

Delimitación de parcelas agrícolas mediante consenso de diversas segmentaciones

Ángel García-Pedrero⁽¹⁾, Consuelo Gonzalo-Martín⁽¹⁾, Dionisio Rodríguez-Esparragón⁽²⁾ y Mario Lillo-Saavedra⁽³⁾

⁽¹⁾ Centro de Tecnología Biomédica, Universidad Politécnica de Madrid. Campus de Montegancedo, Pozuelo de Alarcón, 28223, Madrid, España. Email: am.garcia@alumnos.upm.es, consuelo.gonzalo@upm.es

⁽²⁾ Instituto de Oceanografía, y Cambio Global-IOGAG, Universidad de Las Palmas de Gran Canaria. Campus Universitario de Tafira, 35017, Las Palmas de Gran Canaria, España. Email: drodriguez@dsc.ulpgc.es

⁽³⁾ Facultad de Ingeniería Agrícola, Universidad de Concepción. Av. Vicente Méndez 595, Casilla 537, Chillán, Octava Región, Chile. Email: malillo@udec.cl

Resumen: La delimitación de parcelas agrícolas a gran escala juega un papel primordial en los estudios relacionados con el manejo y la gestión de las explotaciones agrícolas. Por ello, es necesario el diseño de métodos computacionales que realicen esta labor de forma automática, rápida y precisa. El objetivo de este trabajo es proporcionar un marco que permita la correcta delimitación de las parcelas. La metodología propuesta emplea un consenso de segmentaciones a diferentes escalas para proporcionar información acerca de los bordes más significativos correspondientes a las parcelas agrícolas presentes en una imagen de muy alta resolución espacial.

Palabras clave: segmentación de imágenes, parcelas agrícolas, imágenes de alta resolución

Delineation of agricultural parcels through consensus of diverse segmentations

Abstract: *Delineation of agricultural parcels on a large-scale plays a major role in studies related to farming management activities. For this reason, it is necessary to design computational methods to obtain fast and accurate delineations in an automatic way. The aim of this paper is to provide a framework for the correct delineation of agricultural parcels. The proposed methodology employs a consensus of image segmentations at different scales to provide information about the most significant edges corresponding to agricultural parcels in a high-resolution image.*

Keywords: *image segmentation, agricultural parcels, high-resolution images*

1. INTRODUCCIÓN

La monitorización precisa y oportuna desempeña un papel importante en el manejo y la gestión de las explotaciones agrícolas, permitiendo así una agricultura sostenible y competitiva en los mercados internacionales. Sin embargo, una de las primeras limitaciones para desarrollar esta tarea a escalas locales y/o regionales es la posibilidad de delimitar, de forma eficiente y automática, los campos de cultivo con la finalidad de trazar mapas de uso de suelo, registrar cambios en sus límites, y mantener actualizado el catastro de parcelas agrícolas, entre otras actividades.

Las imágenes de alta resolución adquiridas mediante sensores remotos proporcionan información útil para la delimitación de parcelas agrícolas. El gran reto es cómo procesar esta información en el menor tiempo y con el menor error posible. Por ello, existe la necesidad de métodos computacionales que realicen esta labor de forma automática, rápida y precisa.

En la literatura pueden encontrarse algunos trabajos al respecto, entre ellos destacan dos enfoques: 1) los basados en contornos y 2) los basados en regiones. Los primeros (p. ej., Bailly & Levavasseur, 2012) emplean algoritmos de detección de bordes para obtener los gradientes de la imagen. Sin embargo, estos métodos tienden a producir más bordes de los deseados, debido principalmente a los campos arados y al ruido de la imagen. Por otra parte, los enfoques basados en regiones

(p. ej., Torre & Radeva, 2000; Lang *et al.*, 2009) emplean métodos de segmentación para obtener las parcelas; sin embargo, los resultados obtenidos son sensibles a la variabilidad intra-predial, y a los parámetros seleccionados. Otro factor a considerar es la variabilidad en tamaños y formas de las parcelas que ocasiona que una configuración de parámetros determinada no permita delimitar correctamente todas las parcelas.

La hipótesis de este trabajo es que la combinación de diferentes resultados de segmentación permitirá reducir la sensibilidad al ruido de la imagen y a la selección de parámetros, produciendo una mejor delimitación de las parcelas de forma automática. Bajo esta hipótesis, en el presente trabajo se presenta una metodología que permite delimitar las parcelas en imágenes multiespectrales de muy alta resolución mediante el consenso de diversas segmentaciones obtenidas previamente.

2. ÁREA DE ESTUDIO Y DATOS

El área de estudio (Figura 1) corresponde a una zona de cultivos situada en la región de Valparaíso, Chile (-32,86, -70,64), de la cual está disponible para el análisis una imagen (pancromática y multiespectral) registrada el 3 de diciembre de 2011 mediante el sensor WorldView-2. La imagen cubre una superficie de 156,44 hectáreas, equivalentes a 2.088x2.088 píxeles en

la pancromática. La configuración espectral es de 4 bandas (azul, verde, rojo e infra-rojo cercano). La imagen ha sido corregida tanto radiométrica como geoméricamente.



Figura 1. Composición en color real de la zona de estudio.

3. METODOLOGÍA

La metodología propuesta tiene como base la generación de diversas segmentaciones, a partir de las cuales se busca delimitar las parcelas. Para ello, se realizan los siguientes procesos: 1) pre-proceso, 2) consenso de segmentaciones, y 3) post-proceso.

3.1. Pre-proceso

Para favorecer la segmentación y la detección de bordes de las parcelas, la imagen es fusionada mediante el algoritmo IHS (Tu *et al.*, 2001). En este método la componente de intensidad es sustituida por la información pancromática, dando como resultado una imagen con una gran calidad espacial. Posteriormente, las bandas espectrales de la imagen fusionada son sometidas a un proceso de ajuste automático de contraste. Finalmente la imagen obtenida es filtrada para reducir el ruido y facilitar la segmentación de la misma. El filtro elegido para este propósito es el *Rolling Guidance Filter* (Zhang *et al.*, 2014).

3.2. Consenso de segmentaciones

El proceso de consenso consiste en generar l segmentaciones, y entonces combinarlas mediante un esquema de votación que determina que píxeles tienden a pertenecer a una misma región y cuales forman parte de los bordes de los objetos de la imagen. Así, para cada par de píxeles adyacentes, i y j , el esquema de votación E_{ij} toma en cuenta la pertenencia de ambos a una misma región r . Entonces E_{ij} se define como:

$$E_{ij} = \sum_{k=1}^l \psi_{ij}^k \quad (1)$$

$$\psi_{ij}^k = \begin{cases} S(r_a^k, r_b^k), & i \in r_a^k, j \in r_b^k, r_a^k \neq r_b^k \\ 0, & \text{de lo contrario} \end{cases} \quad (2)$$

donde r_a^k representa la región a perteneciente a la k -ésima segmentación y $S(r_a^k, r_b^k)$ una medida de similitud entre las regiones a y b . Si i y j no pertenecen a la misma región, se considera que ambos píxeles forman

parte de un borde entre dos objetos distintos. Mientras más alto sea el valor de E_{ij} , más fuerte es la separación entre los dos objetos. Finalmente, se genera un mapa de bordes con la información del esquema de votación normalizado a un rango de 0 a 1.

La medida de similitud empleada, similar a la propuesta por Uijlings *et al.* (2013), se define como una combinación de la similitud en color y textura:

$$s(r_a^k, r_b^k) = s_{color}(r_a^k, r_b^k) + s_{textura}(r_a^k, r_b^k) \quad (3)$$

$s_{color}(r_a^k, r_b^k)$ mide la similitud en color. Para cada región r_a^k se obtiene un histograma de color usando 25 intervalos por cada banda espectral. Así se genera un histograma de color $C_a = \{c_a^1, \dots, c_a^h\}$ para cada región a con un tamaño $h=25*B$, donde B representa el número de bandas de la imagen. El histograma de color es posteriormente normalizado usando la norma L_1 . Finalmente, la similitud entre los histogramas de las regiones r_a^k y r_b^k es calculada usando el estadístico χ^2 (Rubner *et al.*, 2000):

$$s_{color}(r_a^k, r_b^k) = \sum_{i=1}^h \frac{(c_a^i - (c_a^i + c_b^i)/2)^2}{(c_a^i + c_b^i)/2} \quad (4)$$

$s_{textura}(r_a^k, r_b^k)$ mide la similitud en textura. La textura es calculada mediante filtros direccionales (Freeman & Adelson, 1991) tomando como base derivadas gaussianas en ocho direcciones y $\sigma=1$. En este caso, se genera un histograma de 10 intervalos para cada dirección de cada banda espectral. Así, se produce un histograma de textura $T_a = \{t_a^1, \dots, t_a^h\}$ para cada región a con un tamaño $h=80*B$. La similitud en textura entre los histogramas de las regiones r_a^k y r_b^k es calculada:

$$s_{textura}(r_a^k, r_b^k) = \sum_{i=1}^h \frac{(t_a^i - (t_a^i + t_b^i)/2)^2}{(t_a^i + t_b^i)/2} \quad (5)$$

En este trabajo, las segmentaciones son obtenidas mediante el algoritmo de generación de superpíxeles conocido como SLIC (Achanta *et al.*, 2012). SLIC tiene dos parámetros: n , el número de superpíxeles deseados, y c , el factor compacidad. En particular, se emplea una versión de SLIC modificada para operar con imágenes multispectrales (Fonseca-Luengo *et al.*, 2014). Las segmentaciones son generadas manteniendo fijo el valor de c ; pero variando el tamaño de los superpíxeles. Al igual que en el trabajo de Fonseca-Luengo *et al.* (2014), el número de superpíxeles empleado sigue una escala diádica.

3.3. Post-proceso

A partir del mapa de bordes y usando el método propuesto por Arbelaez *et al.* (2009), se calcula un *Ultrametric Contour Map* (UCM). Un UCM es un mapa de bordes con la notable propiedad de que produce un conjunto de curvas cerradas cuando se establece cualquier umbral (Dollár & Zitnick, 2013). Lo cual no necesariamente ocurre con un mapa de bordes normal. En otras palabras, un UCM es una representación

“suave” de una segmentación que toma en cuenta la información de los bordes de la imagen. Así, mientras más grande sea el umbral establecido mayor será el contraste de los bordes de los segmentos generados.

3.4. Evaluación de resultados

Para evaluar los resultados obtenidos al aplicar un umbral sobre el UCM, se emplea una medida de error de desplazamiento de bordes (BDE), la cual es descrita en el trabajo de Freixenet *et al.* (2012). BDE mide el error promedio de desplazamiento de los píxeles pertenecientes a los bordes (píxeles-borde) entre dos imágenes segmentadas. En particular, se define el error de un píxel-borde como la distancia entre éste y el píxel-borde más cercano en la otra imagen. Esta comparación es realizada entre las parcelas obtenidas por la metodología propuesta y las delimitadas manualmente por un experto (verdad de terreno).

4. RESULTADOS Y DISCUSIÓN

A partir de la imagen fusionada y pre-procesada, se empleó SLIC para generar 17 segmentaciones diferentes con un factor de compacidad (c) igual a $1/25$ veces el valor máximo espectral contenido en la imagen, mientras que el tamaño de superpíxeles generados va de 4 a 272.484 píxeles, siguiendo una distribución de crecimiento exponencial.

Ejemplos de las segmentaciones obtenidas, amplificadas para su mejor visualización, se muestran en la figura 2. Como puede observarse, los superpíxeles tienden a adherirse bien a los objetos de la imagen. Particularmente, mientras más pequeño es el tamaño del superpíxel mejor es su adherencia a los bordes, así como la homogeneidad de los píxeles que lo componen (ver Figura 2a). Por otra parte, en las segmentaciones con superpíxeles de mayor tamaño (Figura 2b), los segmentos son espectralmente menos homogéneos; no obstante, tienden a respetar los bordes entre regiones con un alto contraste.




Figura 2. Detalle ampliado de las segmentaciones con 17233 (a) y 439 (b) superpíxeles. En rojo, se muestran los bordes de cada segmento.

El consenso de las diferentes segmentaciones da como resultado el mapa de bordes mostrado en la figura 3. Este mapa tiene en cuenta los siguientes factores: 1) diferentes escalas de segmentación, expresadas por un tamaño diferente de superpíxeles, 2) la disimilitud espectral y de textura entre dos regiones vecinas, y finalmente, 3) la probabilidad de que un píxel sea un píxel-borde. Mientras más cercano a 1 sea el valor de un

píxel, mayor es la probabilidad de éste a pertenecer a un borde en las múltiples segmentaciones, y por consiguiente, el contraste entre las regiones separadas por él en las diferentes escalas es mayor.




Figura 3. Mapa de bordes (votación) de la escena analizada. Los tonos cercanos al azul indican los píxeles vecinos que tienden a pertenecer al mismo segmento.

El mapa de bordes obtenido (Figura 3) aporta la información para poder identificar los bordes que pertenecen a las parcelas; sin embargo, como se mencionó anteriormente, éste no garantiza completar las parcelas al aplicar un umbral, debido principalmente, a que no todos los píxeles-borde tienen el mismo valor. Así, para obtener las parcelas sería necesario el uso de algoritmos para completar los bordes. Por ello, se genera un UCM a partir del mapa de bordes. A diferencia del mapa de bordes, el UCM devuelve curvas cerradas, lo que garantiza completar las parcelas al aplicar el umbral adecuado. La figura 4 muestra el mapa de bordes (Figura 4a) y el UCM (Figura 4b) de una región ampliada de la imagen.




Figura 4. Comparación entre el mapa de bordes (a) y el Ultrametric Contour Map (b) en una región ampliada.

Se usaron diferentes valores de umbrales sobre el UCM para determinar la mejor delimitación de las parcelas. Los umbrales empleados van desde 0,05 a 0,95 con un paso de 0,05. La evaluación de la calidad (BDE) de los segmentos obtenidos se muestra en la figura 5. Como puede observarse, mientras más alto (estricto) es el umbral (0,70 – 0,95) mayor es el error registrado, debido principalmente, a que pocos bordes lo superan produciéndose una sub-segmentación de la imagen. Por el contrario, mientras menos estricto es el umbral, el error disminuye a la vez que se produce un aumento en el número de segmentos. En el marco de los umbrales probados, el mejor resultado se obtuvo con 0,45.




Figura 5. BDE de los segmentos obtenidos al aplicar cada uno de los umbrales.

En la figura 6 se muestra una comparativa entre la verdad de terreno (Figura 6a) y los bordes de la segmentos obtenidos con el umbral 0,45 (Figura 6b). Como puede observarse, la mayoría de los bordes coinciden en ambas imágenes, sobre todo en áreas homogéneas con un alto contraste entre regiones adyacentes; sin embargo, también pueden distinguirse discrepancias en parcelas con diferentes patrones de labrado, donde la aparición de bordes internos se hace presente, al igual que en parcelas en cuyo interior se perciben anomalías debido a malas prácticas agrícolas, o problemas del terreno.



Figura 6. Comparación entre los bordes de la verdad de terreno (a) y los bordes obtenidos mediante un umbral de 0,45 (b). Los bordes, en color negro, han sido engrosados mediante operaciones morfológicas para su mejor visualización.

5. CONCLUSIONES

En este trabajo se presentó una metodología para la delimitación de parcelas agrícolas, la cual emplea un consenso de segmentaciones (superpíxeles) a diferentes escalas para determinar los bordes de las parcelas. El consenso de segmentaciones disminuye el ruido de la imagen mientras que facilita la detección de bordes, reduciendo considerablemente el número de parámetros a sintonizar. Estudios preliminares muestran que un umbral alrededor de 0,45 es adecuado para delimitar correctamente las parcelas. Sin embargo, éste debe ser analizado y generalizado a un número mayor de imágenes de características similares.

6. AGRADECIMIENTOS

A. García-Pedrero agradece al Consejo Nacional de Ciencia y Tecnología (CONACYT) de México el soporte brindado a través de la beca de estudios doctorales número 216146. Este trabajo ha sido apoyado

por el proyecto ARTeMISat (CGL2013-46674-R) financiado por el Ministerio de Economía y Competitividad de España.

7. BIBLIOGRAFÍA

- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., & Süsstrunk, S. 2012. *SLIC Superpixels Compared to State-of-the-Art Superpixel Methods*. TPAMI, 34(11), 2274–2282.
- Arbelaez, P., Maire, M., Fowlkes, C., & Malik, J. 2009. *From Contours to Regions: An Empirical Evaluation*. CVPR. 2294–2301.
- Bailly, J. S., & Levavasseur, F. 2012. *Potential of linear features detection in a Mediterranean landscape from 3D VHR optical data: Application to terrace walls*. IGARSS, 7110–7113.
- Dollár, P., & Zitnick, C. L. 2013. *Structured Forests for Fast Edge Detection*. ICCV, 1841–1848.
- Fonseca-Luengo, D., García-Pedrero, A., Lillo Saavedra, M., Costumero, R., Menasalvas, E., & Gonzalo Martín, C. 2014. *Optimal Scale in a Hierarchical Segmentation Method for Satellite Images*. RSEISP, 8537 (Chapter 36), 351–358.
- Freeman, W. T. & Adelson, E. H. 1991. *The design and use of steerable filters*, TPAMI, 891–906.
- Freixenet, J., Muñoz, X., Raba, D., Martí, J., & Cufí, X. 2002. *Yet Another Survey on Image Segmentation: Region and Boundary Information Integration*. Lecture Notes in Computer Science (Vol. 2352, pp. 408–422–422). Springer Berlin Heidelberg.
- Lang, S., Schöpfer, E., & Langanke, T. 2009. *Combined object-based classification and manual interpretation--Synergies for a quantitative assessment of parcels and biotopes*. Geocarto, 24(2), 99–114.
- Rubner, Y., Tomasi, C., & Guibas, L. J. 2000. *The Earth Mover's Distance as a Metric for Image Retrieval*. IJCV, 40(2), 99–121.
- Torre, M., & Radeva, P. 2000. *Agricultural-field extraction on aerial images by region competition algorithm*. ICPR, 313–316.
- Tu, T., Su, S., Shyu, H. & Huang, P. 2001. *A new look at IHS-like image fusion methods*. Inf. Fusion, vol. 2, no. 3, 177–186.
- Uijlings, J., van de Sande, K., Gevers, T., & Smeulders, A. 2013. *Selective Search for Object Recognition*. IJCV, 104(2), 154–171.
- Zhang, Q., Shen, X., Xu, L., & Jia, J. 2014. *Rolling Guidance Filter*. ECCV, Vol. 8691, 815–830.