

Redes Neuronales Basadas en Detección de Objetos para el Manejo Inteligente de Malas Hierbas en el Cultivo de Tomate

Juan Manuel LÓPEZ-CORREA¹, Ángel TOLEDO¹, Orly Enrique Apolo-Apolo², Dionisio ANDUJAR¹

¹ Centro de Automática y Robótica, CSIC-UPM, Arganda del Rey, 28500 Madrid, España

² Departamento de Ingeniería Aeroespacial y Mecánica de Fluidos 'Área Agroforestal', Escuela Técnica Superior de Ingeniería Agronómica (ETSIA), Universidad de Sevilla, Ctr. Utrera Km 1,41013 Sevilla, España

Resumen

El tomate (*Solanum lycopersicum L.*) es uno de los cultivos más importantes, no solo en España sino también a nivel mundial. Sin embargo, las malas hierbas más problemáticas para este cultivo ponen en riesgo su potencial productivo. Es por ello que se vuelve crucial identificar estas especies a nivel localizado para realizar un control especial y selectivo sobre ellas. La agricultura de precisión, de la mano de la visión por computador, es una herramienta poderosa para resolver el problema. Las cámaras digitales y las redes neuronales se han desarrollado rápidamente en los últimos años, proporcionando nuevos métodos y herramientas para la agricultura y el manejo de malas hierbas. El presente estudio tiene como objetivo detectar y clasificar de forma automática a las especies de malas hierbas más agresivas en el cultivo de tomate en España. El procedimiento está basado en *Redes Neuronales para la Detección de Objetos*. Como *input* de entrada a la red se han utilizado imágenes RGB tomadas en un cultivo comercial de tomate donde se han fotografiado malas hierbas monocotiledóneas (*Cyperus rotundus L.*, *Echinochloa crus galli L.*, *Setaria itálica L.*) y dicotiledóneas (*Portulaca oleracea L.*, *Solanum nigrum L.*). Una vez entrenado el modelo, se validó sobre un conjunto de imágenes no utilizadas en el entrenamiento, utilizando la métrica mean Average Precision (mAP) para evaluar el desempeño de un modelo. Los resultados obtenidos fueron entre 90% - 97% dependiendo de la especie. Este trabajo de investigación promete una importante contribución al manejo selectivo de malas hierbas en el cultivo de tomate.

Palabras clave: Redes Neuronales, Detección de Objetos, Manejo Selectivo.

1. Introducción

El tomate (*Solanum lycopersicum L.*) es uno de los cultivos más importantes a nivel mundial. La producción mundial de tomates es de alrededor de 170,8 millones de toneladas. China es el mayor productor de tomates y representa el 31% de la producción total a nivel mundial. Le siguen muy de cerca, con el segundo y tercer puesto en cuanto a producción, India y Estados Unidos. La producción española es de alrededor más de 4 millones de toneladas, ocupando el puesto 11 entre los países con mayor producción de tomate (FAO, 2017). Sin embargo, las malas hierbas más problemáticas para este cultivo ponen en riesgo su producción, compitiendo por agua, luz, nutrientes, espacio físico, etc. (Qasem *et al.*, 2019). El manejo de malas hierbas juega uno de los roles más importantes en el cultivo de tomate. La densidad y composición de las malas hierbas, en la práctica, no son uniformes en todo el campo, con variación espacial y temporal (Fernández-Quintanilla *et al.*, 2018). A día de hoy la estrategia de manejo más utilizada para luchar contra las malas hierbas es la aplicación de herbicidas, la cual se realiza de manera uniforme en toda la superficie cultivada (Pérez-Ortiz *et al.*, 2016). Sin embargo, a través del *manejo localizado de malas hierbas* (SSWM), se puede lograr un tratamiento de malas hierbas más preciso con beneficios económicos, ambientales y llevar a una mejor calidad alimentaria (Tanget *et al.*, 2017). El SSWM se logra aplicando un tratamiento solo en los rodales de malas hierbas (e.g., utilizando, boquillas que abren y cierran en función de una orden). Este procedimiento se puede ver

complementado utilizando la materia activa específica o más efectiva para cada mala hierba. La integración de un sistema de detección de malas hierbas de clases múltiples tiene como ventaja la generación de aplicaciones más eficaces para el control de especies problemáticas a través de la elección automática del herbicida y dosis a aplicar. Además, hay que sumar como beneficios: un uso reducido de herbicidas, productos agrícolas más seguros para el consumidor y el medio ambiente, y una agricultura más sostenible.

El uso de las redes neuronales se presenta como un método innovador y prometedor en muchos campos de la agricultura, pero especialmente para la detección y clasificación de múltiples especies de malas hierbas. Dyrmann et al.(2016) recopiló seis conjuntos de datos de diferentes trabajos de investigación y entrenó una red neuronal convolucional (CNN) para clasificar un conjunto de 22 especies de malas hierbas. En este trabajo, se logró una precisión de clasificación de entre 82,4% y 88,2%, lo que muestra el potencial de clasificación de malas hierbas de CNN dejando de lado el problema de detección de malas hierbas en campo. Otro estudio en la misma línea es el desarrollado por Dyrmann et al. (2017), donde un total de 17 especies de malas hierbas en un campo de maíz fueron detectadas y clasificadas. Se utilizaron técnicas de segmentación para la detección de las especies vegetales con valores de IoU (*Intersection over Union*) entre 0,69 y 0,93 para malas hierbas y plantas de maíz. Tras la detección de las malas hierbas, se utilizó una red neuronal convolucional, que clasificaba las malas hierbas con una precisión global del 87%. Sin embargo, se necesitaron dos procesos diferentes para tener una clasificación del conjunto total de las malas hierbas lo cual no es óptimo. Recientemente, se han desarrollado modelos que permiten una mejor detección y clasificación de objetos. Uno de esos modelos es el desarrollado por Lin et al.. (2017) llamado *RetinaNet*. Esta red es un detector de objetos de una etapa que puede manejar la ubicación y clasificación de objetos a la vez, lo que reduce el tiempo de predicción y aumenta la precisión de detección. El desarrollo de esta red ha permitido realizar trabajos en el ámbito agrícola como el llevado a cabo por Zheng *et al.* (2018) donde se realizaron detecciones en tiempo real de diferentes tipos de hortalizas. La utilización de *RetinaNet* para la detección de malas hierbas es escasa según la bibliografía consultada. Wei *et al.*(2020) desarrollaron un robot “Robot de Identificación Rápida Basado en ROS” para detectar malas hierbas en el cultivo de maíz obteniendo un 0,94 AP en la detección de malas hierbas, sin clasificación por especie y 0,93 detectando plantas de maíz.

En todos los casos, los autores han demostrado el uso potencial de arquitecturas de detección de objetos en la disciplina agrícola. Sin embargo, no pudieron detectar y discriminar entre varias especies de malas hierbas en un solo paso, como lo podría hacer *RetinaNet*. El uso de Redes de Detección de Objetos puede ser muy útil para pulverizaciones inteligentes durante las aplicaciones de herbicidas. Dado que , estas redes pueden integrarse en sistemas de tratamiento en tiempo real capaces de decidir qué tipo de tratamiento se desea aplicar. Algunos prototipos comerciales, como el caso Blueriver, combinan sistemas de detección en tiempo real con un aplicador comercial planta por planta. Todos estos sistemas están evolucionando rápidamente y pueden ser una respuesta a la demanda de un uso reducido de herbicidas y mayores rendimientos. El presente estudio propone un sistema de detección de las especies de malas hierbas monocotiledóneas (*Cyperus rotundus L.*, *Echinochloa crus galli L.*, *Setaria itálica L.*) y dicotiledóneas (*Portulaca oleracea L.*, *Solanum nigrum L.*) en parcelas comerciales de tomate (*Solanum lycopersicum L.*) utilizando *RetinaNet*.

2. Materiales y métodos

2.1. Adquisición de imágenes

El estudio tuvo lugar en parcelas de tomate (*Solanum lycopersicum L.*) comerciales localizadas en la Provincia de Badajoz (España). Se verificó que en los lotes de las parcelas seleccionadas no se haya realizado ninguna aplicación de herbicida en los 15 días anteriores. Se tomaron un total de 1713 imágenes de manera cenital a una altura de 1 m en condiciones reales de iluminación siguiendo una trayectoria “M” cada 2 m de distancia. Se encontraron cuatro especies de malas hierbas (*Cyperus rotundus L.*, *Echinochloa crus galli L.*, *Setaria itálica L.*, *Portulaca oleracea L.*). El modelo de cámara utilizado fue una Canon PowerShot SX540 HS con una resolución de 5184 px X 3886 px. Se utilizó una velocidad de obturación de 1/1000, mientras que el ISO se calibró automáticamente para lograr una buena calidad de imagen.

2.2. Pre-procesamiento de imágenes

El etiquetado de las imágenes se realizó utilizando un software dedicado llamado LabelImg (Tzutalin, 2015), que guarda las etiquetas utilizando el formato PascalVOC (Everingham et al., 2010). Este formato guarda las coordenadas de un cuadro delimitador que rodea al objeto que representa. Todos los cuadros delimitadores definidos para una imagen se guardaron en un solo archivo XML, y para cada objeto se guardaron las coordenadas de la esquina superior izquierda e inferior derecha (xmin, ymin, xmax, ymax), así como el nombre de la clase del objeto etiquetado. Se categorizaron cuatro especies de malas hierbas con la ayuda de expertos y se etiquetaron usando el código EPPO (*European and Mediterranean Plant Protection Organization*): “SOLNI” para plantas identificadas como la especie *Solanum nigrum L.*, “CYPRO” para *Cyperus rotundus L.*, “ECHCG” para *Echinochloa crus galli L.*; “SETIT” para *Setaria itálica L.*, POROL para *Portulaca oleracea L.* y para el cultivo *Zea mays L.* “LYPES”. Además, se consideró una clase más para aquellas especies de malas hierbas en estado de emergencia que no podían ser reconocidas por los expertos por pequeña resolución que presentaban en la imagen, a esta clase se le colocó la etiqueta “NCI”.

Para evaluar el potencial predictivo de un modelo, es necesario realizar una evaluación con datos que no se han utilizado para el entrenamiento, es decir, 'nuevos datos para el modelo'. El conjunto de datos se dividió de la siguiente manera: el 70% de las imágenes se tomaron al azar para formar el *conjunto de entrenamiento*, y el 30% restante para el *conjunto de validación*. Además, se tomó una muestra aleatoria del 20% de las imágenes del conjunto de entrenamiento, conforme al *conjunto de prueba*. El último conjunto se tomó para evaluar el progreso del entrenamiento. Después del procesamiento de división de cada uno de los tres grupos de imágenes (conjunto de entrenamiento, conjunto de prueba y conjunto de validación), se obtuvieron 1.199 imágenes de entrenamiento, 513 imágenes de validación y 239 imágenes de prueba. Las etiquetas fueron examinadas visualmente por expertos que corrigieron los errores de etiquetado. El conjunto de datos final consta de 1.713 imágenes con 8.521 cuadros delimitadores con la distribución por clase mostrada en la Tabla 1.

Tabla 1: Especies de malas hierbas identificadas en el estudio etiquetadas con el código EPPO. Número de cuadros delimitadores etiquetados para el *conjunto entrenamiento, de prueba y de validación*.

Especies	Etiqueta	Grupo de entrenamiento	Grupo de prueba	Grupo de validación
<i>Solanum nigrum L.</i>	SOLNI	1.917	383	821
<i>Cyperus rotundus L.</i>	CYPRO	1.691	338	725
<i>Echinochloa crus galli L.</i>	ECHCG	895	179	384
<i>Setaria itálica L.</i>	SETIT	157	31	67
<i>Portulaca oleracea L.</i>	POROL	506	101	217
<i>Solanum lycopersicum L.</i>	LYPES	799	160	342
<i>No reconocidas por tamaño</i>	NCI	372	74	159

2.3. Red Neuronal RetinaNet

RetinaNet es una herramienta de alta capacidad para la detección de objetos, por su arquitectura es capaz de detectar y clasificar objetos en un solo paso. Esta capacidad le brinda altos valores de precisión y velocidad de predicción, aspecto muy interesante para aplicaciones que a tiempo real. *RetinaNet* fue seleccionada entre las redes de detección de objetos disponibles en la literatura ya que ha mostrado un buen desempeño logrando una precisión similar a las redes de dos pasos pero con la velocidad de las redes de un solo paso.

2.3.1. Entrenamiento

Las plantas de malas hierbas y cultivos se clasificaron en 6 clases diferentes: SOLNI, CYPRO, ECHCG, SETIT, POROL, LYPES, NCI. El entrenamiento se realizó utilizando la implementación propuesta por Gaiser *et. al.*, (2019). El modelo de aprendizaje profundo utilizado en este estudio se implementa con Keras 2.4.3 en python 3.6.8 con el backend de TensorFlow (2.3.0). En la mayoría de las aplicaciones de aprendizaje

profundo, es común utilizar un modelo de visión por computadora desarrollado previamente y entrenado en un conjunto de datos relevante llamado *transfer learning* (Pan *et al.*, 2010). Recopilar un conjunto de datos lo suficientemente grande para desarrollar un método de aprendizaje profundo personalizado sería difícil, consumiría mucho tiempo y sería casi imposible (Pan & Yang., 2010). El modelo Resnet50 (He *et al.*, 2016) se utilizó como arquitectura principal de la red, el modelo pre-entrenado COCO (Lin *et al.*, 2014), y se utilizó una tasa de aprendizaje inicial de $1e-5$. Para los subconjuntos de entrenamiento y validación, también se llevó a cabo “data augmentation” (Shorten *et al.*, 2019) para evitar el sobreajuste y superar la naturaleza altamente variable de la clasificación de destino. Para ello se utilizó la librería de Keras (Keras, 2015) con los parámetros como rotación, escala, iluminación, perspectiva y color. Específicamente, se realizaron aleatoriamente una rotación de hasta 10° , un cambio de brillo de $\pm 20\%$, un cambio de canal de $\pm 30\%$, un zoom de $\pm 20\%$, junto con giros horizontales y verticales. RetinaNet se entrenó hasta que el mAP del conjunto de entrenamiento de cada clase no mejoró durante 16 épocas consecutivas. Los parámetros utilizados para la implementación de RetinaNet (Gaiser *et al.*, 2019) fueron los siguientes: $1e-5$ para la tasa de aprendizaje; el conjunto de datos COCO como modelo pre entrenado, el modelo de backbone utilizado fue ResNet-50 (He *et al.*, 2016)), el número de épocas para entrenar fue 100 y el número de pasos por época fue 600, las capas del backbone se congelaron durante el entrenamiento, las imágenes no se redimensionaron, la opción de aumento de imagen se llevó a cabo como se indicó anteriormente, y el tamaño del lote fue 8. El resto de parámetros disponibles en la implementación se dejaron por defecto.

2.3.2. Evaluación de la condición física

Se guardó un modelo entrenado al final de cada época. Por lo tanto, el número de modelos generados es igual al número de épocas durante el proceso de entrenamiento en el que cada modelo entrenado puede producir un grado diferente de precisión de detección. En este estudio, se generaron 100 modelos después del entrenamiento. Se analizó cada modelo para determinar cuál proporciona el mejor resultado. En la validación se utilizó dicho conjunto de imágenes con un total de 513 imágenes con 2716 plantas etiquetadas (ver Tabla 1) que no se usaron en el entrenamiento para seleccionar el modelo de red con mejor desempeño en este estudio.

3. Resultados y discusiones

Este estudio consideró seis especies diferentes de plantas para identificar, cinco de malas hierbas: monocotiledóneas (*Cyperus rotundus L.*, *Echinochloa crus galli L.*, *Setaria itálica L.*), dicotiledóneas (*Portulaca oleracea L.*, *Solanum nigrum L.*) y el cultivo en cuestión (*Solanum lycopersicum L.*) El rendimiento del modelo de RetinaNet se evaluó mediante la métrica más aceptada por la comunidad científica para algoritmos de detección de objetos “mean Average Precision (mAP)”, calculada como la precisión promedio (AP) en cada clase (Padilla *et al.*, 2020). El modelo fue entrenado durante 100 épocas obteniendo un valor máximo de predicción (maP: 0,92755) sobre el *conjunto de validación*. Los valores AP por clase se muestran en la Tabla 2, donde el valor AP más bajo ocurre para la clase NCI clase (AP: 0,823) y la más alta para la clase LYPES (AP: 0,9842).

Tabla 2: Distribución de valores de AP por clase y valor medio entre todas las clases obtenido de las predicciones con el grupo de validación.

Clases	Etiqueta	AP
<i>Solanum nigrum L.</i>	SOLNI	0,9209
<i>Cyperus rotundus L.</i>	CYPRO	0,9322
<i>Echinochloa crus galli L.</i>	ECHCG	0,9502
<i>Setaria itálica L.</i>	SETIT	0,9044
<i>Portulaca oleracea L.</i>	POROL	0,9776
<i>Solanum lycopersicum L.</i>	LYPES	0,9842
<i>No reconocidas por tamaño</i>	NCI	0,8234
mAP		0,92755

El número de especie con las que se ha trabajado no es alto, sin embargo, los dos grupos importantes de malas hierbas estuvieron representados, malas hierbas de hoja ancha como *Solanum nigrum L.* y *Portulaca oleracea L.* y malas hierbas de hojas estrechas como *Cyperus rotundus L.* y *Echinochloa crus-galli L.*, *Setaria itálica L.* La clasificación entre estos grupos es importante para seleccionar el tipo de herbicida ya que muchos de estos están formulados para controlar el grupo de malas hierbas de hoja ancha, “*herbicidas de malas hierbas de hoja ancha*”, y otros para controlar las malas hierbas de hoja estrecha “*herbicidas de hoja estrecha*”. Además, las especies seleccionadas son las que presentan mayor frecuencia y mayor capacidad de invasión en los cultivos de tomate en España.

Esta capacidad de detectar malas hierbas pequeñas y etapas bajas de desarrollo como las clases NCI permite un control temprano de malas hierbas, por lo tanto, disminuir herbicida en el control químico o menor alteración de suelo en el control mecánico. Además, tres especies (*Echinochloa crus-galli L.*, *Cyperus rotundus L.*, *Setaria itálica L.*) del mismo gran grupo de malas hierbas representan similitudes morfológicas para los algoritmos de clasificación. Incluso se logró discriminar entre dos especies (*Echinochloa crus-galli L.*, *Setaria itálica L.*) pertenecientes a la misma familia (“*Poaceas*”) La discriminación entre estas dos especies es relevante ya que se han reportado casos de resistencia genética a herbicidas para biotipos de *Echinochloa crus-galli L.* (Gavilan A., 2011).

Conclusiones

El presente trabajo muestra que es posible la detección automática de las principales malas hierbas que afectan la producción de cultivos de tomate en España en condiciones reales de campo. Los valores obtenidos de precisión son lo suficientemente altos para realizar controles selectivos eficaces. Además se logró clasificar entre dos grupos importantes de malas hierbas, como las de hoja ancha (*Solanum nigrum L.* y *Portulaca oleracea L.*) y las de hoja estrecha (*Cyperus rotundus L.*, *Echinochloa crus-galli L.* y *Setaria itálica L.*) con condiciones variables de iluminación. Además, los resultados obtenidos de discriminación entre especies dentro de una misma familia brindan un gran potencial para la identificación de especies con resistencias a herbicidas. Este método de detección de especies de malas hierbas basado en Redes *Neuronales de Detección de Objetos* presenta resultados prometedores no sólo para controles selectivos de mala hierbas vs cultivo, sino también para controles selectivos por especie de mala hierbas.

Agradecimientos

Esta investigación se desarrolló en el “Centro de Automática y Robótica” perteneciente al Consejo Superior de Investigaciones Científicas”. Esta publicación es parte del proyecto de I+D+i /PID2020-113229RBC43/AEI/10.13039/501100011033

Referencias

- DYRMANN, M., KARSTOFT, H., & MIDTIBY, H. S. (2016). Plant species classification using deep convolutional neural networks. *Biosystems Engineering*, 151, 72-80.
- DYRMANN, M. (2017). Automatic detection and classification of weed seedlings under natural light conditions (Doctoral dissertation, University of Southern Denmark).
- EPPO *European and Mediterranean Plant Protection Organization* code system, <http://eppt.eppo.org/>, last accessed 1 December 2020; EPPO Plant Protection Thesaurus.
- EVERINGHAM, M., VAN GOOL, L., WILLIAMS, C. K., WINN, J., & ZISSERMAN, A. 2010. The pascal visual object classes (voc) challenge. *International Journal of Computer Vision*, 88(2), 303-338.
- FERNÁNDEZ-QUINTANILLA, C.; PEÑA, J.M.; ANDÚJAR, D.; DORADO, J.; RIBEIRO, A.; LÓPEZ-GRANADOS, F. 2018. Is the current state of the art of weed monitoring suitable for site-specific weed management in arable crops?. *Weed Research*, 58, 259–272.
- GAISER, H., DE VRIES, M., LACATUSU, V., & WILLIAMSON, A. 2019. fizyr/keras-retinanet 0.5. 1. Zenodo.
- FOOD AND AGRICULTURAL ORGANIZATION (FAO) (2017). *FAO Production year book*, Rome, Italy; 2017
- HE, K., ZHANG, X., REN, S., & SUN, J. 2016. Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and pattern recognition* (pp. 770-778). Keras <https://keras.io/>. 2015.
- LIN, T. Y., MAIRE, M., BELONGIE, S., HAYS, J., PERONA, P., RAMANAN, D. ET., 2014.

Microsoft coco: Common objects in context. In European conference on computer vision (pp. 740-755). Springer, Cham.

LIN, T. Y., GOYAL, P., GIRSHICK, R., HE, K., & DOLLÁR, P. 2017. Focal loss for dense object detection. In Proceedings of the IEEE international conference on computer vision (pp. 2980-2988).

PADILLA, R., NETTO, S. L., & DA SILVA, E. A. 2020. A survey on performance metrics for object-detection algorithms. In 2020 International Conference on Systems, Signals and Image Processing (IWSSIP) (pp. 237-242). IEEE.

PAN, S.J.; YANG, Q. A SURVEY ON TRANSFER LEARNING 2010. IEEE Transactions on Knowledge and Data Engineering. 22, 1345–1359. doi:10.1109/tkde.2009.191.

PÉREZ-ORTIZ, M.; PEÑA, J.M.; GUTIÉRREZ, P.A.; TORRES-SÁNCHEZ, J.; HERVÁS-MARTÍNEZ, C.; LÓPEZ-GRANADOS, F. 2016. Selecting patterns and features for between- and within- crop-row weed mapping using UAV-imagery. *Expert Systems with Applications*, 47, 85–94.

SHORTEN, C., & KHOSHGOFTAAR, T. M. 2019. A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60.

TANG, J. L., CHEN, X. Q., MIAO, R. H., & WANG, D. 2016. Weed detection using image processing under different illumination for site-specific areas spraying. *Computers and Electronics in Agriculture*, 122, 103-111.

TZUTALIN, D. 2015. LabelImg. Git code.

WEI, Q., PENG, J., ZHANG, H., MO, H., & QIN, Y. 2020, October. Design and Implementation of ROS-Based Rapid Identification Robot System. In *International Conference on Computer Engineering and Networks* (pp. 376-387). Springer, Singapore.

ZHENG, Y. Y., KONG, J. L., JIN, X. B., SU, T. L., NIE, M. J., & BAI, Y. T. 2018. Real-Time Vegetables Recognition System based on Deep Learning Network for Agricultural Robots. In *2018 Chinese Automation Congress (CAC)* (pp. 2223-2228). IEEE.

Intelligence Weed Management based on Object Detection Neural Network in Tomato Crops

Juan Manuel LOPEZ CORREA, Angel TOLEDO¹, Orly Enrique APOLO-APOLO, Dionisio ANDUJAR¹

¹ Center for Automation and Robotics, CSIC- UPM, Arganda del Rey, 28500 Madrid, Spain

² Department of Aerospace Engineering and Fluid Mechanics 'Agroforestry Area', Higher Technical School of Agronomic Engineering (ETSIA), University of Seville, Ctr. Utrera Km 1, 41013 Seville, Spain

Abstract

Tomato (*Solanum lycopersicum L.*) is one of the most important crops, not only in Spain but also worldwide. However, the most problematic weeds for this crop compromise its productive potential. Thus, the identification of problematic weed species is of high importance to carry out a selective weed control. Precision agriculture, associated to computer vision, is a powerful tool to solve the problem. Digital cameras and neural networks have been improved in recent years, providing new methods and tools for Precision Agriculture and weed management. The present study aims to automatically detect and classify the most aggressive weed species for tomato crop production in Spain. The procedure is based on *Neural Networks for Object Detection*. As *input* to the network, RGB images taken in a commercial tomato crop have been used. Monocotyledonous weeds (*Cyperus rotundus L.*, *Echinochloa crus galli L.*, *Setaria itálica L.*) and dicotyledons (*Portulaca oleracea L.*, *Solanum nigrum L.*) have been photographed. Once the model was trained, it was tested on a set of images not used in the training, using the metric mean Average Precision (mAP) to evaluate the performance of the model. The results showed an accuracy between 90% - 97% depending on the weed specie. This research work promises an important contribution to selective weed control in tomato crops.

Keywords: Neural Networks, Object Detection, Selective Management, DACWEED.