

DetECCIÓN REMOTA DE INVERNADEROS A PARTIR DE ESTÉREO PARES DEL SATÉLITE WORLDVIEW-2

Aguilar, M.A.*¹, Montalbán, M.A.¹, Saldaña, M.M.¹, Aguilar, F.J.¹, Fernández, I.¹, García-Lorca, A.M.²

¹ Departamento de Ingeniería, Universidad de Almería, Ctra. Sacramento s/n, La Cañada (Almería), 04120, España.

² Departamento de Geografía, Historia y Humanidades, Universidad de Almería, La Cañada (Almería), 04120, España

Resumen: El lanzamiento de los primeros satélites comerciales de muy alta resolución (*Very High Resolution*; VHR) capaces de capturar imágenes pancromáticas de la superficie terrestre con un tamaño de píxel de 1 m e incluso menor (e.g. IKONOS en 1999 y QuickBird en 2001), marcó el comienzo de una nueva era en teledetección. El 4 de enero de 2010 se empezaron a comercializar imágenes de WorldView-2. Posiblemente WorldView-2 sea en la actualidad el satélite comercial más sofisticado que orbita sobre la Tierra y la explotación de sus datos supone un verdadero desafío para investigadores de todo el mundo. Por otra parte, la práctica de la agricultura bajo plástico ha tenido un gran desarrollo en el área Mediterránea durante los últimos 60 años, especialmente en Almería, suponiendo un motor económico fundamental en la zona. El objetivo de este trabajo es la detección de invernaderos aplicando técnicas de análisis de imágenes basadas en objetos (OBIA). La información de base consistirá en una ortoimagen fusionada y datos de elevaciones de objetos, ambos productos obtenidos a partir de un estéreo par de imágenes del satélite WorldView-2. Los resultados obtenidos indican que el uso de las ocho bandas multiespectrales, junto a la inclusión de un modelo normalizado de elevaciones mejoran las precisiones en la clasificación de invernaderos, pudiéndose obtener precisiones globales superiores al 90%.

Palabras clave: WorldView-2, OBIA, Modelo Digital de Superficies, Modelo Digital de Elevaciones, clasificación de invernaderos.

Remote sensing for greenhouse detection from stereo pairs of WorldView-2 satellite

Abstract: The successful launch of the first very high resolution (VHR) satellites capable of capturing panchromatic imagery of the land surface with ground sample distance even lower than 1 m (e.g. IKONOS in 1999 or QuickBird in 2001) marked the beginning of a wholly new age in remote sensing. On January 4, 2010, images of WorldView-2 were placed on the market. Possibly it is the most sophisticated commercial VHR satellite currently orbiting the Earth and the exploitation of its data poses a challenge to researchers worldwide. Moreover, the practice of under plastic agriculture had a great development in the Mediterranean area during the past 60 years, especially in Almeria, acting as a key economic driver in the area. The goal of this work is the automatic greenhouse mapping by using Object Based Image Analysis (OBIA). The required input data will be a pan-sharpened orthoimage and a normalized digital surface model (nDSM) for objects, both products generated from a WorldView-2 stereo pair. The attained results show that the very high resolution 8-band multispectral and the nDSM data improve the greenhouses automatic detection. In this way, overall accuracies higher than 90% can be achieved.

Key words: WorldView-2, OBIA, Digital Surface Model, Digital Elevation Model, greenhouse classification.

* Autor para la correspondencia: maguilar@ual.es

1. Introducción

El lanzamiento de IKONOS en septiembre de 1999, el primer satélite óptico comercial con una resolución geométrica inferior a 1 m en la banda pancromática (PAN), supuso el comienzo de una nueva generación de satélites comerciales clasificados como de muy alta resolución (*Very High Resolution*; VHR). Actualmente existe más de una docena de este tipo de satélites orbitando sobre la superficie terrestre, entre los que destacan la constelación de satélites VHR de DigitalGlobe formada por WorldView-2, WorldView-1, GeoEye-1, IKONOS y QuickBird.

En estos últimos años y en el marco del Proyecto del Plan Nacional de Investigación con referencia CTM2010-16573/TECNO, se han demostrado las capacidades de las imágenes de GeoEye-1 y WorldView-2 para generar productos georreferenciados de precisión, como son ortoimágenes pancromáticas (PAN) y *pan-sharpened* (Aguilar et al., 2013a), Modelos Digitales de Superficies, DSMs (Aguilar et al., 2014), o mapas de usos de suelos en ambientes urbanos mediante técnicas de análisis de imágenes basada en objetos, OBIA (Aguilar et al., 2013b).

Por otra parte, desde que a principios de los años 50 los primeros invernaderos de plástico fueron aplicados en agricultura de una manera importante, el área cubierta por estas estructuras ha ido creciendo a un ritmo rapidísimo (Espí et al., 2006). El norte de África, Oriente Medio y China están multiplicando su superficie de invernaderos con tasas anuales del 15-30%, mientras que Europa (principalmente España, Italia y Francia) presenta también un continuo incremento, aunque con tasas mucho menores. Actualmente, hay alrededor de 1.600.000 ha de invernaderos y macro túneles en el mundo (Espí et al., 2006). La práctica de la agricultura bajo plástico, también conocida como plasticultura, es parte de la transformación de la agricultura tradicional en una agricultura mucho más industrial, tecnificada y de precisión (Levin et al., 2007). Según datos del Anuario de Estadística del Ministerio de Medioambiente y Medio Rural y Marino de 2009, España posee alrededor de 52.723 ha de invernaderos, de las que aproximadamente 27.000 ha se encuentran en Almería. Más importante si cabe que el dato de superficie invernada, es el hecho de que ocupando únicamente el

0,2% de la superficie agraria útil en España, los cultivos protegidos consiguen aportar alrededor del 15% de la producción final agrícola española. Este sistema productivo intensivo está registrando también un rápido incremento de la superficie de cultivos protegidos cultivada en Marruecos, pasando de 11.000 ha en 1999 (FAO, 2002) a 17.000 ha en 2006 (Torrens, 2006). Estas superficies protegidas están principalmente dedicadas al cultivo de tomate y están compitiendo duramente con el producto español producido principalmente en Almería.

Es de sobra conocido que este tipo de cultivo intensivo y altamente industrializado está ligado a un importante impacto antrópico (Parra et al., 2008). De hecho, la construcción de invernaderos junto con la infraestructura necesaria para su explotación comercial (e.g., red de caminos y carreteras, edificios de almacenaje, red eléctrica, red de riego y balsas de riego) contribuyen de manera notable a la modificación del entorno (Arcidiacono y Porto, 2010). Por eso, un cuidadoso planeamiento del desarrollo territorial en estas áreas agrícolas es vital para minimizar el impacto medio ambiental (Agüera et al., 2008; Arcidiacono y Porto, 2010; Picuno et al., 2011).

El objetivo fundamental de este trabajo es la detección automática y remota de invernaderos a partir de imágenes de satélites comerciales VHR y mediante técnicas OBIA. Se pretende estudiar el nivel de precisión y calidad alcanzables en la clasificación de los distintos tipos de invernaderos existentes en una zona piloto, a partir de una ortoimagen fusionada (*pan-sharpened*) de WorldView-2 y un modelo digital de elevaciones de objetos sobre el terreno (*normalized Digital Surface Model*; nDSM). Ambos productos se obtienen a partir del procesamiento de un estéreo par de WorldView-2.

2. Zona de estudio y datos de partida

2.1. Zona de estudio

El estudio se realiza en la zona comprendida entre el pueblo de Palomares y el río Almanzora (centrada en las coordenadas UTM 30N ETRS89 607781 E, 4122675 N), situada en el levante de la provincia de Almería con una superficie total aproximada de 125 ha (Figura 1). Dentro de esta zona de estudio se han recabado los datos georreferenciados que a continuación se detallan.

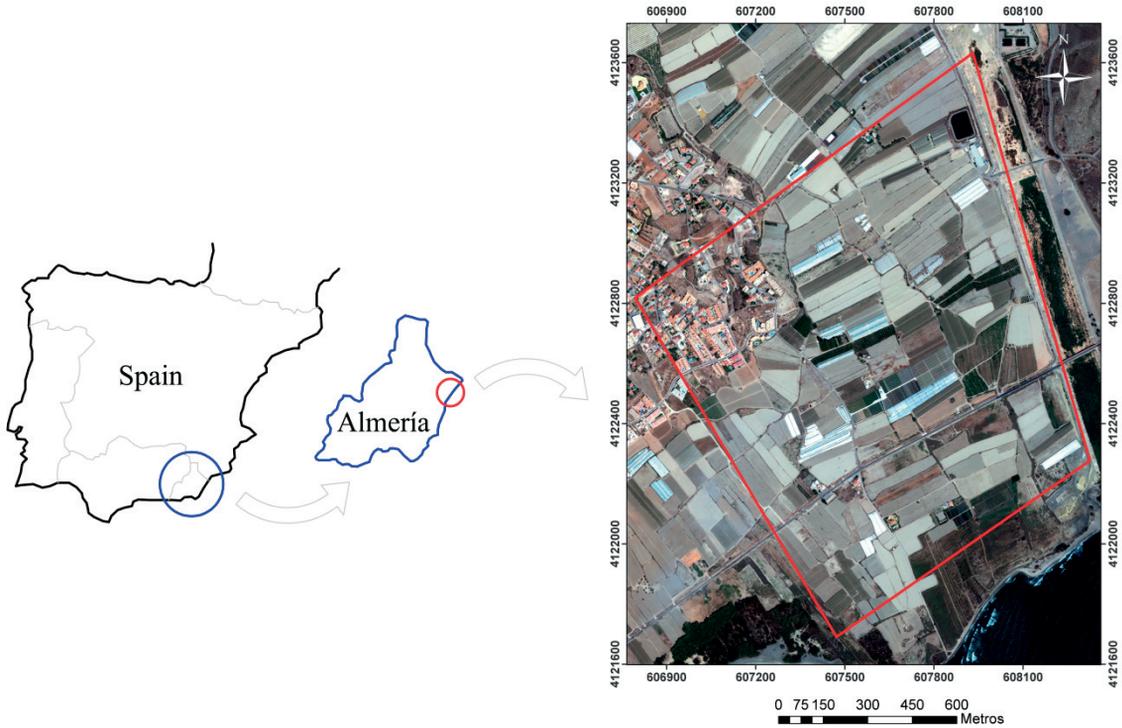


Figura 1. Zona de estudio superpuesta sobre la ortoimagen pan-sharpened de WorldView-2 (composición RGB). Sistema de coordenadas ETRS89 UTM zona 30N.

2.2. Datos georreferenciados de partida

El 4 de enero de 2010, se comenzaron a comercializar imágenes del satélite comercial VHR más sofisticado que actualmente orbita sobre la tierra. Se trata de WorldView-2 (DigitalGlobe, Inc.), que es actualmente el único satélite VHR cuya imagen multispectral (MS) está compuesta por 8 bandas: *coastal*: C (400-450 nm), *blue*: B (450-510 nm), *green*: G (510-580 nm), *yellow*: Y (585-625 nm), *red*: R (630-690 nm), *red edge*: RE (705-745 nm), *near infrared-1*: NIR1 (760-895 nm) y *near infrared-2*: NIR2 (860-1040 nm). Todos los productos georreferenciados empleados en este trabajo fueron obtenidos a partir de un estéreo par de imágenes del satélite World-View-2, incluyendo datos de los sensores PAN y MS con 8 bandas. El estéreo par fue tomado el 18 de agosto de 2011 en formato *Ortho Ready Standard* (ORS2A). Las imágenes obtenidas estaban remuestreadas a 0,5 m y 2 m en modo PAN y MS respectivamente. Las características de las imágenes que componen dicho estéreo par se muestran en la Tabla 1. Los productos extraídos del estéreo par de WorldView-2 se detallan a continuación.

Tabla 1. Características de las imágenes PAN y MS que forman el estéreo par de WorldView-2 (ORS2A) adquiridas en el lugar de estudio.

Imagen ID	WV2-1	WV2-2
Sensor	WV2	WV2
Producto	ORS2A	Basic
Fecha de adquisición	18/8/2011	18/8/2011
Hora de adquisición (GMT)	11:23	11:22
Cobertura de nubes	0%	0%
Dirección de escaneado	Reverse	Forward
Azimut solar	152,8°	152,3°
Elevación solar	63,8°	63,7°
Elevación del satélite	80,0°	67,7°
Azimut del satélite	216,3°	4,8°
Tamaño de píxel (PAN)	0,5 m	0,5 m
Tamaño de píxel (MS)	2 m	2 m
Bits por píxel	11	11

- (i) Ortoimagen fusionada o *pan-sharpened* de WorldView-2 (Figura 1). Se trata de una ortoimagen fusionada (PAN + MS) con 0,5 m de resolución (*Ground Sample Distance*, GSD) y 8 bandas. Para la generación de la imagen

fusionada se empleó el algoritmo PANSHARP del programa Geomatica v. 2012 (PCI Geomatics, Richmond Hill, Ontario, Canada). La ortoimagen se generó usando 7 puntos de control, funciones racionales de grado cero y el Modelo Digital de Elevaciones (DEM) de la Junta de Andalucía (Aguilar et al., 2013a).

- (ii) Modelo Digital de Superficies (*Digital Surface Model*; DSM). Se generó a partir del estéreo par PAN de WorldView-2. Se trata de un DSM con 1 m de paso de malla, generado en OrthoEngine, el módulo fotogramétrico de Geomatica v. 2012 (más detalles en Aguilar et al. 2014).
- (iii) nDSM. Tras el relleno de huecos automático del DSM obtenido en el paso anterior, se generó un DEM mediante el algoritmo DSMsDEM de Geomatica v. 2012. El algoritmo DSMsDEM filtra todo el relieve (i.e., edificios, árboles, etc.) sobre el terreno original. Finalmente el nDSM se obtiene por sustracción del DEM al DSM (Figura 2a). El nDSM tiene un paso de malla de 1 m. Podemos observar como la

mayoría de invernaderos de la zona de estudio (Figura 2b) aparecen con cierta elevación en el nDSM (i.e., en color blanco).

- (iv) Generación del archivo vectorial de referencia (*Ground Truth*) considerando: ortoimágenes aéreas y de satélite, información catastral, DEMs, DSMs, y demás información geoespacial disponible en la zona. Con todos estos datos se generó un archivo vectorial que contenía los 52 invernaderos comprendidos en la zona piloto (Figura 2b). Estos resultados agrupados en diferentes tipologías: tipo malla, plástico blanqueado, plástico sin blanquear. Además se intentó diferenciar si los distintos invernaderos estaban cultivados o no en base a los cambios provocados en la reflectancia de los invernaderos por los cultivos o suelo desnudo situado bajo la cubierta semitransparente. En este sentido los invernaderos cultivados presentaban un índice NDVI mayor que los no cultivados. Algunos invernaderos abandonados o en construcción fueron agrupados en la clase

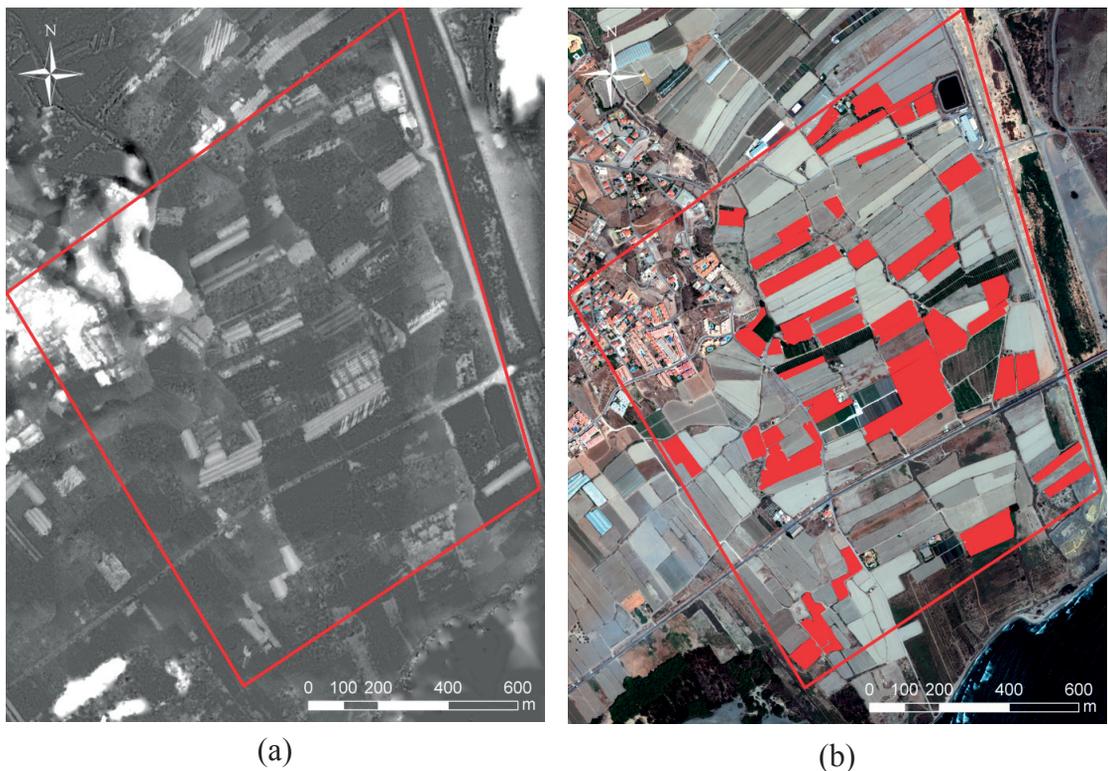


Figura 2. a) nDSM extraído sobre la zona de estudio. b) invernaderos existentes en la zona piloto resaltados en rojo sobre la ortoimagen de WorldView-2.

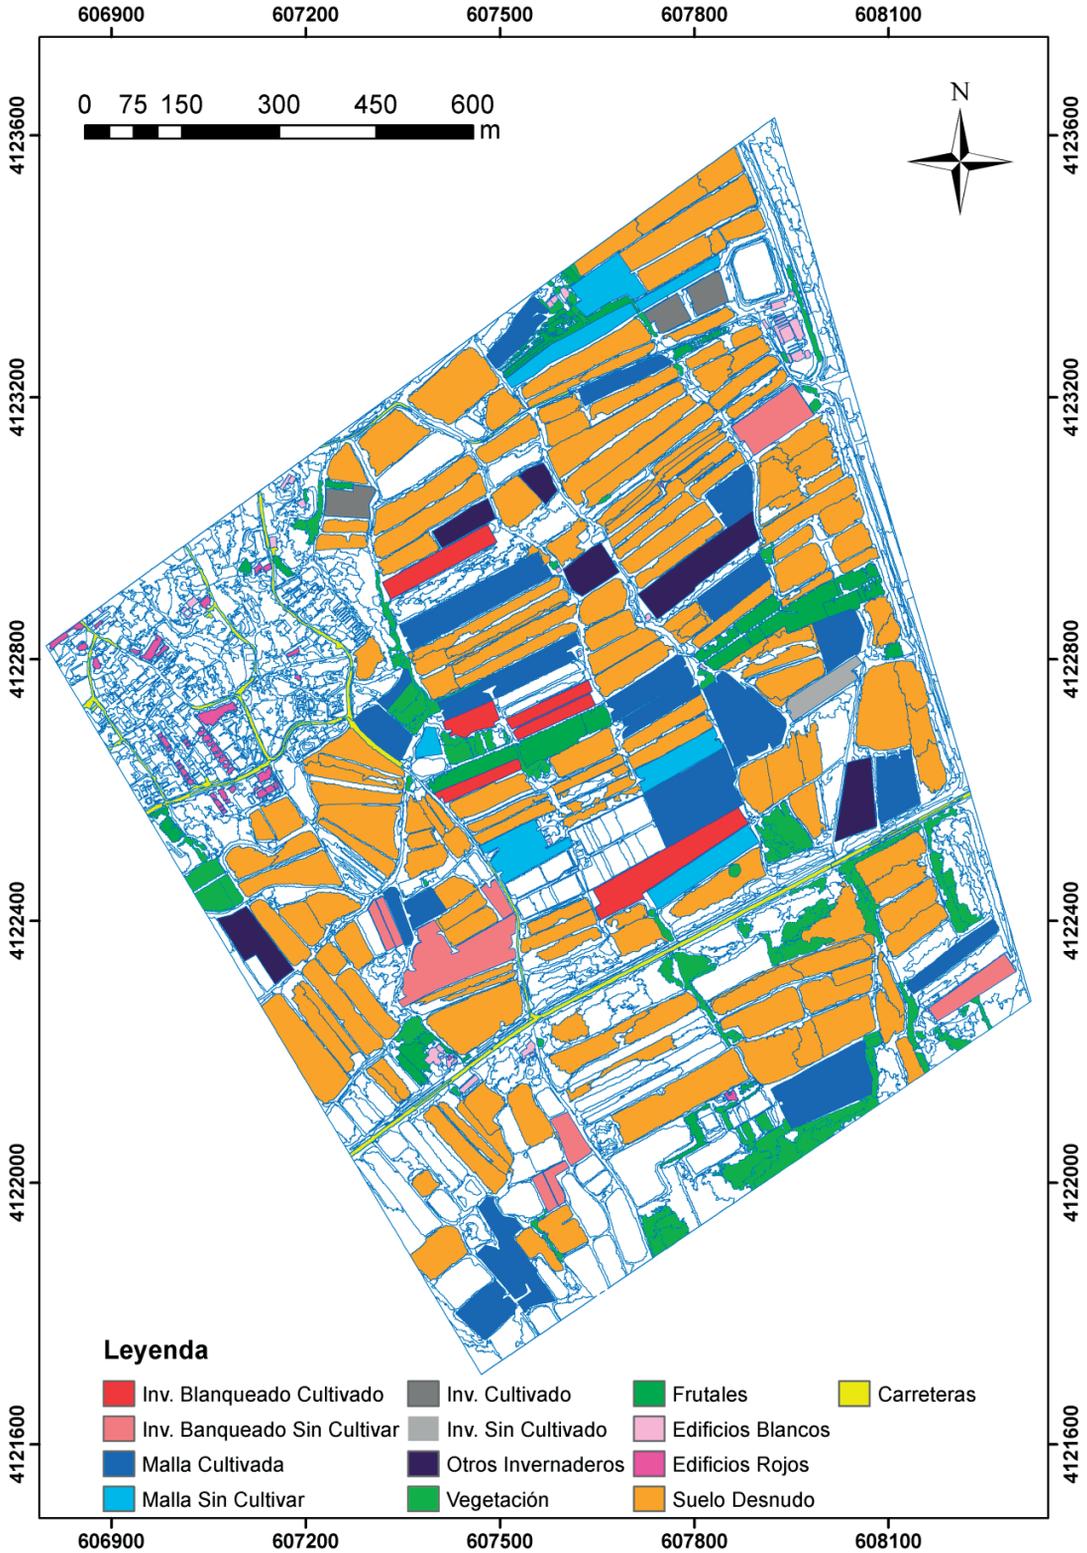


Figura 3. Clasificación manual de los objetos generados en la segmentación Óptima y asignación a las clases objetivo (Mapa de Referencia o *Ground Truth*). Sistema de coordenadas ETRS89 UTM zona 30N.

Otros Invernaderos. Como podemos observar en la Figura 3, además de las 7 clases consideradas para los distintos tipos de invernaderos (i.e., Invernadero Blanqueado Cultivado, Invernadero Blanqueado Sin Cultivar, Malla Cultivada, Malla Sin Cultivar, Invernaderos Cultivado, Invernadero Sin Cultivar y Otros Invernaderos), otras 6 clases fueron incluidas en la clasificación (i.e., Vegetación, Frutales, Edificios Blancos, Edificios Rojos, Suelo Desnudo y Carreteras).

5. Metodología

5.1. Segmentación

El primer paso en una clasificación OBIA es la segmentación o creación de los objetos que posteriormente serán clasificados. En este trabajo se han generado dos segmentaciones diferentes.

La primera de ellas se generó a partir de la ortoimagen *pan-sharpened* de WorldView-2 y el nDSM, empleando el algoritmo de segmentación *multiresolution* implementado en eCognition. En este caso se usó una escala de 200, un factor de forma de 0,3 y un valor de *Compactness* de 0,5.

A las 8 bandas de la ortoimagen y a la capa de información correspondiente al nDSM, le fueron asignados pesos iguales. En esta segmentación, a la que llamaremos Multi-resolución, se generaron 743 objetos de interés (IOs). Un ejemplo de esta segmentación puede verse en la Figura 4a.

La segunda segmentación, a la que denominaremos segmentación Óptima (Figura 3), tuvo el objetivo de respetar fielmente la digitalización manual del contorno de los 52 invernaderos presentes en la zona de estudio. Esto se consiguió realizando una primera segmentación *chessboard* usando el archivo vectorial en formato *shape* con los 52 invernaderos como capa temática. Tras esta segmentación previa que contenía 53 IOs (52 invernaderos y un objeto que contenía el resto del territorio), se realizó una segmentación *multiresolution* al nivel de los objetos obtenidos previamente. En este segundo paso se utilizaron los mismos datos de partida que en el caso de la segmentación Multi-resolución, aunque sólo sobre el IO con un tamaño superior a 400.000 píxeles. Con esto, nos aseguramos que los 52 invernaderos iniciales quedan intactos, y sólo se segmentará el objeto que engloba el resto de la zona de estudio. Se procedió

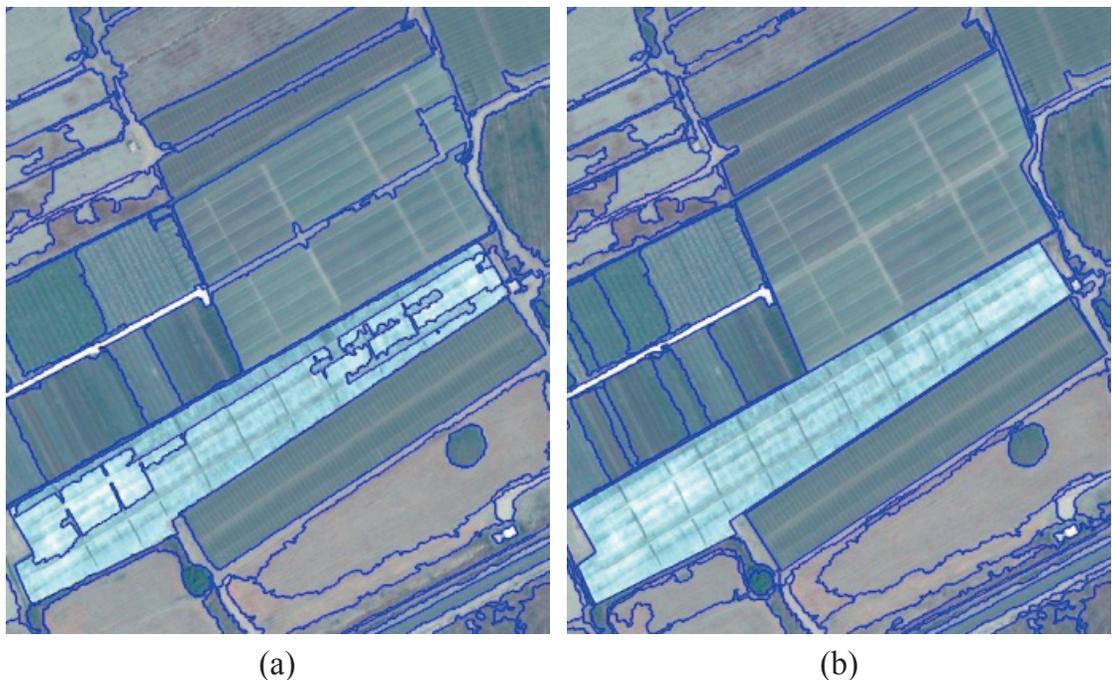


Figura 4. a) Detalle de la segmentación Multi-resolución. b) Segmentación Óptima.

de forma similar al caso anterior y 2.137 IOs fueron generados. En la Figura 4b se puede observar un detalle de la segmentación Óptima, y puede ser comparada con la segmentación Multi-resolución (Figura 4a).

5.2. Mapa de referencia

Un total de 445 de los 2.137 IOs segmentados en el caso de la segmentación Óptima fueron visualmente clasificados y asignados a una de las 13 clases objetivo usadas en este trabajo (Figura 3). Un total de 6 Invernaderos Blanqueados Cultivados, 9 Invernaderos Blanqueados Sin Cultivar, 20 Mallas Cultivadas, 7 Mallas Sin Cultivar, 3 Invernaderos Cultivados, 1 Invernadero Sin Cultivar, 6 Otros Invernaderos, 100 Vegetación, 33 Frutales, 41 Edificios Blancos, 24 Edificios Rojos, 174 Suelo Desnudo y 21 Carreteras, constituyeron este mapa de referencia.

5.3. Clasificación supervisada

El clasificador supervisado *Nearest Neighbor* (NN) implementado en eCognition, fue el que se

empleó en este trabajo. Para identificar el conjunto de características que presentaba una mayor distancia o separabilidad entre las distintas clases, se empleó la herramienta de optimización del espacio de características (*Features Space Optimization*, FSO) incluida en eCognition. El conjunto inicial incluía 42 características: 6 índices de vegetación (ver Oumar y Mutanga, 2013), 10 valores medios, 9 desviaciones estándar (Std), 9 ratios a escena y 8 características geométricas.

De entre todas estas características, 9 fueron detectadas mediante FSO como la combinación ideal. Estas fueron: *Carotenoid reflectance index* (CRI), *Vogelmann red edge 1* (VOGRE), Mean Blue, Std nDSM, Std Red, Ratio nDSM, Ratio NIR1, Área y Densidad.

Un subconjunto formado por 53 muestras o IOs pertenecientes al Mapa de Referencia (variando entre 1 y 8 IOs por cada una de las 13 clases objetivo) fue usado para entrenar al clasificador supervisado basándonos en el espacio de 9 características definido anteriormente.

Tabla 2. Características seleccionadas mediante FSO para llevar a cabo la clasificación.

No.	Característica	Descripción
1	Mean Blue	Media de los valores digitales de los píxeles incluidos en objetos para la banda <i>Blue</i> de la ortoimagen <i>pan-sharpened</i> .
2	Std Red	Desviación estándar de los valores digitales de los píxeles incluidos en objetos para la banda <i>Red</i> de la ortoimagen <i>pan-sharpened</i> .
3	Ratio NIR1	Ratio de la media de los valores digitales de los píxeles que forman un objeto para la banda NIR1 de la ortoimagen <i>pan-sharpened</i> con respecto a la media de los valores digitales para esa banda en toda la escena.
4	Std nDSM	Desviación estándar de los valores digitales de los píxeles (elevaciones) incluidos en objetos del nDSM.
5	Ratio nDSM	Ratio de la media de los valores digitales de los píxeles que forman un objeto para la capa de elevaciones del nDSM con respecto a la media de los valores digitales para esa capa en toda la escena.
6	CRI	Índice de reflectancia de los carotenoides: $(1/Band\ Green) - (1/Band\ Red\ Edge)$; Gitelson <i>et al.</i> (2002)
7	VOGRE	Vogelmann borde rojo 1: $Band\ Red\ Edge / Band\ Red$; Vogelmann <i>et al.</i> (1993)
8	Área	Superficie del objeto.
9	Densidad	Número de píxeles que forman el objeto de imagen dividida por su radio aproximado, basado en la matriz de covarianza.

5.4. Precisión de la clasificación

Los índices de precisión de la clasificación usados en este trabajo estuvieron basados en la matriz de error (Congalton, 1991). Se realizaron dos ensayos de clasificación, uno de ellos sobre la segmentación Óptima y el segundo sobre la segmentación Multi-resolución. Las clases Edificios Blancos y Rojos fueron finalmente agrupadas en una única clase denominada Edificios. De igual forma, las clases Mallas Cultivadas y Sin Cultivar fueron incluidas en la clase Mallas. Por último, las clases Vegetación y Frutales también fueron fusionadas en la clase Vegetación Total. Así la precisión del usuario (*User's accuracy*, UA), la del productor (*Producer's accuracy*, PA), el índice Kappa por clase (KIA) y la precisión global (*Overall accuracy*, OA) fueron los índices de precisión calculados a partir de la matriz de confusión.

6. Resultados

En la Tabla 3 se presentan los resultados de precisión (UA, PA, KIA por clase y OA) obtenidos a partir de las dos segmentaciones ensayadas. Para la segmentación Óptima, se obtuvieron unos excelentes resultados. La OA alcanzada fue del 92,36%, casi 2 puntos mejor que la encontrada en un trabajo similar realizado por Tarantino y Figorito (2012). En este último trabajo, los autores utilizaron ortomárgenes aéreas RGB con 0,20 m de resolución geométrica para detectar invernaderos de viñas

mediante técnicas OBIA (eCognition), aunque sin utilizar datos de elevaciones (nDSM). Cabe destacar que cuando la segmentación Óptima fue usada, todas las clases relativas a invernaderos presentaron un KIA del 100%. La información altimétrica, que ya se ha mostrado muy valiosa en ambientes urbanos (Aguilar et al., 2013b), también lo es para la detección de invernaderos. De hecho, en el nDSM mostrado en la Figura 2a, el lector puede adivinar claramente la situación de los invernaderos en la zona de estudio. Cuando llevamos a cabo la clasificación sobre la segmentación Óptima suprimiendo la información del nDSM (i.e., eliminando las dos características derivadas del nDSM, Std nDSM y Ratio nDSM, de las nueve inicialmente seleccionadas mediante FSO) la OA bajó hasta un 73,45%.

Cuando la segmentación de los invernaderos no fue asistida por una digitalización previa (archivo formato *shape* con invernaderos), los resultados de precisión de la clasificación bajaron a un 84,37% en términos de OA (Tabla 3). En este caso, la existencia de IOs de pequeño tamaño que formaban parte de un mismo invernadero (Figura 4a) causados por una segmentación excesiva (*oversegmentation*), provocaron una pérdida de precisión en la clasificación final.

Algunos errores en determinados IOs fueron detectados en el nDSM (e.g. carreteras elevadas, suelo desnudo con cotas medias de 1,5 m, etc.). Estos fallos del nDSM fueron debidos principalmente a que el DEM generado mediante el algoritmo

Tabla 3. Precisiones expresadas en tantos por ciento resultantes de la clasificación realizada sobre las segmentaciones Óptima y Multi-resolución.

Clases	Segmentación Óptima			Segmentación Multi-resolución		
	UA	PA	KIA	UA	PA	KIA
Inv. Blanqueados Cultivados	100	100	100	60	80	78,3
Inv. Blanqueados Sin Cultivar	81,8	100	100	87,1	81,8	79,3
Inv. Cultivados	100	100	100	50	100	100
Inv. Sin Cultivar	100	100	100	50	100	100
Otros Inv.	85,7	100	100	54,5	75	72,6
Suelo Desnudo	99,4	95,9	93,5	94,8	92,9	88,6
Carreteras	72,4	100	100	-	0	0
Vegetación Total	100	81,9	76,1	96,67	82,9	80,58
Edificios	98,4	95,4	94,6	100	81,2	80,25
Mallas	56,25	100	100	82,35	82,3	79,65
OA		92,36			84,37	

DSM2DEM de Geomatica v. 2012 no funcionó idealmente. Esto fue debido a la dificultad de fijar para este algoritmo un parámetro de embaldosado (*horizontal tile size*) óptimo para toda la zona de estudio. Este parámetro fija el tamaño del área cuadrada utilizada para encontrar la elevación mínima local y está relacionado con el tamaño de los objetos que se desean eliminar del DSM original. Dado que el tamaño de estos objetos era muy variable (desde pequeños edificios y masas arbóreas hasta grandes invernaderos), el resultado del algoritmo de filtrado podría ser mejorable. Por otro lado, el DSM generado a partir del estéreo par de WorldView-2 tuvo unas precisiones verticales en términos de desviación estándar en la zona de trabajo de 1,75 m, variado desde 2,74 m en zonas urbanas a 0,53 m en zonas abiertas (Aguilar *et al.*, 2014). El algoritmo de extracción automática del DSM de OrthoEngine funcionó muy bien sobre invernaderos de plástico, aunque tuvo muchas dificultades para detectar las elevaciones de los invernaderos tipo malla.

7. Conclusiones

Los resultados obtenidos en este trabajo indican que la inclusión de un modelo digital de objetos de calidad (nDSM) puede mejorar las precisiones en la clasificación de invernaderos obtenida a partir de ortoimágenes de satélites VHR. La posibilidad de obtener datos de entrada precisos (i.e. ortoimagen y nDSM) a partir de imágenes de satélites comerciales VHR sin necesidad de mediciones de campo previas, hace de la metodología propuesta una buena opción para la detección totalmente remota de invernaderos en zonas conflictivas. Resulta también interesante la diferenciación alcanzada en la clasificación, llegando a detectar invernaderos cultivados y sin cultivar. Existen sin embargo dos claras líneas de mejora de la metodología expuesta. Por un lado, la segmentación ha demostrado ser un punto crítico en los resultados finales de precisión de la clasificación. Por tanto, hay que seguir trabajando en la obtención de una segmentación automática y de calidad sobre zonas agrícolas de invernaderos. La segunda línea de investigación para mejorar la metodología propuesta radica en la obtención de un nDSM de mayor precisión, bien usando nuevos y más poderosos algoritmos de correlación automática (*matching*), o bien mejorando el paso de DSM a DEM mediante filtrado del relieve sobre el terreno natural. También cabe la posibilidad de combinar

datos de imágenes de satélite con datos LiDAR para mejorar los resultados en la clasificación de invernaderos. Sin embargo, estos datos altimétricos de alta precisión son bastante caros de adquirir.

Agradecimientos

Este trabajo se ha desarrollado en el marco de los Proyecto del Plan Nacional de Investigación con referencias CTM2010-16573 y AGL2013-42603-R, financiados por el Ministerio de Ciencia e Innovación del Gobierno de España y con fondos FEDER. El trabajo ha sido también cofinanciado mediante fondos FEDER a través del Programa de Cooperación Transfronteriza España-Fronteras Exteriores, POCTEFEX 2008-2013 (referencia 0065_COPTRUST_3_E). Los autores agradecen el apoyo de la Junta de Andalucía a través del Proyecto de Excelencia RNM-3575 y al Campus de Excelencia Internacional Agroalimentario ceiA3 (<http://www.ceia3.es/>).

Referencias

- Agüera, F., Aguilar, F.J., Aguilar, M.A., 2008. Using texture analysis to improve per-pixel classification of very high resolution images for mapping plastic greenhouses. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(6), 635-646. doi:10.1016/j.isprsjprs.2008.03.003
- Aguilar, M.A., Saldaña, M.M., Aguilar, F.J., 2013a. Assessing geometric accuracy of the orthorectification process from GeoEye-1 and WorldView-2 panchromatic images. *International Journal of Applied Earth Observation and Geoinformation*, 21, 427-435. doi:10.1016/j.jag.2012.06.004
- Aguilar, M.A., Saldaña, M.M., Aguilar, F.J., 2013b. GeoEye-1 and WorldView-2 pan-sharpened imagery for object-based classification in urban environments. *International Journal of Remote Sensing*, 34(7), 2583-2606. doi:10.1080/01431161.2012.747018
- Aguilar, M.A., Saldaña, M.M., Aguilar, F.J., 2014. Generation and Quality Assessment of Stereo-Extracted DSM from GeoEye-1 and WorldView-2 Imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 52(2), 1259-1271. doi:10.1109/TGRS.2013.2249521
- Arcidiacono, C., Porto, S.M.C., 2010. A model to manage crop-shelter spatial development by multi-temporal coverage analysis and spatial indicators. *Biosystems Engineering*, 107(2), 107-122. doi:10.1016/j.biosystemseng.2010.07.007

- Congalton, R.G., 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46. doi:10.1016/0034-4257(91)90048-B
- Espí, E., Salmerón, A., Fontecha, A., García, Y., Real, A.I., 2006. Plastic films for agricultural applications. *Journal of Plastic Film and Sheeting*, 22(2), 85-102. doi:10.1177/8756087906064220
- FAO, 2002. El cultivo protegido en clima mediterráneo. Estudio FAO Producción y Protección Vegetal 90, Organización de las Naciones Unidas para la Agricultura y la Alimentación, Roma.
- Gitelson, A., Zur, Y., Chivkunova, O., Merzlyak, M., 2002. Assessing carotenoid content in plant leaves with reflectance spectroscopy. *Photochemistry and Photobiology*, 75(3), 272-281. doi:10.1562/0031-8655(2002)0750272ACCIPL2.0.CO2
- Levin, N., Lugassi, R., Ramon, U., Braun, O., Ben-Dor, E., 2007. Remote sensing as a tool for monitoring plasticulture in agricultural landscapes. *International Journal of Remote Sensing*, 28(1), 183-202. doi:10.1080/01431160600658156
- Oumar, Z., Mutanga, O., 2013. Using WorldView-2 bands and indices to predict bronze bug (*Thaumastocoris peregrinus*) damage in plantation forests. *International Journal of Remote Sensing*, 34(6), 2236-2249. doi:10.1080/01431161.2012.743694
- Parra, S., Aguilar, F.J., Calatrava, J., 2008. Decision modelling for environmental protection: the contingent valuation method applied to greenhouse waste management. *Biosystems Engineering*, 99(4), 469-477. doi:10.1016/j.biosystemseng.2007.11.016
- Picuno, P., Tortora, A., Capobianco, R.L., 2011. Analysis of plasticulture landscapes in Southern Italy through remote sensing and solid modelling techniques. *Landscape and Urban Planning*, 100(1-2), 45-56. doi:10.1016/j.landurbplan.2010.11.008
- Tarantino, E., Figorito, B., 2012. Mapping Rural Areas with Widespread Plastic Covered Vineyards Using True Color Aerial Data. *Remote Sensing*, 4(7), 1913-1928. doi:10.3390/rs4071913
- Torrens, M., 2006. El sector de Invernaderos en Marruecos. Instituto Español de Comercio Exterior (ICEX). Nota Sectorial, 15 pp.
- Vogelmann, J.E., Rock, B.N., Moss, D.M., 1993. Red edge spectral measurements from sugar maple leaves. *International Journal of Remote Sensing*, 14(8), 1563-1575. doi:10.1080/01431169308953986