

Sistemas aéreos pilotados de forma remota y clasificación orientada a objetos: un acercamiento al análisis submétrico de una zona periurbana

C. Peralta-Carreta^{1,*}, J.V. Solórzano¹, A. Fernández-Montes de Oca¹, J.A. Gallardo-Cruz¹

(1) Centro del Cambio Global y la Sustentabilidad en el Sureste A.C. Calle del Centenario del Instituto Juárez, S/N, Col. Reforma, C.P. 86080, Villahermosa, Tabasco, México.

* Autor de correspondencia: J.V. Solórzano [jonathanvsv@gmail.com]

> Recibido el 29 de octubre de 2015 - Aceptado el 31 de marzo de 2016

Peralta-Carreta, C., Solórzano, J.V., Fernández-Montes de Oca, A., Gallardo-Cruz, J.A. 2016. Sistemas aéreos pilotados de forma remota y clasificación orientada a objetos: un acercamiento al análisis submétrico de una zona periurbana. *Ecosistemas* 25(1): 90-93. Doi.: 10.7818/ECOS.2016.25-1.13

Los RPAS (Sistemas Aéreos Pilotados de Forma Remota) han abierto la posibilidad de generar imágenes multiespectrales submétricas con costos relativamente bajos y de buena calidad. Al utilizar estas imágenes con metodologías de clasificación precisas, como la orientada a objetos, se deberían obtener excelentes resultados. Por ello, el objetivo de esta investigación fue evaluar el potencial de este tipo de clasificación utilizando imágenes obtenidas con un RPAS para generar un mapa temático de una escena suburbana. La clasificación resultó exitosa (fiabilidad total = 0.83) y permitió discernir trece categorías focales y una sin clasificar. Dentro de la clasificación fue posible distinguir entre cobertura urbana de diferentes alturas, cinco tipos de vegetación y cuerpos de agua.

Palabras clave: Sistemas Aéreos Pilotados de Forma Remota (RPAS); imágenes de muy alta resolución; eBee Ag; eCognition.

Peralta-Carreta, C., Solórzano, J.V., Fernández-Montes de Oca, A., Gallardo-Cruz, J.A. 2016. Remotely Piloted Aircraft Systems and Object-oriented classification: an approach into the submetric analysis of a suburban area. *Ecosistemas* 25(1): 90-93. Doi.: 10.7818/ECOS.2016.25-1.13

RPAS (Remotely Piloted Aircraft Systems) have opened the possibility to obtain submetric multispectral images with a high quality at a relative low cost. The use of this type of imagery together with precise classification methods, such as the object-oriented approach, should derive excellent results. Thus, this study aimed at evaluating the potential of this type of classification using a submetric image obtained with a RPAS to obtain a thematic map of a suburban scene. The classification was successful (total reliability = 0.83), and thirteen focal classes and one without classification were distinguished. In the classification, urban areas with different heights were discriminated, as well as five types of vegetation and water bodies.

Keywords: Remotely Piloted Aircraft Systems (RPAS); very high resolution imagery; eBee Ag; eCognition.

El uso y popularidad de los Sistemas Aéreos Pilotados de Forma Remota (RPAS) ha incrementado en los últimos años, no sólo para fines recreativos, sino para fines científicos también (Watts et al. 2012; Marris 2013; Selker et al. 2015). Los RPAS se han utilizado para estudiar mediante percepción remota diversos fenómenos, ya que permiten (Colomina y Molina 2014; Koh y Wich 2012): 1) obtener imágenes multiespectrales con resolución espacial submétrica, y 2) generar modelos tridimensionales submétricos de superficie y de terreno. Además, a mediano y largo plazo, resultan más baratos que las imágenes de satélite de muy alta resolución (el costo de un RPAS de uso no recreativo equivale al costo de entre 22 y 114 imágenes Quickbird [25 km², píxel = 60 cm]). Por el contrario, las mayores desventajas de los RPAS radica en su autonomía de vuelo y la extensión que pueden cubrir (p.ej. eBee Ag: 1000 ha / 45 min; Sensefly-Parrot Company 2013) y que sus posibles aplicaciones dependen de las características del sensor.

Gran parte de los estudios con percepción remota están enfocados en la implementación de clasificaciones digitales; para ello existen dos métodos, por píxel y orientados a objetos (COO). El pri-

mero se basa en la asignación de clases en función únicamente de la información contenida en cada píxel (Puissant et al. 2005). En contraste, la COO se basa en las características de determinados grupos de píxeles (objetos) como forma, altura y textura para asignar las clases. Este enfoque permite obtener mejores resultados con información de muy alta resolución espacial (Myint et al. 2011).

Este estudio evaluó el potencial de la COO de imágenes obtenidas desde un RPAS para el reconocimiento de diferentes tipos de cobertura en un área heterogénea. El área de estudio (303.75 ha) se ubicó en una zona suburbana de la ciudad de Villahermosa, Tabasco, México (18° 00' 57" N y 92° 57' 52" O) que presentó vegetación arborea (p.ej. *Mangifera indica*, *Tabebuia rosea*), vegetación herbácea acuática (p.ej. *Typha latifolia*, *Cyperus giganteus*) y no acuática (p.ej. *Paspalum notatum*), y diferentes tipos de coberturas urbanas (Fig. 1).

Para obtener las imágenes se utilizó un eBee Ag, el cual cuenta con una autonomía de vuelo entre 20 y 25 min. El sensor, una cámara Canon S110 NIR, cuenta con tres bandas: verde (G: $\lambda = 550$ nm), roja (R: $\lambda = 625$ nm) y la infrarroja cercana (NIR: $\lambda = 850$ nm).




Figura 1. Imagen de falso color (Infrarrojo cercano, Rojo, Verde) obtenida por el eBee Ag y la localización geográfica del sitio de estudio.

Figure 1. False composite image (Near infrared, Red, Green) captured by the eBee Ag and the geographic position of the study site.

Para cubrir el área de interés, se realizaron cuatro vuelos el 13 de julio del 2015 entre las 10:00 y 13:00 horas (buscando que el efecto de las sombras fuera mínimo) a una altura de 572 m sobre la altitud de despegue. El solapamiento lateral entre las imágenes fue del 60 % y longitudinal del 75 %. En total se obtuvieron 300 imágenes, cada una con un tamaño de píxel de 20 cm. Los programas utilizados para la planeación del vuelo y procesamiento de las imágenes fueron el eMotion 2 y Postflight Terra 3D (Sensefly-Parrot Company 2013). Tras la corrección radiométrica y geométrica de las imágenes se generó un mosaico de reflectividad ortorectificado y dos modelos digitales, uno de superficie (DSM, el cual fue utilizado para la ortocorrección) y uno de terreno (DTM). Posteriormente, se calculó el modelo digital normalizado (nDSM) mediante la fórmula: $nDSM = DSM - DTM$ (Chen et al. 2009) y el índice de vegetación de diferencia normalizada (NDVI) calculado como: $NDVI = \frac{NIR - R}{NIR + R}$. Se realizó una COO utilizando las tres bandas espectrales, el NDVI y el nDSM en eCognition Developer 8 (Definiens-Imaging 2010). Las clases se definieron a partir de características de los objetos como: pertenencia a un polígono georreferenciado de humedales (conocimiento previo), forma, reflectividad, altura, distancia entre clases, valores máximos de píxeles contenidos en los objetos y características del borde de los objetos. Se generaron 21 009 601 objetos, mediante una segmentación de multiresolución, los cuales se clasificaron en 13 categorías: cinco clases de vegetación (tres humedales con diferente tipo de cobertura o régimen de inundación, arbolado y pastizal), dos de agua (río y lago), tres de infraestructura (edificaciones con distintas alturas), dos de tipo de suelo (pavimento o suelo desnudo) y sombras. Para la identificación de las diferentes clases de humedal se realizó una verificación en campo. En el proceso se definieron las clases de acuerdo a reglas dicotómicas de pertenencia. Los objetos no categorizados se definieron como "no clasificado".

La fiabilidad de la clasificación se evaluó mediante 324 puntos aleatorios. Esta cifra se alcanzó al incrementar gradualmente el número de muestras hasta que todas las clases de interés estuvieran representadas por al menos cinco puntos. Debido a la pequeña superficie de las clases suelo desnudo y sombras, éstas no pudieron ser evaluadas con este método. Para la mayoría de las clases, la verificación se realizó mediante el módulo de *Street view*, Google Earth (Google Inc. 2009). En él se consultaron las fotos a nivel de calle para contar el número de pisos de las construcciones, utilizando la coordenada geográfica y objetos de referencia para ubicarlos (p. ej. intersecciones de calles, presencia de cochera). Se construyó una matriz de confusión para evaluar los errores de comisión y omisión por categoría (Hay 1988).

En la Figura 2 se muestra que sólo el 0.39 % del área no pudo ser clasificada. La clase con mayor extensión fue la de pastizal con un 31.23 % del área total, mientras que la de menor superficie correspondió a sombras (esencialmente provocadas por nubes) con un 0.09 % (Tabla 1). La fiabilidad de la clasificación fue alta (0.84), ya que los errores de omisión y comisión se encontraron entre el 0 % y 35.29 % (Tabla 2). Sin embargo, cabe resaltar que hubo mayor fiabilidad en las clases menos específicas (p.ej. clases de agua) que en las más (p. ej. casas de uno, dos, tres o mas pisos; Tabla 2).

Se concluye que: 1) la COO con información espectral y de elevación submétrica permite distinguir categorías de uso de suelo y vegetación con una precisión alta, e incluso diferenciar entre estructuras urbanas con alturas distintas; 2) los RPAS permiten generar información submétrica de altura y reflectancia con mayor facilidad y economía en comparación con otras alternativas satelitales. Aunque el uso de la COO y los RPAS es reciente, su potencial en aplicaciones sociales y ambientales comienza a ser evidente (d'Oleire-Oltmanns et al. 2012; Immerzeel et al. 2014).




Figura 2. Clasificación de una escena suburbana de la ciudad de Villahermosa, Tabasco. Se muestran en color negro los puntos utilizados para calcular la fiabilidad de la clasificación.

Figure 2. Classification of a suburban scene of Villahermosa, Tabasco. Black dots indicate reference points used to estimate classification accuracy.

Tabla 1. Superficie (ha) y porcentaje del área total de las clases obtenidas mediante una clasificación orientada a objetos de una escena suburbana.

Table 1. Surface area (ha) and total area percentage of the classes obtained with an object-oriented classification of a suburban scene.

Clase	ha	%
<i>Agua</i>		
Ríos	3.55	1.17
Lagos	1.75	0.58
<i>Cobertura urbana</i>		
Casas 1 piso (altura ≤ 3.5 m)	24.99	8.23
Casas 2 pisos (altura > 3.5 m y altura ≤ 7 m)	29.00	9.55
Casas 3 pisos y edificios (altura > 7 m)	9.92	3.27
Pavimento	56.15	18.48
<i>Vegetación</i>		
Arbolado	48.03	15.81
Pastizal	94.87	31.23
<i>Humedal</i>		
Tular en cuerpo de agua permanente	7.06	2.32
Tular en cuerpo de agua estacional	16.00	5.27
Agroecosistema inundable	9.62	3.17
<i>Otros</i>		
Suelo desnudo	1.33	0.44
Sombras	0.29	0.09
No clasificado	1.17	0.39

Tabla 2. Evaluación de la fiabilidad de la clasificación orientada a objetos, utilizando puntos aleatorios.**Table 2.** Accuracy assessment of the object-oriented classification, using the random points.

Categorías reales	Categorías predichas															Total	Error Omisión
	Ríos	Lagos	No Clasificado	Arbolado	Pastizal	Suelo desnudo	Agroecosistema inundable	Pavimento	Casas 1 piso	Casas 2 pisos	Casas 3 pisos y edificios	Sombra	Tular en cuerpo de agua estacional	Tular en cuerpo de agua permanente			
	Ríos	11	0	0	0	0	0	0	0	0	0	0	0	0	0	11	0.00
	Lagos	0	7	0	0	0	0	0	0	0	0	0	0	0	0	7	0.00
	No Clasificado	0	0	0	0	2	0	0	0	0	0	0	0	0	0	2	1.00
	Arbolado	0	0	0	37	9	0	0	0	0	0	0	0	0	0	46	0.20
	Pastizal	0	0	0	6	66	0	0	1	0	0	0	0	0	0	73	0.01
	Suelo desnudo	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	n/d
	Agroecosistema inundable	0	0	0	1	0	0	15	0	0	0	0	0	0	0	16	0.06
	Pavimento	1	0	1	0	1	2	0	57	6	1	0	1	0	0	70	0.19
	Casas 1 piso	0	1	0	0	1	0	0	3	11	1	0	0	0	0	17	0.35
	Casas 2 pisos	0	0	0	0	1	0	0	3	0	12	0	0	0	0	16	0.25
	Casas 3 pisos y edificios	0	0	0	0	0	0	0	2	0	4	12	0	0	0	18	0.33
	Sombra	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	n/d
	Tular en cuerpo de agua estacional	0	0	0	1	4	0	0	0	0	0	0	0	33	0	38	0.13
	Tular en cuerpo de agua permanente	0	0	0	0	0	0	0	0	0	0	0	0	0	10	10	0.00
	Total	12	8	1	45	84	2	15	66	17	18	12	1	33	10	324	
	Error Omisión	0.08	0.13	1.00	0.18	0.21	n/d	0.00	0.14	0.35	0.33	0.00	n/d	0.00	0.00		
	Fiabilidad total																0.84
	n/d: Clase que no fue evaluada																Estadístico kappa

Referencias

- Chen, Y., Su, W., Li, J., Sun, Z. 2009. Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas. *Advances in Space Research* 43(7):1101-10.
- Colomina, I., Molina, P. 2014. Unmanned Aerial Systems for photogrammetry and remote sensing: A Review. *International Society for Photogrammetry and Remote Sensing Journal of Photogrammetry and Remote Sensing* 92:79-97.
- d'Oleire-Oltmanns, S., Marzloff, I., Peter, D.K., Ries, J.B. 2012. Unmanned Aerial Vehicle (UAV) for monitoring soil erosion in Morocco. *Remote Sensing* 4(11): 3390-3416.
- Definiens-Imaging 2010. eCognition Software. Munich: Definiens-Imaging. [consultado agosto 2015]. Disponible en: <http://www.ecognition.com/>.
- Google Inc. 2009. Google Earth. Mountain View: Google Inc. [consultado septiembre 2015]. Disponible en: <https://www.google.com/earth/>.
- Immerzeel, W.W., Kraaijenbrink, P.D.A., Shea, J.M., Shrestha, A.B., Pellicciotti, F., Bierkens, M.F.P., de Jong, S.M. 2014. High-resolution monitoring of Himalayan glacier dynamics using unmanned aerial vehicles. *Remote Sensing of Environment* 150:93-103.
- Hay, A.M. 1988. The derivation of global estimates from a confusion matrix. *International Journal of Remote Sensing* 9(8):1395-1398.
- Koh, L.P., Wich, S.A. 2012. Dawn of drone ecology: low-cost autonomous aerial vehicles for conservation. *Tropical Conservation Science* 5(2):121-132.
- Marris, E. 2013. Fly and bring me data. *Nature* 498:156-58.
- Myint, S.W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q. 2011. Per-pixel vs object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment* 115:1145-1161.
- Puissant, A., Hirsch, J., Weber, C. 2005. The utility of texture analysis to improve Per-pixel Classification for high to very high spatial resolution imagery. *International Journal of Remote Sensing* 26(4):733-45.
- Selker, J., Tyler, S., Higgins, C. Wing, M.G. 2015. Drone squadron to take Earth monitoring to new heights. *Eos* 96:1-7.
- Sensefly-Parrot Company. 2013. *eBee Ag*. senseFly Ltd., Cheseaux-Lausanne, Suiza.
- Watts, A.C., Ambrosia, V.G. Hinkley, E.A. 2012. Unmanned Aircraft Systems in remote sensing and scientific research: classification and considerations of use. *Remote Sensing* 4(6):1671-92.