

EVALUACIÓN DE LA TÉCNICA DE RESAMPLING EN IMÁGENES UAV PARA LA DETECCIÓN DE MALAS HIERBAS MEDIANTE ANÁLISIS OBIA

Borra I. *, Peña J.M., Torres-Sánchez J., López-Granados F.

*Instituto de Agricultura Sostenible (IAS-CSIC),
Apdo. 4084, 14004 Córdoba, España.*

**irene.borra@ias.csic.es*

Resumen: Los vehículos aéreos no tripulados (UAVs) son una tecnología emergente en el estudio de parámetros agrícolas por sus características y por portar sensores en diferente rango espectral. En este trabajo se ha detectado y cartografiado rodales de malas hierbas en fase temprana mediante análisis OBIA para elaborar mapas que optimicen el tratamiento herbicida localizado. Se ha aplicado resampling (resamplio) sobre imágenes tomadas en campo desde un UAV (UAV-I) para crear una nueva imagen con distinta resolución espacial. A las imágenes resampleadas (RS-I) se les evaluó la calidad espacial y espectral y la eficacia de nuestro análisis en la detección de malas hierbas. Los resultados de las imágenes RS-I muestran una precisión similar a las imágenes UAV-I siendo factible su utilización en tecnologías de manejo localizado de malas hierbas. Se discuten las ventajas del uso de la técnica de resampling en imágenes UAV.

Palabras clave: Agricultura de precisión, teledetección, mapas, drones.

Summary: *Evaluation of resampling applied to UAV imagery for weed detection using OBIA.* Unmanned aerial vehicles (UAV) are an emerging technology for the study of agriculture parameters due to its characteristics and the availability of embedding sensors with different spectral range. In our study, the detection and mapping of weeds in early phenological stage allowed to design a strategy for the optimizing of herbicide treatment. In this work, resampling is used to create a new version of an image with a different spatial resolution, using real UAV imagery. A spatial and spectral quality evaluation was carried out to resampled images (RS-I), and then, our workflow for weed detection applied. The results showed that RS-I and UAV-I showed similar accuracy on weed detection and thus could be used for site-specific weed management achieving a percentage of savings in the herbicide. Opportunities of using RS-I are discussed.

Keywords: Precision agriculture, remote sensing, maps, UAV.

INTRODUCCIÓN

La distribución en rodales y la variabilidad en densidad y especie de las malas hierbas en los cultivos ha sido demostrada (López-Granados, 2011). Sin embargo, para controlarlas, en la mayoría de los casos, se aplica herbicida de forma uniforme en el campo generando gastos innecesarios. Esta situación puede solventarse mediante un control localizado de las infestaciones presentes en el campo de cultivo. Para estados fenológicos tardíos se han creado mapas de malas hierbas a partir de imágenes de satélite y aéreas; pero en fase temprana, la baja resolución espacial que presentan dichas imágenes (>50cm/píxel) no permite distinguir la mala hierba del cultivo. El UAV surge como alternativa que cumple los requisitos de generar imágenes con alta resolución espacial y espectral. Peña et al. (2013) emplearon el análisis de imagen basado en objetos (*Object-Based Image Analysis*, OBIA) para la discriminación temprana de malas hierbas en maíz mediante imágenes UAV sin mosaicar. No obstante, para cubrir la superficie de toda la parcela y localizar los rodales es necesario emplear imágenes orto-mosaicadas.

El *Resampling* es una técnica matemática usada para crear una nueva imagen (RS-I) con un tamaño diferente de píxel (Dogson, 1992) que se ha empleado desde los años 70 para la fusión de imágenes de satélite con distinta resolución. En el caso de aplicar resampling a imágenes tomadas con UAV (UAV-I), se persigue obtener una nueva imagen que simule una altura de vuelo mayor (con menor resolución espacial) a partir de una imagen de baja altitud (alta resolución espacial) para reducir costes económicos (menor número de vuelos), tiempos y optimizar el análisis (mapas se obtienen en menor tiempo).

Por lo anterior, los objetivos de este trabajo fueron: 1) resamplear imágenes UAV a diferentes alturas de vuelo y evaluar su calidad espacial y espectral, 2) aplicar el proceso OBIA en RS-I y UAV-I, 3) comparar los mapas de malas hierbas resultantes en cada tipo de imágenes, y 4) valorar las ventajas del resampling en relación a la optimización de la tecnología UAV.

MATERIAL Y MÉTODOS

Localización, vuelos y sensores

El estudio se realizó en dos campos de girasol de 1 ha (Campo1 y Campo2) en la provincia de Sevilla (coordenadas UTM X=295.400m Y=4.156.107m, y X=295.112m Y=4.155.611m, respectivamente). El estado fenológico tanto de las malas hierbas como del cultivo era: fase principal 1, de 4 a 6 hojas verdaderas según escala BBCH (Meier, 1997).

Las imágenes fueron tomadas mediante un quadcopter UAV modelo md4-1000. Se tomaron las imágenes utilizando dos sensores, una cámara convencional visible (RGB) Olympus PEN E-PM1 y una multiespectral Tetracam mini-MCA-6 (TTC; RGB+NIR, infrarrojo cercano), el día 7 de mayo 2014 a diferentes alturas de vuelo: 30, 60 y 100m. No obstante, el vuelo a 60m con RGB en el Campo1 no ha podido ser estudiado por problemas de descarga de las imágenes en el ordenador. Información más detallada de la configuración de los vuelos y especificaciones del vehículo y cámaras pueden encontrarse en Torres-Sánchez et al. (2013). Para mosaicar las imágenes se empleó el software Agisoft Photoscan Professional Edition (Agisoft LLC, St. Petersburg, Rusia).

Resampling: degradación espacial de imágenes de alta calidad

La UAV-I generada del vuelo a 30m (resolución espacial 1,07cm para RGB y 1,16cm para TTC) fue degradada para simular las resoluciones espaciales de vuelos a 60 y 100m de altura. Para crear las RS-Is se empleó el método de resampling del vecino más próximo (*nearest neighbor*, NN) en el software ENVI (ENVI 5.0, Research Systems Inc. Boulder, CO, USA). Se opta por la técnica NN si la nueva imagen ha de ser clasificada por dos motivos: mantiene los niveles digitales de los píxeles al realizar simplemente un reajuste posicional (se asigna al nuevo píxel el valor del más cercano de la imagen de partida), y por la sencillez de su implementación (Dogson, 1992). Se crearon 7 imágenes, 3 para Campo1 y 4 para Campo2.

A las RS-Is se les realizó una evaluación visual y matemática de la calidad espacial y espectral. La fiabilidad posicional (calidad espacial) fue estimada mediante un test de la *American Society of Photogrammetry and Remote Sensing* (ASPRS, 1990). Dicho test establece tres categorías de calidad acorde al Error Medio Cuadrático (RMSE, de las siglas en inglés *Root-Mean-Square Error*) siendo clase 1 la más precisa, con un valor máximo de 1,25cm, y las restantes categorías dos y tres veces menos exactas. El RMSE en este caso corresponde a la diferencia en las coordenadas entre las RS-Is y UAV-Is de 20 puntos de muestreo seleccionados. Los valores espectrales se compararon mediante histogramas para comprobar que no se habían modificado los niveles digitales de los píxeles.

Detección de malas hierbas

Como primer paso, se delimitó el área a estudiar con el fin de comparar superficies iguales. A las RS-Is y UAV-Is se les aplicó un algoritmo OBIA para la detección de rodales de malas hierbas desarrollado en el software eCognition Developer 8.9 (Trimble GeoSpacital, Munich, Germany) y basado conceptualmente en el algoritmo OBIA diseñado para cultivo de maíz en imágenes no mosaicadas por Peña et al. (2013). Para

determinar la idoneidad de la aplicación del algoritmo OBIA en las RS-Is se compararon los resultados obtenidos con los de las UAV-Is reales tomadas en campo (mismo sensor, alturas y campo) del área infestada de malas hierbas que requería tratamientos localizados. Además, se evaluó la discriminación de mala hierba dentro de 32 marcos de 1 m² distribuidos por todo el campo. Estos marcos de muestreo fueron representativos del grado de infestación observado en cada campo. Los marcos se clasificaron visualmente en 4 categorías: 0 correspondió a la no presencia (zona libre de mala hierba), 1 a baja infestación (30-50 píxeles infestados en la UAV-I de 30m), 2 a media infestación (unos 75 píxeles) y 3 a alta infestación (más de 100 píxeles). Por otra parte, se establecieron 7 umbrales de detección en base al porcentaje de cobertura de mala hierba como regla de decisión para la aplicación de herbicidas. Desde el 0% (herbicida se aplica en el momento que la presencia es detectada) al 15% de área infestada (tratamiento si la cobertura de mala hierba es >15%) con incrementos de 2,5. Los marcos de muestreo fueron clasificados en *Tratar* o *No_tratar* en función de si el umbral era rebasado en la RS-I y la UAV-I para cada campo, altura y cámara.

RESULTADOS Y DISCUSIÓN

Evaluación de la similitud y calidad entre RS-I and UAV-I

Las resoluciones espaciales de RS-Is y UAV-Is a 60 y 100m fueron análogas debido a que el tamaño de píxel es función de la altura y sensor empleado. Los resultados del test de calidad espacial llevado a cabo entre los dos tipos de imágenes mostraron que todos los valores de RMSE obtenidos fueron menores a 1,25cm. Por lo tanto, las RS-Is creadas pertenecieron a la clase 1, la de mayor calidad según el test ASPRS. Además, los histogramas de las imágenes fueron semejantes (test de calidad espectral), indicando que la técnica de resampling elegida no modificó los valores digitales.

Detección de mala hierba: mapeo y fiabilidad

Se localizaron las líneas de cultivo con un 95% de exactitud. Este hecho no se consiguió únicamente por la buena ejecución del resampling sino por el mosaicado realizado para construir la UAV-I de 30m. Si los mosaicos no hubiesen mostrado alta calidad, las líneas de cultivo hubieran aparecido interrumpidas sin una buena georreferenciación y el proceso de clasificación se hubiese visto afectado negativamente (Gómez-Candón et al., 2014). La correcta unión y el mosaicado de las fotos es imprescindible para lograr la detección de mala hierba localizada entre las líneas de cultivo y es más complejo en escenarios agrícolas que en

otros casos debido al patrón de distribución repetitivo de las hileras de cultivo y a la carencia de elementos invariantes en las parcelas.

Como primer resultado, se obtuvo el área a tratar para ambos campos, cámaras y alturas en las RS-Is y UAV-Is. En todos los casos, excepto para RGB a 100m de altitud, en las RS-Is se tendió a detectar mayor cobertura de mala hierba y por consiguiente, el área a tratar fue mayor. Desde un punto de vista agronómico, la sobreestimación de infestación es preferible ya que los agricultores prefieren tratar más superficie, aún incluyendo zonas sin presencia, para no asumir riesgos y asegurar el control de las malas hierbas (Peña-Barragán et al., 2007). Aunque difieran ambos tipos de imagen, se consiguió un importante ahorro de herbicida frente al manejo tradicional. La discrepancia pudo deberse a la calidad de la información espectral: los píxeles de las RS-Is a 60m de altura de vuelo preservaron el valor espectral original de la UAV-I a 30m (píxel de 1,07cm para RGB y 1,6cm para TTC) frente a los píxeles de UAV-I a 60m que pudieron presentar mezcla espectral debido a su mayor tamaño (2 y 3,2cm respectivamente).

La detección de mala hierba entre RS-I y UAV-I se realizó en toda la superficie del campo (Figura 1) evaluando el porcentaje de acierto en la clasificación en los 32 marcos de muestreo en función de los umbrales establecidos.




Figura 1. Ejemplo de mapas de malas hierbas (en oscuro) en Campo1 a 60m con TTC: 1a) UAV-I; 1b) RS-I. Se muestra también la discriminación de las hileras de siembra y del suelo desnudo.

En la Tabla 1 se observan los mejores resultados en las RS-Is procedentes de UAV-Is tomadas con TTC llegando a alcanzarse 100% de acierto (misma clasificación en todos los marcos). La tendencia fue que

el porcentaje de acierto aumenta con el umbral. Se debe a que OBIA detecta mejor una mayor cobertura de mala hierba al abarcar mayor número de píxeles lo que aumenta la diferencia espectral frente al suelo. Ello se comprobó examinando los marcos por niveles de infestación. En el Campo1 se obtuvo un 100% de acierto en las categorías 2 y 3, mientras que en las otras dos se alcanzó un 70%. En el Campo 2, el 100% se logró en la categoría 3, siendo un 70% en las categorías 0, 1 y 2. Desde un punto de vista agronómico, es deseable detectar con mayor precisión las categorías correspondientes a las mayores densidades de malas hierbas (es decir, 2 y 3), y de este modo ser más efectivo en los tratamientos de control.

Tabla 1. Porcentajes de acierto en la clasificación de los marcos de muestreo (Cámara visible: RGB; Cámara multiespectral, TTC: RGB + NIR).

Campo	Sensor	Altura (m)	Umbrales			
			0	5	10	15
1	RGB	100	84	88	88	81
		60	81	100	94	97
	TTC	100	84	97	100	91
2	RGB	60	84	88	91	94
		100	63	75	88	91
	TTC	60	84	94	97	94
		100	69	91	91	94

Según la precisión de los resultados obtenidos, la metodología UAV puede beneficiarse del resampling. Por ejemplo, la aplicación de OBIA en la UAV-I de 30m tarda aproximadamente 90 minutos y para la RS-I de 100m se tarda 15 minutos (85% menos). Al ser la cartografía de los rodales de malas hierbas en la RS-I a 100m similar a la de UAV-I, se sugiere no volar a dicha altura y resamplear la UAV-I de menor altitud para evitar las posibles distorsiones por viento en altitudes altas. Además, si el rodal de malas hierbas es menor al tamaño de pixel de la UAV-I a 100m (5,4cm) se produciría una mezcla entre el suelo y la mala hierba dentro del pixel. Igualmente sería posible crear RS-I cuando un conjunto de imágenes a distintas alturas tiene que ser comprobado y ocurre alguna incidencia que no permite terminar la toma de imágenes para acabar el experimento. También se sugiere aplicar RS-I en un test preliminar donde se quieren extrapolar los resultados a áreas más extensas facilitando la toma de decisión de la realización del vuelo a mayor altitud si los resultados son satisfactorios.

CONCLUSIONES

Los resultados obtenidos muestran la idoneidad del uso del resampling-NN para optimizar las limitaciones que se presentan a lo largo de todo el proceso de obtención de mapas de mala hierba. Hasta el momento, no había sido publicada ninguna evaluación cuantitativa de la calidad de RS-I procedentes de UAV-I orto-mosaicada para detección temprana y mapeo mediante OBIA. El hecho de realizar nuestro estudio con dos cámaras y en dos campos indica que nuestros resultados son consistentes.

AGRADECIMIENTOS

Estudio financiado por el Proyecto RECUPERA2020 (Acuerdo CSIC y MINECO-Fondos FEDER). El trabajo de J. Torres-Sánchez y J.M. Peña han sido financiados por los programas FPI y Ramón y Cajal. Los autores agradecen al Duque del Infantado y Marqués de Armunia por facilitar los campos para el desarrollo de nuestra experimentación.

BIBLIOGRAFÍA

- ASPRS (1990) Accuracy standards for large scale maps. *Photogrammetric Engineering and Remote Sensing* 56, 1068-1070.
- DOGSON NA (1992) Image resampling. PhD thesis, University of Cambridge, UK.
- GÓMEZ-CANDÓN D, CASTRO AID & LÓPEZ-GRANADOS F (2014) Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. *Precision Agriculture* 15, 44-56.
- LÓPEZ-GRANADOS F (2011) Weed detection for site-specific weed management: mapping and real-time approaches. *Weed Research* 51, 1-11.
- MEIER U (1997) *Growth stages of mono- and dicotyledonous plants*. BB Monograph. Federal Biological Research Centre for Agriculture and Forestry. Available at: http://www.jki.bund.de/fileadmin/dam_uploads/_veroeff/bbch/BBCH-Skala_englisch.pdf.
- PEÑA-BARRAGÁN JM, LÓPEZ-GRANADOS F, JURADO-EXPÓSITO M & GARCÍA-TORRES L (2007) Mapping *Ridolfia segetum* patches in sunflower crop using remote sensing. *Weed Research* 47, 164-172.

PEÑA JM, TORRES-SÁNCHEZ J, CASTRO AID, 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:e77151.

TORRES-SÁNCHEZ J, LÓPEZ-GRANADOS F, CASTRO AID & PEÑA-BARRAGÁN JM (2013) Configuration and specifications of an Unmanned Aerial Vehicle (UAV) for early site specific weed management. *PLOS ONE* 8:e58210.