

Tratamiento Inteligente de Malas Hierbas a través de ISOBUS basado en reconocimiento automático en el cultivo de Tomate.

Juan LÓPEZ-CORREA¹, Ángel TOLEDO¹, Dionisio ANDUJAR¹

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

Introducción

DACWEED (Detection and Actuation system for WEED management) es un Proyecto Europeo de EIT-Food basado en visión artificial y aperos inteligentes. El sistema es controlado por las normas de comunicación en maquinarias agrícolas ISOBUS (ISO11783) para lograr aplicaciones selectiva de herbicidas. DACWEED tiene tres pilares básicos:

- (1) un sistema de detección de malas hierbas
- (2) un sistema de apoyo a la toma de decisiones
- (3) un implemento ISOBUS para la aplicación del tratamiento

Una de las líneas de investigación de DACWEED tiene como objetivo detectar y clasificar de forma automática las especies de malas hierbas más problemáticas en el cultivo de tomate en España.



Figura 1 – Prototipo de actuación DACWEED.

Materiales y métodos

- Parcelas de tomate (*Solanum lycopersicum L.*) comerciales localizadas en la Provincia de Badajoz (España).
- Toma de imágenes de rodales de cinco de las especies más problemáticas de malas hierbas (*Cyperus rotundus L.*, *Echinochloa crus galli L.*, *Setaria itálica L.*, *Portulaca oleracea L.*, *Solanum nigrum L.*).
- Etiquetado de imágenes según la especie de malas hierba. Software Labelling (Tzotalin, 2015).
- Entrenamiento de red neuronal basada en detección de objetos *Retina Net* (Lin et al., 2017)
- Cuantificación del error predicción por la métrica “*mean Average Precision (mAP)*” (Padilla et al., 2020).

Resultados y discusión

- Tras 100 épocas entrenamiento se obtuvo un valor medio de predicción (mAP: 0,92755) sobre el conjunto de validación. Los valores *Avarege Presition (AP)* por especie se muestran en la Tabla 1
- Dos de los grandes grupos de malas hierbas estuvieron representados: malas hierbas de hoja ancha y malas hierbas de hoja estrecha.
- Discriminación entre especies que son controladas con diferentes tipos de herbicida
- Identificación de especies con mayor frecuencia y capacidad de invasión en los cultivos de tomate en España.
- Discriminación entre especies dentro de una misma familia.

Tabla 1- Distribución de valores de AP por clase y valor medio (mAP) con el grupo de validación.

Clases	Label	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
Not recognised by size	NCI	0,8234
mAP		0,92755



Figura 2 – Aplicador selectivo DACWEED controlado por ISOBUS

Conclusiones

- La detección automática de las principales especies malas hierbas que afectan la producción de tomate en España es viable en condiciones de campo.
- Los resultados obtenidos de discriminación entre especies dentro de una misma familia muestran un gran potencial para la identificación de especies con resistencias a herbicidas.
- Este método de *Redes Neuronales de Detección de Objetos* presenta resultados prometedores no sólo para controles selectivos de malas hierbas vs cultivo, sino también para controles selectivos por especie de malas hierbas.

Referencias bibliográficas

- 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
- TZOTALIN, D. 2015. Labelling. Git code.

Agradecimientos

Esta investigación fue financiada por la EIT FOOD bajo el proyecto #20140 “Detection and ACTuation system for WEED management” (DACWEED). EIT FOOD es la comunidad de innovación en Alimentos del Instituto Europeo de Innovación y Tecnología (EIT), un organismo de la UE en el marco de Horizonte 2020, el Programa Marco de Investigación e Innovación de la UE.

Tratamiento Inteligente de Malas Hierbas a través de ISOBUS basado en reconocimiento automático en el cultivo de Tomate.

Juan LÓPEZ-CORREA¹, Ángel TOLEDO¹, Dionisio ANDUJAR¹

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

*d.andujar@csic.es

Resumen

Los desarrollos presentados en este trabajo son los resultados obtenidos del proyecto EIT-Food H2020 “Detection and ACTuation system for WEED management” (DACWEED) donde se desarrollan nuevos sistemas tecnológicos basados en visión artificial y aperos inteligentes controlados por las normas ISO11783 de comunicación en maquinarias agrícolas (ISOBUS) para la aplicación selectiva de herbicidas. Este proyecto integra tres pilares básicos: (1) un sistema de detección de malas hierbas, (2) un sistema de apoyo a la toma de decisiones (3) un implemento ISOBUS para la aplicación del tratamiento. El procedimiento de clasificación está basado en redes neuronales para la detección de objetos. Para el desarrollo de la red se han utilizado imágenes RGB tomadas en un cultivo comercial de tomate. Una vez entrenado el modelo, se validó sobre un conjunto de imágenes no utilizadas en el entrenamiento. Los resultados obtenidos fueron entre 90% - 97% dependiendo de la especie. Los datos de la Red Neuronal sirven de entrada al DSS (Decision Support System) que envía las órdenes de control a través del protocolo estandarizado ISOBUS siendo capaz de comunicar el sistema con cualquier equipo comercial del mercado.

Palabras clave: *Manejo de Malezas, Control Selectivo, Redes Neuronales, DACWEED.*

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 más preciso con beneficios económicos, ambientales y lograr una mejor calidad alimentaria (Tanget 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 proyecto europeo EIT-Food DACWEED desarrolla nuevos sistemas tecnológicos basados en visión artificial y aperos inteligentes controlados por las normas internacionales ISO11783 de comunicación entre maquinarias agrícolas. Estas normas y/o protocolos son estandarizados, de fuente abierta y más conocidas como ISOBUS. En este proyecto son utilizadas para aplicación selectiva de herbicidas según la composición de especies del rodal de malas hierbas. De esta forma el proyecto busca minimizar el uso de herbicidas, y maximizar el rendimiento y calidad de las cosechas. De este modo, este proyecto integra tres pilares básicos: (1) Un sistema de sensores para detectar la presencia y composición de malas hierbas en cada lugar del campo, (2) Un sistema de apoyo a la toma de decisiones (3) Un implemento que puede ser controlado por las normas de comunicación ISOBUS para la aplicación del tratamiento.

Este trabajo muestra una de las líneas de investigación del proyecto llevada a cabo en cultivos de tomate (*Solanum lycopersicum* L.) para la detección y tratamiento preciso en tiempo real. Esta tiene como objetivo detectar y clasificar de forma automática las especies de malas hierbas más problemáticas 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 con malas hierbas monocotiledóneas (*Cyperus rotundus* L., *Echinochloa crus galli* L., *Setaria itálica* L.) y dicotiledóneas (*Portulaca oleracea* L., *Solanum nigrum* L.). Paralelamente al sistema de detección automática de especies de malas hierbas se presenta el sistema de percepción y actuación mediante la pulverización inteligente.

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 había 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 principales 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). Este software guarda las coordenadas de un cuadro delimitador que rodea al objeto que representa. 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 *Solanum lycopersicum* 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”.

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*. 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 explicada en el párrafo anterior

2.3. Entrenamiento de la Red Neuronal RetinaNet

RetinaNet (Lin *et al.*, 2017) 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 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.

Las plantas de malas hierbas y cultivo 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). Para la 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 proporcionaba el mejor resultado. En la validación se utilizó dicho conjunto de imágenes con un total de 513 imágenes con 2716 plantas etiquetadas que no se usaron en el entrenamiento para seleccionar el modelo de red con mejor desempeño en este estudio.

2.3. Sistema de percepción y actuación.

Cómo se explicó anteriormente el sistema de percepción está conformado por cámaras RGB que proporciona la entrada de datos al sistema . Estas cámaras están instaladas en la parte delantera del tractor, lo que proporciona el tiempo necesario para la captura, procesamiento de datos y toma de decisión para la actuación. El procesamiento de la imágenes y decisión se realizan a través de una placa Jetson NVIDIA. Esta decisión es transmitida a través del protocolo ISOBUS al terminal del tractor para realizar calibraciones (e.g. activar o desactivar dosificador, velocidad de trabajo, buffer de pulverización alrededor del rodal, dosis, etc). Finalmente la decisión de actuación es transmitida al pulverizador a través del protocolo ISOBUS para realizar el control selectivo de malas hierbas. En la figura 1a se puede visualizar una representación del sistema.

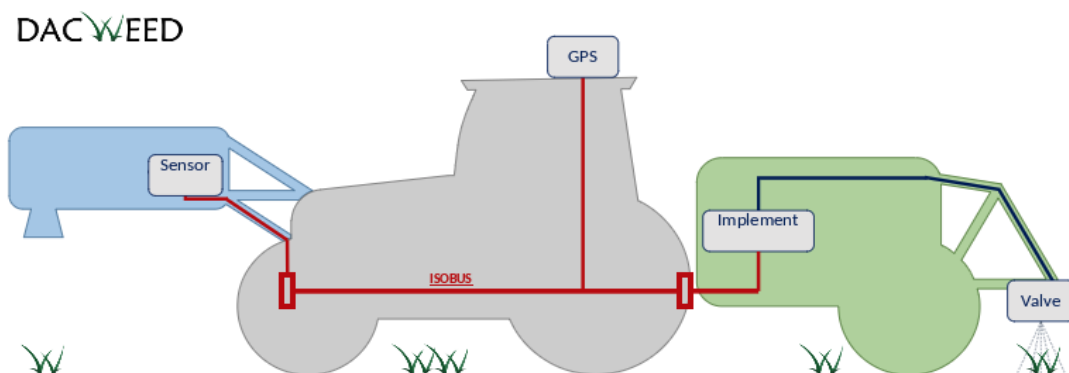


Figura 1: Representación esquemática del sistema inteligente de pulverización. Cámara RGB como sensor, GPS, conexión sensor- monitor a través de ISOBUS, sistema de actuación a través de la pulverizadora.

1. 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 fué 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

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 grupo de malas hierbas representan similitudes morfológicas para los algoritmos de clasificación. Incluso se logró discriminar entre dos especies (*Echinochloa crus-galli L.* y *Setaria itálica L.*) pertenecientes a la misma familia (“*Poaceae*”) 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).

3. 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 cultivo. Los valores obtenidos de precisión son lo suficientemente altos para realizar controles selectivos eficaces. Además se logró clasificar diferentes especies de dos grupos importantes de mala hierba, 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 muestran 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.

4. Agradecimientos

This research was funded by EIT FOOD as project# 20140 and DACWEED: Detection and Actuation system for WEED management. EIT FOOD is the innovation community on Food of the European Institute of Innovation and Technology (EIT), an EU body under Horizon 2020, the EU Framework Programme for Research and Innovation.

5. Referencias

- EPPO European and Mediterranean Plant Protection Organization code system, <http://eppt.eppo.org/>, last accessed 1 December 2020; EPPO Plant Protection Thesaurus.
- 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).
- 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.
- 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
- TANGET, 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.