han permitido que muchos sistemas familiares se conviertan en invernaderos familiares conllevando con ello la problemática de los mismos en cuanto a la clasificación y detección de plagas.

Estos traspatios son administrados familiarmente y la cosecha obtenida es utilizada para el autoconsumo, dentro de la variedad de vegetales, plantas y frutos que este sistema provee se puede notar que más del sesenta y dos por ciento de los traspatios, siembra o a sembrado jitomate, por su uso en la gastronomía Mexicana (INEGI-SAGARPA, 2015), debido a esto la importancia de analizar los problemas en su producción.

El control de las plagas dentro de esta producción protegida aún no incorpora tecnologías como en otros países, tal es el caso de España donde los movimientos de desarrollo libre han impactado la producción hortícola de tras patio (Gutiérrez Espíritu & Armas Valencia, 2018), donde dichos movimientos han desarrollado la automatización y control de variables bajo invernadero como: el riego, la temperatura, luminosidad, etc., algunos

otros han desarrollado pequeños sistemas para detectar anomalías en los cultivos como el aspecto de las plantas, la falta de riego y enfermedades que afectan a las hojas mediante análisis de imágenes.

Sin embargo, los métodos convencionales de detección de plagas que se ocupan en México, consisten en establecer criterios que en su mayoría basan su acción mediante la observación de un número de plantas cada determinado tiempo, de partes o zonas del cultivo a observar, así como cuantas plantas son afectadas y en que parte de la misma se encuentra el problema observado.

Estos métodos requieren que el agricultor tenga que realizar recorridos e inspecciones visuales, que para el caso de los invernaderos de pequeño tamaño no conllevan un tiempo considerable, sin embargo, los invernaderos que cuentan con extensiones mayores suelen ser los que tienen una problemática más amplia que afrontar, por el tiempo invertido en la revisión, debido a lo anterior estos suelen ser los más interesados en el uso de tecnologías de detección de plagas, sin embargo, esto no significa que la tecnología no pueda ser ocupada en invernaderos familiares.

Metodología

Se realizó la selección de tres plagas del cultivo de jitomate, con esta información se entrenó a una red neuronal artificial para detección y clasificación de la plaga utilizando el algoritmo de detección en imágenes de hojas del cultivo, aplicando la red neuronal artificial de convolución basada en Keras del framework TensorFlow. Se ejecutan pruebas de su entrenamiento con el uso de CPU y un acelerador Intel Neuronal Stick 2, midiendo el tiempo requerido para la obtención de pesos sinápticos óptimos para la detección mínima del ochenta y nueve por ciento de identificación de la plaga, los algoritmos son escritos en lenguaje Python bajo el framework de Intel.

La metodología propuesta para el problema de detección de plagas mediante el entrenamiento de una red neuronal artificial con el modelo Keras para el análisis de imágenes se muestra en la figura 1.



Figura 1. Metodología para el entrenamiento de red neuronal artificial.

Fuente: Elaboración propia

Para llevar a cabo el entrenamiento de la red neuronal artificial Keras, se requiere como mínimo un total de ciento cincuenta imágenes de las tres plagas principales que pueden ser detectadas en las hojas de las plantas del cultivo (Mitidieri & Polack, 2012), mediante imágenes recopiladas en escenarios reales que muestren los estragos en el cultivo o que sean característicos de la plaga, tal es el caso de la araña roja del tomate (Fuentes, Yoon, Kim, & Park, 2017).

Se recopilaron un conjunto de imágenes para desarrollar el entrenamiento de la red neuronal artificial, la cual se basó en los siguientes pasos:

1. Recolección de ciento cincuenta fotografías de alta resolución por cada plaga, que demuestran los problemas generados por las siguientes plagas: mosca blanca, pulgones y araña roja del tomate, estas fotografías tienen que ser tomadas en un ángulo relativo a las cámaras que tendrá el robot móvil, un ángulo superior y un ángulo medio con respecto a el robot móvil teledirigido como se muestra en la figura 2.




Figura 2. Toma de imágenes de hojas de plantas del cultivo.
Fuente: Elaboración propia.

2. Recopilación de ciento cincuenta fotografías de alta resolución de hojas sin problemas en el cultivo, de igual forma se toman los criterios de los ángulos con respecto a la cámara en el robot móvil.
3. Adicionalmente se tomaron ochenta y nueve fotografías de hojas de color amarillo con falta de fotosíntesis y que indican otro tipo de deficiencia en la planta de jitomate, esto se realizó para generar una zona de exclusión que sumadas a las fotografías de hojas sin problemas en la red neuronal artificial eliminarán el solapamiento de problemas que no tienen que ver con las plagas detectadas.

La cantidad de imágenes para detección de plagas y clasificación, se determinó en un estudio previo el cual, realizó la clasificación de los tipos de suelos con una red neuronal artificial (Berra, 2018).

El conjunto de datos utilizados para el entrenamiento de la red neuronal artificial se puede observar en la Figura 3.




Figura 3. Datos utilizados en el entrenamiento de la red neuronal artificial.
Fuente: Elaboración propia.

Teniendo el conjunto de imágenes necesarias se realizó el entrenamiento de la red neuronal artificial basada en Keras, con tres variantes a las que se denominaron "Keras A", "Keras B" y "Keras C", esta API (Application Programming Interface) fue seleccionada debido al enfoque de experimentación rápida, se llevaron a cabo quince intentos de entrenamiento sobre la red neuronal artificial con un total de quinientas ochenta épocas por cada intento, cada variante genera aproximaciones de detección y clasificación de entre cuarenta y cinco y noventa por ciento de confiabilidad.

El algoritmo diseñado para identificación de objetos en el framework de Intel, fue tomado como referencia para realizar la detección de las plagas, realizando modificaciones en la parte de detección por pixeles que se adaptaría mejor a la identificación de insectos, así como en los pesos sinápticos establecidos mediante un algoritmo recursivo de mejora que se ejecutará hasta encontrar el 89% o más de porcentaje de seguridad de clasificación de la plaga.

Tabla 1. Tabulación de entrenamiento de la red neuronal artificial.

Épocas	580						Épocas	580						Épocas	580					
Tipo	Keras "A"						Tipo	Keras "B"						Tipo	Keras "C"					
Intento	CPU Horas	Intel Neuronal Horas	Detección Plaga 1	Detección Plaga 2	Detección Plaga 3	Zona de exclusión	CPU Horas	Intel Neuronal Horas	Detección Plaga 1	Detección Plaga 2	Detección Plaga 3	Zona de exclusión	CPU Horas	Intel Neuronal Horas	Detección Plaga 1	Detección Plaga 2	Detección Plaga 3	Zona de exclusión		
1	192	72	35%	50%	70%	80%	45	26	80%	75%	95%	66%	75	38	40%	70%	80%	35%		
2	189	48	55%	56%	58%	86%	90	29	85%	75%	95%	67%	70	36	42%	70%	85%	45%		
3	140	49	53%	45%	72%	87%	45	35	86%	74%	96%	69%	72	37	45%	75%	86%	40%		
4	150	52	48%	43%	60%	87%	60	36	87%	70%	90%	70%	71	34	42%	78%	89%	40%		
5	170	50	48%	32%	58%	89%	90	28	88%	69%	92%	71%	71	36	40%	86%	90%	33%		
6	180	48	63%	52%	59%	88%	93	28	83%	68%	92%	85%	69	35	50%	82%	92%	35%		
7	190	45	70%	63%	60%	91%	92	27	85%	79%	92%	82%	65	39	60%	81%	93%	36%		
8	140	56	83%	58%	78%	92%	90	26	84%	80%	93%	86%	63	38	70%	70%	92%	39%		
9	110	55	82%	56%	58%	95%	97	28	86%	88%	98%	86%	75	39	71%	85%	91%	38%		
10	150	54	80%	10%	18%	95%	96	35	89%	86%	95%	86%	65	40	73%	86%	90%	39%		
11	110	51	78%	15%	32%	96%	90	37	87%	75%	95%	89%	86	56	60%	59%	93%	40%		
12	100	51	82%	35%	78%	91%	90	25	88%	76%	94%	87%	42	56	65%	86%	92%	30%		
13	132	50	81%	80%	75%	90%	93	24	89%	72%	93%	90%	59	58	85%	74%	91%	30%		
14	115	45	86%	88%	72%	96%	91	26	90%	71%	91%	85%	70	54	45%	59%	90%	28%		
15	189	40	85%	88%	70%	97%	95	20	85%	80%	90%	90%	70	32	71%	74%	92%	27%		

El total de ochomil setecientas épocas se ejecutaron para obtener diversas aproximaciones a la clasificación y detección de plagas, como se puede observar en la Tabla 1, el entrenamiento realizó diversos ajustes obteniendo los valores y porcentajes relativos de confiabilidad de clasificación de los mismos, este entrenamiento de peso se llevó acabo ejecutando los algoritmos para entrenamiento en un CPU sin acelerador y con un acelerador de entrenamiento Neuronal Stick 2 de Intel, para la medición en tiempo de entrenamiento por épocas que servirá de apoyo en trabajos futuros, así como su posible mejora en rendimiento tomando en cuenta el cálculo de los pesos sinápticos obtenidos en el entrenamiento.

El modelo Keras

El modelo Keras utilizado para desarrollar el entrenamiento se muestra en la Figura 4. El modelo planteado tiene como objetivo principal el procesamiento de las capas mediante convoluciones, proporcionando campos receptivos que permiten identificar características específicas del conjunto de imágenes para entrenamiento, que están orientados a la detección y clasificación de las plagas visibles en las hojas y tallos del cultivo de jitomate, destacando que la zona de exclusión permite que la red multicapa realice una mejor clasificación de las plagas visualizadas en las imágenes o el video.

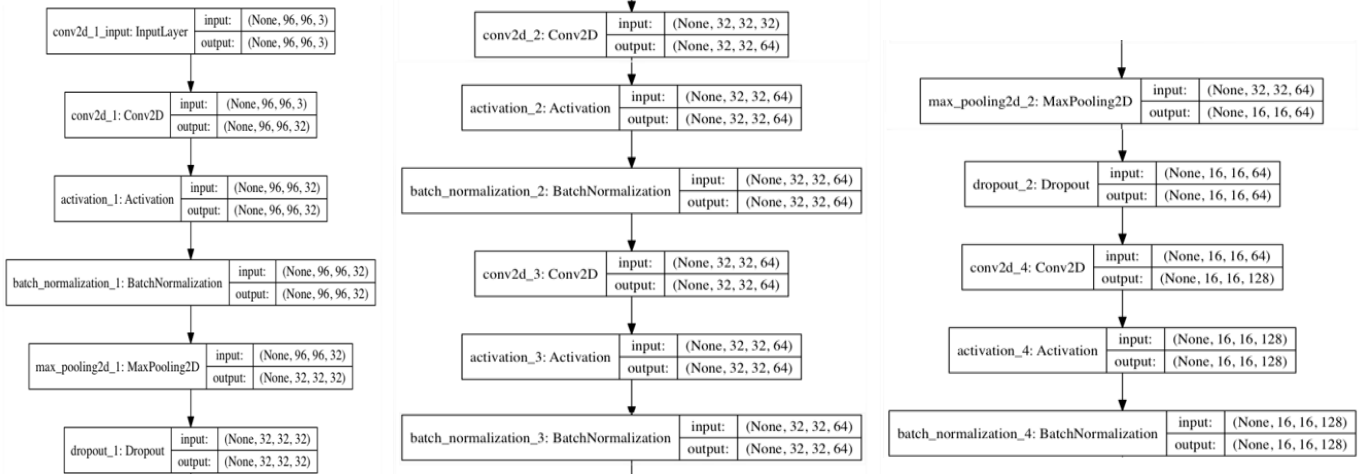


Figura 4. Modelo Keras. Fuente: Elaboración propia.

El modelo se conforma de cinco capas básicamente de entradas, convolución, activación, normalización y la de exclusión 2D, esto se puede visualizar en la Figura 5 donde observamos el proceso de la red neuronal artificial.

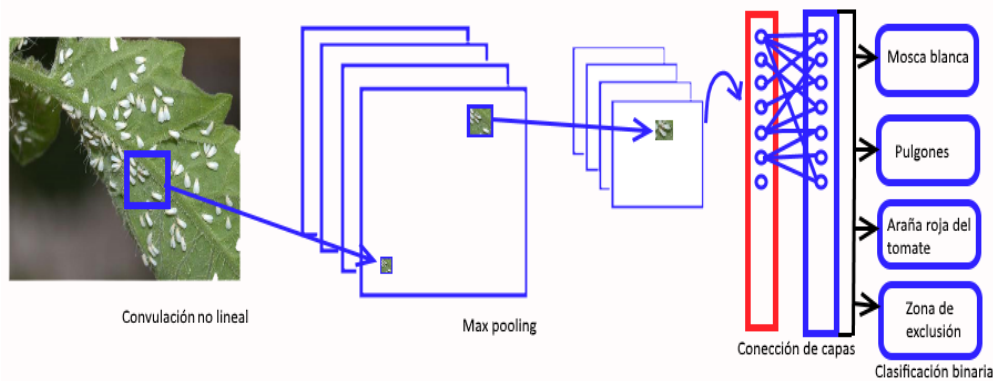


Figura 5. Proceso de clasificación de la red neuronal artificial. Fuente: Elaboración propia.

El entrenamiento para mejorar la clasificación de la red neuronal se llevó a cabo mediante el framework de Intel Open vino, el ajuste de valores sinápticos se lleva a cabo en forma repetida especificando las épocas o repeticiones, así como el porcentaje de confiabilidad de clasificación que se desea obtener, hasta ajustar un valor de detección en el caso particular de la presente investigación igual o mayor al 89 %. Esto se muestra en la figura 6.

[0, 1] element, prob = 0.0198975	(268.75, 105.234)-(460.625, 394.453)	[0, 1] element, prob = 0.0211945	(263.438, 103.359)-(457.188, 405.234)
[1, 2] element, prob = 0.0105972	(265.313, 132.656)-(459.688, 429.375)	[1, 2] element, prob = 0.0119553	(256.25, 117.305)-(492.5, 440.625)
[2, 4] element, prob = 0.0185699	(258.125, 166.641)-(478.125, 394.922)	[2, 4] element, prob = 0.020813	(256.563, 148.359)-(475.938, 384.609)
[3, 5] element, prob = 0.0787964	(265.313, 132.656)-(459.688, 429.375)	[3, 5] element, prob = 0.111145	(261.563, 131.484)-(459.063, 440.391)
[4, 6] element, prob = 0.438721	(260.625, 157.383)-(478.75, 384.375)	[4, 6] element, prob = 0.469727	(256.875, 158.203)-(477.5, 393.047)
[5, 7] element, prob = 0.117554	(258.594, 142.734)-(467.5, 419.297)	[5, 7] element, prob = 0.193237	(254.375, 142.852)-(466.875, 429.375)
[6, 8] element, prob = 0.0517578	(260.625, 138.633)-(477.5, 368.438)	[6, 8] element, prob = 0.0474548	(256.563, 148.359)-(475.938, 384.609)
[7, 9] element, prob = 0.0389404	(265.313, 132.656)-(459.688, 429.375)	[7, 9] element, prob = 0.026535	(261.563, 131.484)-(459.063, 440.391)
[8, 10] element, prob = 0.14624	(260.625, 138.633)-(477.5, 368.438)	[8, 10] element, prob = 0.180664	(255.140, 039)-(473.125, 375.938)
[9, 11] element, prob = 0.110474	(265.313, 132.656)-(459.688, 429.375)	[9, 11] element, prob = 0.117065	(242.188, 162.539)-(480.313, 418.125)
[10, 12] element, prob = 0.188721	(258.594, 142.734)-(467.5, 419.297)	[10, 12] element, prob = 0.179688	(254.375, 142.852)-(466.875, 429.375)
[11, 13] element, prob = 0.204834	(240.781, 136.172)-(481.25, 399.141)	[11, 13] element, prob = 0.140991	(234.688, 135.586)-(479.063, 407.344)
[12, 14] element, prob = 0.382324	(249.688, 142.148)-(475.313, 387.188)	[12, 14] element, prob = 0.373291	(244.063, 140.742)-(474.063, 395.625)
[13, 18] element, prob = 0.011467	(258.125, 166.641)-(478.125, 394.922)		
Only 14 proposals found		Only 13 proposals found	

Figura 6. Ajustes a pesos sinápticos para entrenamiento de la red neuronal artificial. Fuente: Elaboración propia.

El algoritmo de cálculo de pesos se comporta recursivamente en un ciclo de llamadas hasta encontrar el peso adecuado al porcentaje, si se exceden las épocas necesarias para la obtención del peso adecuado se detiene y arroja el ultimo de los resultados obtenidos antes de exceder el ciclo determinado en él, esto se puede observar en la figura 7.

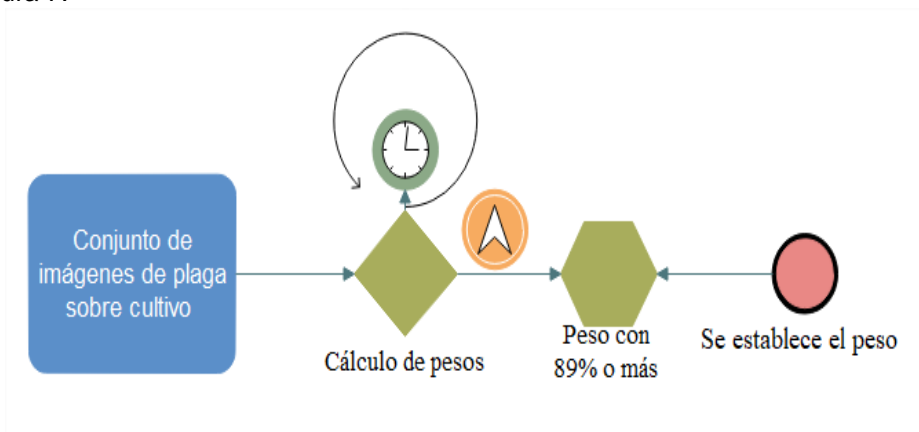


Figura 7. Algoritmo de cálculo de pesos sinápticos.
Fuente: Elaboración propia.

Los cálculos de los pesos fueron almacenados en una base de datos para posteriores usos en redes neuronales artificiales, aplicadas a robots para la detección de plagas de jitomate.

Resultados y discusión

Realizado el entrenamiento de la red neuronal artificial, se procedió a llevar a cabo las pruebas de detección y clasificación en un pequeño invernadero que cuenta con un total de cincuenta plantas de tomate, con recorridos tomando videos con duración de veinte minutos por el robot tele dirigido, los cuales sirvieron como pruebas de las redes neuronales artificiales, tanto para el uso de hardware de aceleración Neuronal Stick 2 de Intel, así como con CPU. La prueba se muestra en la Figura 8 y 9.



Figura 8. Pruebas de detección de zona de exclusión y mosca blanca.
Fuente: Elaboración propia.



Figura 9. Pruebas de detección de zona de exclusión, pulgón y araña.
Fuente: Elaboración propia.

En las pruebas de video la red neuronal artificial cuenta con un nivel de detección correspondiente a los datos mostrados en la tabla 1, contando con niveles de detección del ochenta y cinco por ciento, en el mejor de los casos y en el peor de los casos con cuarenta y cinco por ciento en la prueba de exclusión del último video.

En la tabla 1, se puede observar que las horas de entrenamiento para obtener los pesos adecuados para obtener un nivel de detección del ochenta y nueve por ciento en los casos de la red Keras "A", "B", "C", son mucho más significativos en el rendimiento del CPU, con un total en el peor de los casos de ciento noventa y dos horas y en el mejor de cuarenta y cinco horas, mientras que con Intel Neuronal Stick 2 se obtuvo en el mejor de los casos veinte horas y en el peor setenta y dos horas, estos resultados se utilizarán a futuro para seleccionar el entrenamiento basado en CPU o mediante aceleración con Neuronal Stick 2.

Las redes neuronales artificiales "A", "B" y "C" corresponden a las tres plagas a clasificar, la zona de exclusión se incluye en los parámetros de las tres redes neuronales artificiales, por lo que el peso en tiempo está balanceado con la zona de exclusión, la diferencia entre cada red neuronal artificial radica en dos procesos diferentes entre cada red neuronal artificial, ya que en la red neuronal artificial "A", se tienen programadas dos subclases, mientras que la "B", una sola subclase y en la "C", es generada mediante llamadas recursivas a una función de clasificación.

Cada red neuronal artificial muestra sus ventajas y desventajas al identificar una determinada plaga o la zona de exclusión como se muestra en la tabla 1, por lo que queda a consideración del tipo de plaga a tratar la implementación de cada una de ellas.

Una de las principales limitantes de este modelo es la cantidad de imágenes recabadas para poder generalizarlo a zonas de cultivo bajo invernadero en general, por lo que la base tiene que ser actualizada con las imágenes del sitio donde se tiene que aplicar.

Dadas las condiciones de entrenamiento de la red neuronal artificial Keras, se obtuvieron buenos resultados de detección en dos de las tres plagas, la red neuronal artificial tiene su más bajo rendimiento en la detección de araña roja, debido a que la base de entrenamiento mantiene imágenes con un alto contenido de cultivos afectados por esta plaga, donde es visible la ceda de araña, por lo que al carecer de ella en cualquier otro cultivo no será detectada.

De igual forma se observó, que el hardware de aceleración dota a los programadores y diseñadores de Inteligencia Artificial de una herramienta que puede disminuir considerablemente el proceso de entrenamiento de una red neuronal artificial, tomando en consideración que el algoritmo multicapa probado en la presente investigación cuenta con un grado de complejidad medio/alto adecuado a la detección en video.

El esquema utilizado de cuatro procesos sobre la red Keras, con las pruebas sobre video de veinte minutos, arroja la detección adecuada mediante video de las plagas y la zona de exclusión, haciendo énfasis en que esta zona ayudó a los porcentajes de detección de plagas, eliminando distractores como hojas amarillentas y verdes del cultivo.

Trabajo a futuro

Basado en las conclusiones del entrenamiento de redes neuronales artificiales Keras, se tiene el objetivo de entrenar una red neuronal artificial genérica que pueda clasificar por lo menos diez enfermedades de diversas plantas cultivables en invernaderos, esto permitirá generalizar la clasificación de plagas en los cultivos que se utilizan en el autoconsumo.

De igual manera se desarrollará el algoritmo de control automático del robot, el cual actualmente se controla mediante tele operación y que pretende interactuar con el tratamiento correctivo de plagas, tomando en cuenta los datos arrojados por la red neuronal artificial Keras, generando un robot móvil autónomo para el tratamiento de las plagas de cultivos bajo invernadero.

Conclusiones

La Inteligencia artificial es una herramienta que ha demostrado su eficiencia en la automatización de procesos, el uso de esta permite la optimización de actividades de clasificación y detección como lo demuestra este estudio.

Con el desarrollo y entrenamiento de las redes neuronales artificiales "A", "B" y "C" basadas en Keras, fue posible realizar la detección de tres plagas en cultivos de jitomate obteniendo un porcentaje de detección y clasificación adecuados en pruebas de video.

Por otra parte, se realizó la comparación de entrenamiento de las redes neuronales artificiales, donde el menor tiempo de procesamiento se obtiene utilizando el acelerador de entrenamiento Neuronal Stick 2 de Intel, con la red neuronal artificial Keras "B", con veinte horas en la prueba quince con buenos porcentajes de detección para las plagas y la zona de exclusión como se muestra en la tabla 1.

Este entrenamiento permitirá el desarrollo en trabajos futuros de un robot autónomo, que pueda tomar decisiones en cuanto al tratamiento de plagas de acuerdo al nivel de infestación en el cultivo, así como la generación de software de análisis para la toma de decisiones sobre la producción.

Anexos

El seudocódigo utilizado para la red neuronal artificial Keras es el siguiente:

```
Nombre de archivo de imagen → nombreimagen + 1
correcto → imagen encontrada! = -1
incorrecto → "incorrecto"
mostrar → porcentaje de detección , correcto
salida → imagen a 1080 pixeles
Cpu análisis → salida en, etiqueta, (10, 25), Correr FONT_HERSHEY_SIMPLEX,
0.7, (0, 255, 0), 2)
Imprimir → información en etiqueta
Mostrar → ("Salida", porcentaje)
Finalizar proceso
```

De igual manera se utilizó un esquema de cuatro procesos para generar una sola red neuronal artificial en Python mediante los siguientes cuatro procesos por lotes en ejecución:

```
1.- $ python classify.py --model pokedex.model --labelbin lb.pickle --image database/moscablanca.MPG4
Using TensorFlow backend.
[INFO] loading network...
[INFO] classifying image...
[INFO] moscablanca: 95.77% (correct)
```

```
2.- $ python classify.py --model pokedex.model --labelbin lb.pickle --image database/pulgones.MPG4
Using TensorFlow backend.
[INFO] loading network...
[INFO] classifying image...
[INFO] pulgones: 85.36% (correct)
```

```
3.- $ python classify.py --model pokedex.model --labelbin lb.pickle --image database/rañaroja.MPG4
Using TensorFlow backend.
[INFO] loading network...
[INFO] classifying image...
[INFO] arañaroja: 90.00% (correct)
```

```
4.- $ python classify.py --model pokedex.model --labelbin lb.pickle --image database/Zonaexc.MPG4
Using TensorFlow backend.
[INFO] loading network...
[INFO] classifying image...
[INFO] Zonaexc: 91.00% (correct)
```

Estos cuatro procesos son necesarios para mostrar al usuario la detección sobre el video tomado por la cámara de reconocimiento de plagas del robot.

Referencias

- 1) Arivazhagan, S., Newlin Shebiah, R., Ananthi, S., & Vishnu Varthini, S. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International: CIGR Journal*, 15(1), 211–217. Retrieved from <http://cigrjournal.org/index.php/Ejournal/article/view/2338/1720>
- 2) Berra, E. (2018). Redes neuronales para la toma de decisiones en el sector agrícola análisis exploratorio. *Reacción*, 4(February), 31–45. Retrieved from http://reacion.utleon.edu.mx/Art_Rednes_neuronales_para_la_toma_de_decisiones_en_el_sector_agricola_analisis_exploratorio.html
- 3) Bonilla-Aparicio, M. E., Hernández-Sánchez, F., Mendieta-Sánchez, E., & Herrera-Fuentes, C. (2005). HORTICOLA DIVERSITY FOR FOOD SECURITY MARGINALIZED MUNICIPALITIES IN STATE OF PUEBLA. *Ra Ximhai*, 8(3), 81–110.
- 4) Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors (Switzerland)*, 17(9). <https://doi.org/10.3390/s17092022>
- 5) Gutiérrez Espíritu, J., & Armas Valencia, J. (2018). Diseño de un controlador basado en redes neuronales para la irrigación por goteo sobre cultivos en el distrito de Huacho. *Universidad Tecnológica Del Perú*. Retrieved from <http://repositorio.utp.edu.pe/handle/UTP/1622>
- 6) INEGI-SAGARPA. (2015). Información Relevante.
- 7) Juárez-López, P., Bugarín-Montoya, R., Sánchez-Monteón, A., Balois-Morales, R., Juárez-Rosete, C., & Cruz-Crespo, E. (2012). PERSPECTIVAS PROTECTED HORTICULTURESITUACIÓN ACTUAL Y IN NAYARIT , MEXICO :, 1, 16–24.
- 8) Mitidieri, M. S., & Polack, L. A. (2012). Guía de monitoreo y reconocimiento de plagas, enfermedades y enemigos naturales de tomate y pimiento. *Boletín de Divulgacion Tecnica N° 22 - INTA*.
- 9) Mou, Y., Zhao, Q., & Zhou, L. (2009). Application of simulated annealing algorithm in pest image segmentation. *ISCID 2009 - 2009 International Symposium on Computational Intelligence and Design*, 1(5), 19–22. <https://doi.org/10.1109/ISCID.2009.12>
- 10) OCDE/FAO. (2017). *Perspectivas Agrícolas OCDE-FAO*. <https://doi.org/10.1007/BF02915673>
- 11) Vega, H., Cortez, A., Huayna, A., Loayza, L., & Naupari, P. (2009). Reconocimiento de patrones mediante redes neuronales artificiales. *Revista de Ingeniería de Sistemas e Informática*, 6(2), 17–26. Retrieved from http://sisbib.unmsm.edu.pe/Bibvirtual/publicaciones/risi/2009_n2/v6n2/a03v6n2.pdf