

Detección temprana de malas hierbas dentro y fuera de la línea de cultivo mediante imágenes-UAV y modelos 3D

Jorge Torres-Sánchez^{1✉}, Francisca López-Granados¹, Ana Isabel de Castro¹,
Francisco M. Jiménez-Brenes¹, José Manuel Peña¹

¹Grupo imaPing, Instituto de Agricultura Sostenible, 14004-Córdoba
✉jtorres@ias.csic.es / www.ias.csic.es/imaping

Resumen: Se ha desarrollado una metodología automática para la detección temprana de malas hierbas dentro y fuera de la línea de cultivo en fase temprana usando como variable discriminante la altura de las plantas (cultivo y malas hierbas), calculada mediante técnicas fotogramétricas. Se utilizó un UAV equipado con una cámara modificada para captar información en las bandas del Rojo, Verde e Infrarrojo Cercano. Se tomaron imágenes sobre una parcela de girasol infestada por diferentes especies de malas hierbas en fase temprana. Las imágenes fueron procesadas para generar una ortoimagen y un modelo tridimensional del cultivo y malas hierbas para su posterior análisis usando métodos orientados a objetos y el clasificador Random Forest. Se comparó la infestación de malas hierbas detectada con la realmente existente en el campo en una serie de marcos de referencia, obteniéndose un coeficiente de determinación de 0,91 entre ambas variables.

Palabras clave: vehículo aéreo no tripulado, OBIA, Random Forest, manejo localizado, agricultura de precisión, girasol.

1. INTRODUCCIÓN

En los últimos años ha quedado demostrada la idoneidad de las imágenes procedentes de vehículos aéreos no tripulados (UAVs, por las siglas en inglés de Unmanned Aerial Vehicle) para la detección tanto de especies invasoras como de malas hierbas en cultivos (Hung et al., 2014; López-Granados et al., 2016, ver más publicaciones en www.ias.csic.es/imaping), siendo esto posible incluso en circunstancias complejas como las que se producen en la fase de plántula, en que el cultivo y las malas hierbas son difíciles de discriminar debido a su similitud espectral. La aplicabilidad de la tecnología UAV a la detección de malas hierbas en fase temprana se debe principalmente a tres factores: 1) las imágenes pueden ser tomadas con el UAV en el momento agronómico que interesa, lo que permite adaptarse muy bien a las condiciones del cultivo; 2) los ortomosaicos derivados de las imágenes-UAV tienen una alta resolución espacial (ej.: < 5cm píxel) debido a que se puede volar a baja altura, haciendo posible la detección de las plantas incluso en sus fases más tempranas de crecimiento; y 3) el desarrollo de técnicas de análisis de imagen orientado a objetos (OBIA, por las siglas en inglés de *Object Based Image Analysis*) que mediante la agrupación de píxeles en «objetos» posibilitan: a) un adecuado manejo de la elevada cantidad de información presente en las imágenes de alta resolución espacial, y b) una mayor precisión en las clasificaciones que la obtenida usando el análisis basado en píxeles (Blaschke, 2010).

La utilización de cámaras fotográficas a bordo de los UAVs permite, además de tomar imágenes de muy alta resolución espacial, la generación de modelos digitales de superficie (MDS) mediante la utilización de técnicas de fotogrametría y visión artificial. Estos MDS representan la superficie sobrevolada en tres dimensiones, haciendo posible el cálculo de alturas tanto de cultivos leñosos (Torres-Sánchez et al., 2015) como herbáceos (Geipel et al., 2014).

Hasta ahora la aplicación de técnicas OBIA a imágenes tomadas con UAV había permitido la detección automática de las malas hierbas presentes *entre* las líneas de cultivo, al asumirse que toda vegetación creciendo fuera de la línea de cultivo era mala hierba. Sin embargo, para detectar las plantas no deseadas creciendo *dentro* de la línea de cultivo, se han utilizado técnicas que exigen, aunque sea de forma reducida, la intervención del usuario para entrenar al algoritmo de clasificación (Pérez-Ortiz et al., 2016). Por tanto, el objetivo del presente trabajo ha sido combinar información espectral (ortomosaico) y tridimensional (MDS) para, aplicando técnicas de aprendizaje automático en un entorno OBIA, conseguir la discriminación automática de malas hierbas en fase temprana tanto dentro como fuera de la línea de cultivo. Para ello, se presentan los resultados obtenidos en un cultivo de girasol.

2. MATERIAL Y MÉTODOS

2.1. Área de estudio y vuelo UAV. El ensayo fue realizado en una parcela de girasol situada en una finca privada en el término municipal de Osuna (Sevilla), con una extensión de 2,5 ha. Se tomaron imágenes a 30 m de altura, lo que resultó en un tamaño de píxel de 0,6 cm. En el momento de la adquisición de las imágenes, el girasol estaba en el estado 14-15 de la escala BBCH, y se encontraba infestado de manera natural por diferentes especies de malas hierbas de hoja ancha (*Convolvulus arvensis* L., *Chrozophora tinctoria* (L.) A. Juss., *Polygonum aviculare* L. y *Amaranthus blitoides* S. Wats.) y hoja estrecha (*Phalaris* spp.).

El UAV empleado fue un multirrotor MD4-1000, con capacidad para transportar un sensor de hasta 1,25 kg y una autonomía de vuelo de hasta 45 minutos. Este modelo de despegue y aterrizaje vertical está dotado de un GPS que le permite seguir automáticamente una ruta previamente programada por el piloto. El sistema de manejo del UAV incluye una emisora de radiocontrol, una estación base para recepción de datos de telemetría, así como un paquete de software para diseño de rutas, configuración del vehículo e interpretación de la telemetría. A bordo del UAV se instaló una cámara convencional Sony ILCE-6000, con un sensor de 24 Mp. La cámara, gracias a una modificación de los filtros internos, captura información en las zonas del espectro correspondientes al Rojo, Verde e Infrarrojo cercano (NIR por las siglas en inglés de Near InfraRed). Ello hace que se mejore su capacidad para detectar vegetación, al tener ésta una respuesta muy característica en el NIR. La generación de los ortomosaicos y el MDS (Fig. 1) se almacenaron en formato TIFF mediante Agisoft Photoscan Professional versión 1.2.4.

2.2. Funcionamiento del algoritmo. El algoritmo de análisis de imagen se desarrolló usando Cognition Network Language dentro del entorno del programa eCognition Developer 9.1, lo que permitió combinar el análisis de imagen orientado a objetos con la utilización de un método de aprendizaje automático conocido como Random Forest que está siendo ampliamente utilizado en teledetección (Belgiu and Drăguț, 2016). El funcionamiento del algoritmo se puede dividir en los siguientes pasos:

1. División del campo de cultivo en parcelas. El campo se analiza en pequeñas parcelas de unos 100 m² para tener en cuenta la variabilidad del mismo.
2. Segmentación de una microparcela en objetos y detección de la vegetación, aplicando el método Otsu para calcular el umbral del índice NGDVI (Ec. 1) que separa entre ve-




Figura 1. a) Imagen de la parcela de ensayo tomada a pie de campo. b) Vista parcial del modelo digital de superficies (MDS) representando en oscuro las hileras. Se aprecian en la figura los fallos de siembra.

getación y suelo (Otsu, 1979). El método Otsu también se aplica a los valores de brillo de los objetos para discriminar las sombras presentes en la imagen y que pueden causar confusión en la clasificación.

$$NGDVI = \frac{NII - Verde}{NII + Verde} \quad (\text{Ec. 1})$$

3. Cálculo de la altura de los objetos de vegetación (girasol y malas hierbas) con respecto a la altura de los objetos clasificados como suelo.
4. Delineación de las líneas de cultivo mediante una rutina automática que busca la orientación de las mismas buscando el patrón lineal que abarque el mayor número de objetos de vegetación.
5. Una vez que se han ejecutado los pasos 2 y 3 en 10 microparcels, se procede al entrenamiento del clasificador Random Forest, usando como muestras de cultivo los objetos de vegetación dentro de la línea con mayor altura, y como muestras de mala hierba los objetos fuera de la línea con menor altura. Para el entrenamiento del clasificador se usaron los valores de las diferentes bandas de la imagen, así como el índice NGDVI y el brillo.
6. Aplicación de los parámetros calculados por el clasificador Random Forest al resto de objetos de las 10 microparcels estudiadas para discriminar mala hierba, suelo desnudo, cultivo y sombras.
7. Los pasos 2 a 5 se repiten tantas veces como sea necesario hasta completar el análisis de la parcela de cultivo al completo.

2.3. Validación del algoritmo. A fin de evaluar la precisión de la clasificación automática realizada por el algoritmo, se dibujaron sobre la ortoimagen de la parcela una serie de marcos de

referencia de 2x2 m distribuidos de manera regular cada 20 m, obteniéndose un total de 65 marcos. En cada uno de estos marcos se realizó una clasificación manual de la mala hierba presente, comparándose con posterioridad la cantidad de mala hierba clasificada de manera manual con la clasificada de manera automática. Se utilizó el programa JMP 10.0 para calcular el coeficiente de determinación entre ambas variables.

3. RESULTADOS Y DISCUSIÓN

En la figura 2 se muestra la comparativa gráfica entre las infestaciones de malas hierbas clasificadas de manera manual y la infestación discriminada de manera automática por el algoritmo presentado en este trabajo. El coeficiente de determinación entre ambas variables fue de 0,91, lo que indica una correlación satisfactoria y una gran capacidad del algoritmo diseñado para discriminar las malas hierbas. Se puede apreciar que se consigue la detección de malas hierbas en todo el rango de cobertura que aparece en los marcos de referencia, sin que haya casos de falsos negativos en los que no se produce la detección y que podrían ocasionar que se dejen de tratar adecuadamente las infestaciones.




Figura 2. Comparación entre la mala hierba medida y la detectada de manera automática por el algoritmo en cada una de las superficies de referencia. La línea discontinua representa la línea 1:1.

El algoritmo aquí presentado, además de la detección de malas hierbas *entre* las hileras de girasol gracias a la posición de las plantas con respecto a éstas, llega a detectar las malas hierbas que crecen *dentro* de la línea de cultivo (Fig. 3) gracias al uso de técnicas de aprendizaje automático.

Por tanto, con el presente algoritmo se realiza un gran avance en la detección de malas hierbas al permitir una cartografía de las infestaciones dentro y fuera de la línea de cultivo. A partir de estas infestaciones se diseñan los mapas de tratamiento localizado correspondientes para controlar las malas hierbas presentes en el campo independientemente de su localización respecto a la línea de cultivo.




Figura 3. a) Fragmento del ortomosaico mostrando cultivo y malas hierbas; b) comparado con la imagen clasificada por el algoritmo de manera automática.

4. CONCLUSIONES

Se ha demostrado la eficacia del algoritmo desarrollado para la discriminación automática de malas hierbas en fase temprana en un cultivo de girasol, haciendo uso de procedimientos de análisis OBIA y del método Random Forest de aprendizaje automático. El algoritmo diseñado no necesita de intervención alguna del usuario y permite discriminar las malas hierbas *dentro y fuera* de la línea de cultivo con una gran precisión.

5. AGRADECIMIENTOS

Los autores agradecen a Ovidiu Csillik (Universidad de Salzburgo, Austria) sus aportaciones en la discusión del análisis de las imágenes. Este trabajo fue financiado por el proyecto AGL2014-52465-C4-4-R MINECO-FEDER. La investigación de Jorge Torres Sánchez, Ana Isabel de Castro Megías y José Manuel Peña Barragán fue financiada por los programas FPI, Juan de la Cierva, y Ramón y Cajal, respectivamente. La estancia de Jorge Torres Sánchez en la Universidad de Salzburgo fue financiada por el programa FPI.

6. REFERENCIAS

Belgiu M. & Drăguț L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31.

- Blaschke T (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16.
- Geipel J, Link J and Claupein W (2014). Combined Spectral and Spatial Modeling of Corn Yield Based on Aerial Images and Crop Surface Models Acquired with an Unmanned Aircraft System. *Remote Sensing*, 6(11), 10335-10355.
- Hung C, Xu, Z and Sukkarieh S (2014). Feature Learning Based Approach for Weed Classification Using High Resolution Aerial Images from a Digital Camera Mounted on a UAV. *Remote Sensing*, 6(12), 12037-12054.
- López-Granados F, Torres-Sánchez J, Castro A-I D, Serrano-Pérez A, Mesas-Carrascosa F-J and Peña J-M (2016). Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery. *Agronomy for Sustainable Development*, 36(4), 67.
- Otsu N (1979). A Threshold Selection Method from Gray-Level Histograms. *IEE Transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Pérez-Ortiz M, Peña JM., Gutiérrez PA, Torres-Sánchez J, Hervás-Martínez, C and 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.
- Torres-Sánchez J, López-Granados F, Serrano N, Arquero O & Peña JM (2015). High-Throughput 3-D Monitoring of Agricultural-Tree Plantations with Unmanned Aerial Vehicle (UAV) Technology. *PLoS ONE*, 10(6), e0130479.

Early weed detection between and within the crop row using UAV images and 3D models

Summary: An automatic methodology for early season weed detection between and within the crop rows has been developed, where the main innovation was the use of plant height as discriminant feature. An UAV equipped with a conventional camera modified for R (red), G (green) and NIR (near infrared) acquisition was used for taken images over a sunflower plot infested with different weed species in early season. The images were processed to generate an orthomosaic and a digital surface model (DSM) representing both the crop and weeds, and they were analyzed using object based image analysis (OBIA) and Random Forest classifier. Automatically detected weed cover was compared with the real weed cover in the field in a number of reference frames, and the determination coefficient between both variables was 0.91.

Keywords: unmanned aerial vehicle, OBIA, Random Forest, site-specific weed management, precision agriculture, sunflower.