

Detección de malas hierbas en girasol en fase temprana mediante imágenes tomadas con un vehículo aéreo no tripulado (UAV)

Peña, J.M.*, Torres-Sánchez, J., Serrano-Pérez, A., López-Granados, F.

Departamento de Protección de Cultivos, Instituto de Agricultura Sostenible, IAS-CSIC. Córdoba, España.

Resumen: La discriminación de malas hierbas en fase temprana con técnicas de teledetección requiere imágenes remotas de muy elevada resolución espacial (píxeles <5 cm). Actualmente, sólo los vehículos aéreos no tripulados (UAV) pueden generar este tipo de imágenes. El objetivo de este trabajo fue evaluar imágenes UAV tomadas con una cámara visible a diferentes alturas de vuelo (40, 60, 80 y 100 m) y cuantificar la influencia de la resolución espacial en la discriminación de malas hierbas en fase temprana en un cultivo de girasol. Se aplicó un algoritmo de clasificación de imágenes basado en objetos, el cual se divide en dos fases principales: 1) detección de líneas de cultivo y 2) clasificación de cultivo, malas hierbas y suelo desnudo. El algoritmo resultó 100% eficaz en la detección de las líneas de cultivo en todos los casos (fase 1), así como en la detección de zonas libres de mala hierba en las imágenes tomadas a 40 y 60 m de altura. En las zonas con presencia de malas hierbas, los mejores resultados se obtuvieron en las imágenes tomadas a baja altura (40 m), con un 71% de marcos de muestreo clasificados correctamente (fase 2). La mayoría de los fallos de clasificación cometidos en todas las imágenes fueron falsos negativos, es decir, malas hierbas no detectadas debido a su pequeño tamaño en el momento de la captura de las imágenes. Por tanto, el siguiente paso sería desarrollar un estudio multi-temporal para estudiar la detección de las malas hierbas en estados fenológicos más avanzados. Esto podría facilitar su discriminación en las imágenes y, por tanto, disminuir el porcentaje de falsos negativos en las clasificaciones.

Palabras clave: agricultura de precisión, control localizado de malas hierbas, rango espectral visible, alta resolución espacial, análisis de imágenes basado en objetos (OBIA).

Weed mapping in early-season sunflower fields using images from an unmanned aerial vehicle (UAV)

Abstract: Weed mapping in early season requires of very high spatial resolution images (pixels <5 cm). Currently only Unmanned Aerial Vehicles (UAV) can take such images. The aim of this work was to evaluate the optimal flight altitude for mapping weeds in an early season sunflower field using a low-cost camera that took images in the visible spectrum at several flight altitudes (40, 60, 80 and 100 m). The object based image analysis procedure used for weed mapping was divided in two main phases: 1) crop-row identification, and 2) crop, weed and bare soil classification. The algorithm identified the crop rows with 100% accuracy at every flight altitude (phase 1) and it detected weed-free zones with 100% accuracy in the images captured at 40 and 60 m flight altitude. In weed-infested zones, the classification algorithm obtained the best results in the images captured at low altitude (40 m), reporting 71% of correctly classified sampling frames (phase 2). Most of errors committed (incorrectly classified frames) were produced by non-detection of weeds (negative false). Subsequent studies would consist in a multi-temporal study aiming to detect weeds are at a more advance growth stage. It could reduce the percentage of negative false in the classification.

Key words: precision agriculture, site-specific weed management, visible spectra, high spatial resolution, object-based image analysis (OBIA).

* Autor para la correspondencia: jmpena@ias.csic.es

1. Introducción

La utilización de productos fitosanitarios es una de las principales técnicas para mantener la sanidad de los cultivos. No obstante, su empleo supone un elevado coste para el agricultor e implica ciertos riesgos medioambientales, de ahí la importancia de una aplicación sostenible y óptima de estos productos. La agricultura de precisión y, en concreto, el manejo localizado de malas hierbas van orientados a este propósito, es decir, aplicar los herbicidas sólo en aquellas zonas del cultivo que lo necesiten y usar el tipo de herbicida requerido para cada grupo de malas hierbas dependiendo de si son monocotiledóneas o dicotiledóneas. Existen numerosos trabajos de cartografía de malas hierbas en época tardía mediante imágenes remotas tomadas con aviones tripulados (Peña-Barragán *et al.*, 2011; de Castro *et al.*, 2012) o con satélites (Martín *et al.*, 2011; de Castro *et al.*, 2013). Sin embargo, el uso de estas imágenes plantea varias limitaciones para la detección de malas hierbas en época temprana, que es el momento recomendado en muchos cultivos para realizar los tratamientos herbicidas y obtener un control óptimo. Dichas limitaciones son la baja resolución espacial de las imágenes, que imposibilita la discriminación entre cultivo y plántulas de mala hierba debido a su pequeño tamaño y a su similar aspecto y comportamiento espectral (López-Granados, 2011), o la influencia de las condiciones ambientales en la captura de imágenes, lo que condiciona el momento del vuelo y, en definitiva, la obtención de mapas de malas hierbas en el momento necesario.

Estas limitaciones pueden ser solventadas con el uso de los vehículos aéreos no tripulados (UAVs, por las siglas en inglés de *Unmanned Aerial Vehicles*), que pueden volar a muy baja altura (<100 m) y, por tanto, permiten la captura de imágenes remotas de muy alta resolución espacial (1-5 cm/píxel). Además, los UAVs pueden tomar imágenes en días nublados y pueden ser manejados autónomamente por el usuario, lo que añade una total flexibilidad para tomar las imágenes en el momento óptimo de aplicación de medidas de control (Torres-Sánchez *et al.*, 2013). Otra de las ventajas de los UAV es el bajo coste de los sensores empleados, pudiéndose usar cámaras digitales convencionales. Este tipo de cámaras ya han sido utilizadas anteriormente

en la detección de malas hierbas dentro de los cultivos por medio de vehículos terrestres con buenos resultados (Meyer y Neto, 2008; Guijarro *et al.*, 2011; Romeo *et al.*, 2013). La discriminación de malas hierbas en fechas tempranas con imágenes remotas es una tarea difícil con métodos de análisis basados en píxeles debido a su similitud espectral con las plantas del cultivo. La solución es la aplicación de métodos basados en objetos (*Object Based Image Analysis, OBIA*), que permiten diferenciar entre plantas de cultivo y de malas hierbas usando, además de la información espectral, la posición relativa de las malas hierbas con respecto a las líneas de cultivo (Peña *et al.*, 2013). Con las técnicas OBIA, la mayor o menor precisión conseguida en la detección dependerá de las decisiones que se tomen respecto a la captura de las imágenes y su posterior proceso, influyendo los siguientes factores: 1) altura de vuelo del UAV, que es uno de los factores determinantes para una mayor o menor resolución espacial, 2) resolución espectral del tipo de sensor elegido para la captura de imágenes que podrá abarcar diferentes zonas del espectro (cámara visible, cámara multi-espectral con infrarrojo, entre otras), 3) índice de vegetación utilizado en la discriminación entre vegetación y suelo desnudo, y 4) método de cálculo del valor umbral óptimo para la separación entre clases (suelo-vegetación).

En esta investigación se tomaron imágenes UAV con un sensor visible sobre un cultivo de girasol a cuatro alturas de vuelo para estudiar su eficiencia en la detección de malas hierbas. Para la discriminación entre vegetación y suelo desnudo se utilizó el índice de vegetación *Excess Green* (ExG), que ha generado resultados satisfactorios en ensayos previos (Torres-Sánchez *et al.*, 2013, 2014), así como el método Otsu (Otsu, 1979) para el cálculo automático del valor umbral óptimo de separación entre ambas clases (Guijarro *et al.*, 2011; Torres-Sánchez *et al.*, 2014). El objetivo fue evaluar la configuración óptima de vuelo según los resultados de clasificación obtenidos y atendiendo a dos factores: 1) la altura de vuelo, que afecta a la resolución espacial de las imágenes y a la superficie de terreno abarcada en cada toma, y 2) la duración del vuelo, que está condicionado por la capacidad de la batería del UAV utilizado.

2. Metodología

2.1. Zona de estudio

El ensayo se realizó en una parcela de girasol de 0,5 hectáreas de superficie situada en la finca pública de Alameda del Obispo en Córdoba (España, coordenadas centrales 37,856N, 4,806W, datum WGS84). El girasol fue sembrado el 15 de abril de 2014 en líneas separadas 70 cm. El campo tenía una infestación natural de dos malas hierbas dicotiledóneas o de hoja ancha, *Chenopodium album* L y *Convolvulus arvensis* L. Las imágenes remotas se tomaron el 29 de mayo de 2014 (44 días después de la siembra), cuando el estado fenológico del cultivo y las malas hierbas era de 4-6 hojas verdaderas, que corresponde al estadio 1 de la escala BBCH (Lancashire *et al.*, 1991) (Figura 1).



Figura 1. Parcela de estudio y estado fenológico de las plantas de girasol y de las malas hierbas presentes entre las calles del cultivo en el momento de la toma de imágenes.

2.2. Equipo utilizado para la toma de imágenes

El UAV empleado para la toma de imágenes fue un cuadricóptero MD4-1000 (microdrones GmbH, Siegen, Alemania). Este vehículo realiza un despegue y aterrizaje vertical, posee una capacidad de carga de hasta 1,25 kg, y su autonomía de vuelo

es de aproximadamente 45 minutos (Figura 2). Este modelo está dotado de un sistema GPS que le permite volar autónomamente siguiendo una ruta previamente programada. La toma de las imágenes es accionada automáticamente por el UAV según la configuración de vuelo. En el momento de la captura de cada imagen, el UAV registra su posición GPS, su altura y la hora.

Para este estudio se utilizó una cámara modelo Olympus PEN E-PM1 (Olympus Corporation, Tokio, Japón). Esta cámara toma imágenes con un sensor de 12 megapíxeles en color verdadero, compuesto por los canales rojo, verde y azul (RGB, por las siglas en inglés *Red-Green-Blue*) y con unas dimensiones de 4032×3024 píxeles. Las imágenes son almacenadas en una tarjeta de memoria y pueden usarse directamente tras su descarga. Información más detallada acerca de la configuración del vuelo y características del UAV y del sensor pueden encontrarse en Torres-Sánchez *et al.* (2013).



Figura 2. UAV MD4-1000 en vuelo sobre el campo de cultivo con la cámara visible acoplada en su parte central.

2.3. Adquisición de imágenes

Las imágenes se tomaron sobre la parcela de estudio a cuatro alturas de vuelo diferentes: 40, 60, 80 y 100 m, y ascendiendo el vehículo sobre un punto fijo de referencia consistente en un panel espectralón (Labsphere Inc., North Sutton, NH,



Figura 3. Detalle del panel espectralón sobre el campo de girasol.

EE.UU.), claramente visible en las imágenes tomadas (Figura 3). Las cuatro imágenes obtenidas a diferentes alturas se georreferenciaron en base a las coordenadas de una serie de puntos de control medidos mediante GPS.

Las resoluciones espaciales resultantes para cada altura de vuelo así como la superficie cubierta en campo con cada toma se muestran en la Tabla 1.

Tabla 1. Resolución espacial y área capturada por cada imagen según la altura de vuelo.

Altura de vuelo (m)	Resolución espacial (cm/píxel)	Área (m ²)
40	1,52	2817
60	2,28	6338
80	3,04	11268
100	3,81	17699

2.4. Procedimiento de análisis de imágenes

El algoritmo de clasificación OBIA utilizado para el análisis de las imágenes se generó con el programa eCognition developer 8.9 (Trimble GeoSpatial, Munich, Alemania). El método desarrollado es

completamente automático y se basa en los algoritmos previamente desarrollados para cartografía de malas hierbas en maíz descritos en Peña *et al.* (2013). Consta de las siguientes fases:

1. **Segmentación de la parcela en sub-parcelas:** La imagen se dividió en pequeñas áreas de estudio de 5×5 m. Cada sub-parcela se estudió de forma independiente, lo que permitió ajustar el análisis a las características espectrales (tipo de malas hierbas, color del suelo, etc) y morfológicas (crecimiento del cultivo, separación entre líneas de cultivo) de cada zona de la parcela. De esta manera, se minimiza el error debido a variaciones locales en la parcela de estudio.
2. **Segmentación de la imagen:** Las sub-parcelas obtenidas en el paso anterior se segmentaron en objetos homogéneos más pequeños de varios píxeles de tamaño, formados por vegetación (cultivo y mala hierba) y suelo desnudo. Esos objetos contienen la información espectral y contextual (orientación, posición, tamaño) para la clasificación posterior de las imágenes.
3. **Discriminación de vegetación:** Para diferenciar entre objetos de vegetación (malas hierbas y cultivo) y de suelo desnudo se utilizó el índice de vegetación *Excess Green* (ExG, Woebbecke *et al.*, 1995) (1), con el que se han obtenido resultados satisfactorios en otros trabajos de discriminación de vegetación en escenarios agrícolas con imágenes de UAV (Torres-Sánchez *et al.*, 2014). El umbral óptimo del índice para discriminar entre ambas clases se obtuvo mediante una adaptación del método iterativo Otsu de cálculo de umbrales (Otsu, 1979) al software eCognition.

(1) $ExG=2g-r-b$, siendo

$$r = \frac{R}{R+G+B}; g = \frac{G}{R+G+B}; b = \frac{B}{R+G+B}$$

4. **Cálculo de la orientación del cultivo:** La orientación del cultivo se calculó mediante un proceso iterativo de segmentación de cada sub-parcela en líneas con diferentes ángulos desde 0° a 180°. La orientación final seleccionada fue aquella con la cual se obtuvieron líneas con un mayor porcentaje total de objetos de vegetación.

5. **Segmentación en líneas de cultivo:** Tras discriminar la vegetación y determinar la orientación del cultivo, se creó un nuevo nivel por encima del principal (nivel superior), formado por una red de líneas con la misma orientación que la calculada para el cultivo.
6. **Clasificación de las líneas de cultivo:** Las líneas del nivel superior que poseen un alto porcentaje de objetos de vegetación en su nivel inferior fueron clasificadas como líneas de cultivo. Para evitar que zonas con mucha infestación de malas hierbas sean confundidas con zonas de cultivo, el algoritmo utilizó la distancia real entre líneas de cultivo y enmascaró las líneas próximas a las líneas clasificadas como cultivo. Por tanto, los objetos en el nivel superior se clasificaron en tres clases diferentes: líneas de cultivo, líneas de suelo desnudo y líneas adyacentes al cultivo.
7. **Discriminación de malas hierbas:** Se creó un nuevo nivel por debajo del principal (nivel inferior) en el cual se realizó la clasificación de malas hierbas según los siguientes criterios: 1) los objetos de vegetación situados en las líneas de suelo desnudo se clasificaron como malas hierbas, 2) los objetos de vegetación situados en las líneas de cultivo se clasificaron como girasol, y 3) los objetos situados en las líneas adyacentes al cultivo se clasificaron como mala hierba o girasol dependiendo de la proximidad espectral del valor del índice de vegetación de cada objeto con respecto a los valores de los objetos clasificados como girasol o como malas hierbas.
8. **Exportación de resultados (validación):** El archivo vectorial compuesto por los 30 marcos de muestreo se utilizó para exportar los porcentajes de superficie contenidos en cada marco para cada una de las clases clasificadas (cultivo, mala hierba, suelo desnudo) y proceder a la evaluación de los resultados obtenidos para cada imagen capturada.

2.5. Evaluación de los resultados

El algoritmo de análisis de imagen se evaluó comparando los resultados de cada clasificación con los datos obtenidos en una clasificación manual realizada en 30 marcos de muestreo de 1×1 m identificados en una imagen verdad-terreno

adquirida el día del ensayo. La imagen verdad-terreno se construyó a partir del mosaico de una secuencia de imágenes solapadas tomadas por la cámara visible a 10 metros de altura. Se tomaron fotos cada segundo con un grado de solape de 80% en la línea de vuelo y del 30% entre líneas. La resolución obtenida a esta altura fue de 0,38 cm. El mosaico de la imagen se realizó con el programa Agisoft PhotoScan Professional Edition (Agisoft LLC, San Petersburgo, Rusia), constando de tres fases: alineación de la imagen, construcción de la geometría y generación de la ortofoto. Los marcos de muestreo se generaron con ArcGis (ESRI, Madrid, España) en formato vectorial (*shapefile*), distribuidos por toda la superficie del ensayo. Veinticuatro marcos tenían presencia de mala hierba y seis estaban libres de infestaciones. La clasificación manual de la vegetación presente en cada marco de muestreo se realizó con el programa eCognition y se distinguieron 3 clases: girasol, mala hierba y suelo desnudo.

La evaluación de las clasificaciones de las imágenes tomadas a cada altura de vuelo se realizó comparando las malas hierbas observadas en la imagen verdad-terreno y las malas hierbas detectadas por el algoritmo en los treinta marcos de muestreo utilizados (Figura 4). Los resultados se agruparon en cuatro tipos: 1) correctos, marcos en los que la mala hierba observada y detectada coinciden, 2) infra-estiman, marcos en los que el algoritmo detecta mala hierba pero menos de la existente realmente en el campo, 3) falsos negativos, marcos en los que existiendo mala hierba el algoritmo no la detecta, 4) falsos positivos, marcos donde el algoritmo clasifica cultivo o suelo desnudo como mala hierba, sobreestimando así la infestación real existente en el cultivo.

3. Resultados y discusión

3.1. Detección de líneas de cultivo

El algoritmo OBIA detectó las líneas de cultivo de girasol con un 100% de exactitud en todos los casos analizados (cuatro alturas de vuelo). Entre los distintos métodos de detección de líneas de cultivo (Guerrero *et al.*, 2013), se aplicó un método basado en la acumulación de objetos de vegetación siguiendo la orientación estimada del cultivo. El método seleccionado es intuitivo y se ajustó

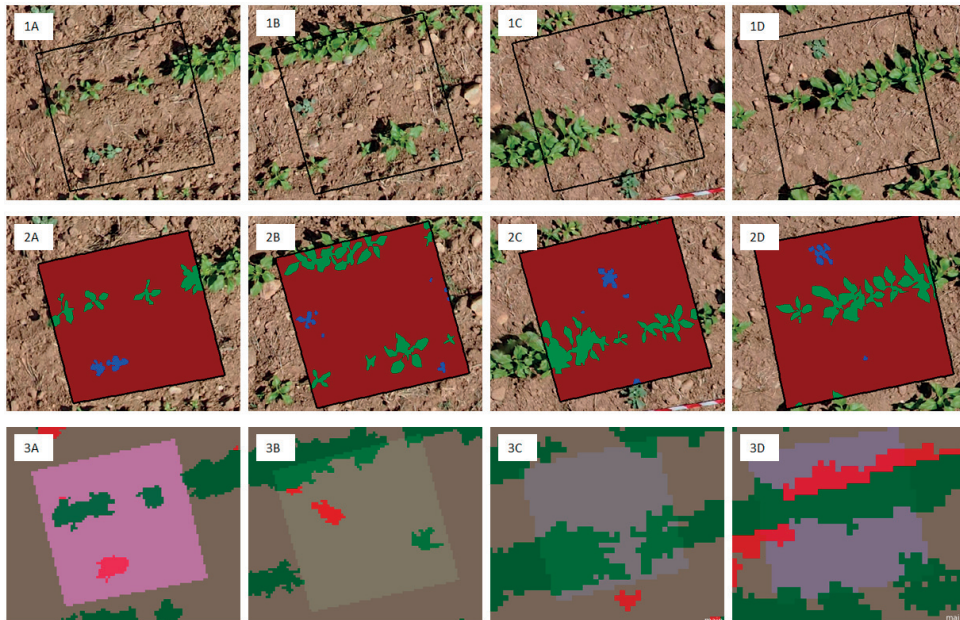


Figura 4. 1) Imágenes verdad-terreno tomadas con el UAV a 10 m de altura, en donde se pueden distinguir visualmente las plantas de mala hierba entre las líneas de cultivo; 2) clasificación visual de cultivo (en verde) y mala hierba (en azul) observadas en los marcos de muestreo; 3) ejemplos de clasificación de cultivo (en verde) y mala hierbas (en rojo) realizada por el algoritmo de análisis de imágenes: A) Correctos, B) Infra-estiman, C) Falsos negativos, D) Falsos positivos. (Para la correcta visualización del color se remite al lector a su versión digital, <http://dx.doi.org/10.4995/raet.2014.3148>)

perfectamente al cultivo de girasol y a las imágenes remotas utilizadas, obteniéndose resultados de clasificación similares a los observados previamente en maíz (Peña *et al.*, 2013) y superiores a los observados en trigo (Torres-Sánchez *et al.*, 2014). La elevada eficacia del algoritmo para detectar las líneas de cultivo fue crucial para la clasificación posterior de los objetos de vegetación en cultivo o mala hierba, ya que la discriminación de malas hierbas se basa en su posición relativa con respecto a las líneas de cultivo.

3.2. Detección de zonas con presencia de malas hierbas

Los porcentajes de precisión en la detección de malas hierbas obtenidos para cada altura de vuelo se muestran en la Tabla 2. A baja altura (40 m) se obtuvo un 71% de marcos clasificados correctamente. Según aumentó la altura de vuelo se observó que la detección empeora, pasando en 60 m a un porcentaje de acierto de 43% y bajando a un 29% y un 19% respectivamente para 80 y 100 m. Siguiendo un protocolo similar con imágenes UAV tomadas a 30 metros de altura sobre una

parcela de maíz, Peña *et al.* (2013) obtuvieron un 85% de exactitud media considerando tres niveles de cobertura de malas hierbas.

La exactitud de las clasificaciones disminuyó progresivamente con la altura de vuelo debido a la pérdida de resolución espacial de las imágenes (Tabla 1). A mayor resolución espacial las plantas en la imagen están muy bien definidas, existiendo casi en la totalidad de la imagen píxeles puros de planta y píxeles puros de suelo desnudo. Sin embargo, el número de píxeles mezclados de suelo desnudo y vegetación aumenta conforme la resolución espacial disminuye. Esta mezcla espectral afecta al valor del índice de vegetación en esos píxeles y al umbral de separación entre clases y, por tanto, empeora la eficacia en la discriminación (Torres-Sánchez *et al.*, 2014).

La mayoría de los errores de clasificación en las imágenes tomadas a 40, 60 y 80 m de altura se debieron a la no detección de mala hierba (falsos negativos). Sin embargo, a alturas superiores (100 m), dichos errores se debieron mayoritariamente a falsos positivos, es decir, a la clasificación de cultivo como mala hierba debido a confusiones

Tabla 2. Porcentajes de precisión en la detección de malas hierbas (mh) en un campo de girasol obtenidos en imágenes de rango visible tomadas a diferentes alturas de vuelo.

Tipo de marco	Altura de vuelo (m)	Porcentaje de marcos clasificados (%)			
		Correctos	Infra-estimados	Falsos negativos	Falsos positivos
Con mh	40	71	5	14	10
	60	43	10	43	5
	80	29	10	48	14
	100	19	10	24	48
Sin mh	40	100	0	0	0
	60	100	0	0	0
	80	44	0	0	56
	100	33	0	0	67

en los bordes de las hileras de girasol. Se observó que dichos errores se debieron a la mezcla espectral entre cultivo y suelo desnudo y a su semejanza con la respuesta espectral de los objetos de mala hierba. Desde el punto de vista agronómico, tienen más relevancia los fallos debidos a la no detección (falsos negativos) o infraestimación de malas hierbas que los causados por sobreestimación, ya que los primeros llevarían a no tratar zonas del cultivo donde existen malas hierbas que compiten con él y que reducen su producción.

3.3. Detección de zonas libres de malas hierbas

Respecto a la precisión en la detección de los marcos en los que no existía mala hierba, el método aplicado alcanzó un 100% de exactitud en la clasificación de las imágenes tomadas a 40 y 60 m de altura. Este resultado es satisfactorio ya que los mapas de tratamientos localizados de herbicidas se generan en base a los mapas de infestaciones de manera que se pueden delimitar con total precisión las zonas en las que no hay que realizar aplicación de herbicida. En las imágenes tomadas a 80 y 100 m de altura, la precisión de las clasificaciones disminuyó drásticamente a un 44% y un 33%, respectivamente, debido principalmente a que algunos bordes de las líneas de cultivo se clasificaron como mala hierba, por las razones explicadas con anterioridad.

4. Conclusiones

Las investigaciones sobre detección y cartografía de malas hierbas en época temprana mediante

teledetección es aún escasa debido a la elevada resolución espacial requerida para observar las plántulas, ya que sólo puede obtenerse en imágenes tomadas con UAV y la aplicación de esta tecnología en estudios agrícolas (Zhang y Kovacs, 2012) y en malherbología (Rasmussen *et al.*, 2013) es muy reciente. En el presente trabajo se tomaron imágenes UAV con una cámara visible (RGB) a varias alturas de vuelo y se cuantificó su eficiencia en la detección de malas hierbas en un cultivo de girasol en época temprana. Las principales ventajas de la cámara utilizada fueron el bajo coste, la facilidad de su uso e instalación en el UAV, y la elevada resolución espacial de las imágenes capturadas.

El algoritmo de clasificación OBIA usado para la cartografía de malas hierbas clasificó las líneas de cultivo con un 100% de exactitud con independencia de la altura de vuelo. La misma exactitud se obtuvo en la detección de zonas libres de malas hierbas en las imágenes tomadas a 40 y 60 m de altura. En zonas con presencia de malas hierbas, los mejores resultados (71%) se obtuvieron en las imágenes tomadas a 40 m de altura. La eficiencia del método disminuyó a medida que aumentó la altura de vuelo, debido principalmente a la dificultad de detectar las malas hierbas en las imágenes con menor resolución espacial. Por tanto, dependiendo del objetivo agronómico, habría que valorar en cada caso y según la precisión necesaria, si es preferible volar a baja altura y obtener resultados más precisos o volar a más altura y reducir la exactitud del método, aunque en esta segunda opción se tenga la ventaja de que se pueda abarcar mayor superficie de cultivo en un solo vuelo y, por tanto, se disminuya el tiempo de vuelo y se pueda optimizar el flujo de trabajo necesario.

Teniendo en cuenta que las imágenes fueron tomadas en una fecha muy temprana de desarrollo del cultivo y, por tanto, con presencia de plántulas de mala hierba de muy pequeño tamaño, se plantea realizar nuevos ensayos con el objetivo de estudiar la detección en fechas más tardías, cuando las malas hierbas se encuentren en un estado fenológico más avanzado, por ejemplo, de 8-10 hojas verdaderas. Asimismo, debido al desarrollo de sensores con rango espectral en el espectro infrarrojo, que son más sensibles a la detección de la vegetación, también se plantea ampliar el estudio con dichos sensores, lo que podría facilitar la detección de vegetación y mejorar los resultados de clasificación. Por tanto, el siguiente objetivo sería comparar los resultados obtenidos con el sensor visible con los que se obtuvieran con un sensor que capte información en infrarrojo cercano, así como incluir un estudio multi-temporal en distintas fechas de vuelo, lo que podría mejorar los resultados obtenidos en este ensayo y disminuir el porcentaje de falsos negativos en las clasificaciones.

Agradecimientos

Este trabajo fue financiado por el proyecto Recupera 2020 (Ministerio de Economía y Competitividad y Fondos FEDER de la Unión Europea). La investigación de Jorge Torres Sánchez fue financiada por el programa FPI (CSIC y fondos FEDER).

Referencias

- De Castro, A.I., Jurado-Expósito, M., Peña-Barragán, J.M., López-Granados, F. 2012. Airborne multi-spectral imagery for mapping cruciferous weeds in cereal and legume crops. *Precision Agriculture*, 13(3): 302-321. <http://dx.doi.org/10.1007/s11119-011-9247-0>
- De Castro, A.I., López-Granados, F., Jurado-Expósito, M. 2013. Broad-scale cruciferous weed patch classification in winter wheat using QuickBird imagery for in-season site-specific control - Springer. *Precision Agriculture*, 14(4): 392-413. <http://dx.doi.org/10.1007/s11119-013-9304-y>
- Guerrero, J.M., Guijarro, M., Montalvo, M., Romeo, J., Emmi, L., Ribeiro, A., Pajares, G. 2013. Automatic expert system based on images for accuracy crop row detection in maize fields. *Expert Systems with Applications*, 40(2): 656-664. <http://dx.doi.org/10.1016/j.eswa.2012.07.073>
- Guijarro, M., Pajares, G., Riomoros, I., Herrera, P.J., Burgos-Artizzu, X.P., Ribeiro, A. 2011. Automatic segmentation of relevant textures in agricultural images. *Computers and Electronics in Agriculture*, 75(1): 75-83. <http://dx.doi.org/10.1016/j.compag.2010.09.013>
- Lancashire, P.D., Bleiholder, H., Boom, T.V.D., Langelüddeke, P., Stauss, R., Weber, E., Witzemberger, A. 1991. A uniform decimal code for growth stages of crops and weeds. *Annals of Applied Biology*, 119(3): 561-601. <http://dx.doi.org/10.1111/j.1744-7348.1991.tb04895.x>
- López-Granados, F. 2011. Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Research*, 51(1): 1-11. <http://dx.doi.org/10.1111/j.1365-3180.2010.00829.x>
- Martín, M.P., Barreto, L., Riaño, D., Fernández-Quintanilla, C., Vaughan, P. 2011. Assessing the potential of hyperspectral remote sensing for the discrimination of grassweeds in winter cereal crops. *International Journal of Remote Sensing*, 32(1): 49-67. <http://dx.doi.org/10.1080/01431160903439874>
- Meyer, G.E., Neto, J.C. 2008. Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, 63(2): 282-293. <http://dx.doi.org/10.1016/j.compag.2008.03.009>
- Otsu, N. 1979. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man and Cybernetics*, 9(1): 62-66. <http://dx.doi.org/10.1109/TSMC.1979.4310076>
- Peña-Barragán, J.M., Ngugi, M.K., Plant, R.E., Six, J. 2011. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, 115(6): 1301-1316. <http://dx.doi.org/10.1016/j.rse.2011.01.009>
- Peña, J.M., Torres-Sánchez, J., de Castro, A.I., Kelly, M., López-Granados, F. 2013. Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *PLoS ONE*, 8(10), e77151. <http://dx.doi.org/10.1371/journal.pone.0077151>
- Rasmussen, J., Nielsen, J., García-Ruiz, F., Christensen, S., Streibig, J.C. 2013. Potential uses of small unmanned aircraft systems (UAS) in weed research. *Weed Research*, 53(4): 242-248. <http://dx.doi.org/10.1111/wre.12026>
- Romeo, J., Pajares, G., Montalvo, M., Guerrero, J. M., Guijarro, M., de la Cruz, J.M. 2013. A new Expert System for greenness identification in agricultural images. *Expert Systems with Applications*, 40(6): 2275-2286. <http://dx.doi.org/10.1016/j.eswa.2012.10.033>

- Torres-Sánchez, J., López-Granados, F., De Castro, A.I., Peña-Barragán, J.M. 2013. Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management. *PLoS ONE*, 8(3), e58210. <http://dx.doi.org/10.1371/journal.pone.0058210>
- Torres-Sánchez, J., Peña, J.M., de Castro, A.I., López-Granados, F. 2014. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103: 104-113. <http://dx.doi.org/10.1016/j.compag.2014.02.009>
- Wobbecke, D.M., Meyer, G.E., Von Bargen, K., Mortensen, D.A. 1995. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the American Society of Agricultural Engineers*, 38(1): 259-269. <http://dx.doi.org/10.13031/2013.27838>
- Zhang, C., Kovacs, J. 2012. The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture*, 13(6): 693-712. <http://dx.doi.org/10.1007/s11119-012-9274-5>