

Trabajo Fin de Máster

Calidad de la Segmentación y precisión de la Clasificación en Teledetección Orientada a Objetos. Caso de los invernaderos de Almería

María Carmen
VICENTE MARTIN

Curso | 2015-2016
Convocatoria | Septiembre

Director/es:

Manuel Ángel AGUILAR TORRES

Fernando José AGUILAR TORRES

Resumen. La última generación de satélites comerciales de muy alta resolución (VHR) abre nuevas posibilidades para las aplicaciones cartográficas y de teledetección. De esta manera, la aproximación del análisis de imágenes basada en objetos (OBIA) se ha demostrado como la mejor opción cuando se trabaja con imágenes de satélite VHR. OBIA considera atributos espectrales, geométricos, de textura y topológicos asociados a objetos de imágenes significativas. El primer paso de OBIA, conocido como segmentación, es delinear los objetos de interés. La determinación de una segmentación óptima es crucial para el éxito de la segunda etapa en OBIA, la clasificación. El objetivo principal de este trabajo es evaluar el algoritmo de segmentación de multi-resolución incluido en eCognition para delinear invernaderos a través de ortoimágenes multispectrales de WorldView-2, y encontrar la relación entre la bondad de la segmentación y la exactitud de la clasificación supervisada a través de clasificador del Vecino más Próximo (Nearest Neighbour). En concreto, la atención se centra en la búsqueda de los parámetros óptimos de la segmentación multi-resolución (Escala, Forma y Compacidad) para invernaderos de plástico. La evaluación de la calidad de la segmentación basada en las discrepancias entre los polígonos de referencia y los segmentos de imagen correspondientes se llevó a cabo para identificar la configuración óptima de los parámetros de la segmentación multi-resolución. Se utilizaron tres índices de discrepancia: Potencial de error de segmentación (PSE), Relación de número de segmentos (NSR) y Distancia Euclídea 2 (ED2). Por último, hemos demostrado que existe una clara relación entre la bondad de la segmentación en los invernaderos de plástico y la precisión de la clasificación OBIA alcanzada cuando se utilizaron las características como los índices espectrales, texturales y de vegetación. La mejor precisión global alcanzada con la mejor segmentación fue ligeramente superior al 95%.

Palabras clave. Teledetección orientada a objetos (OBIA), WorldView-2, Invernaderos, Segmentación, Clasificación supervisada, Vecino más próximo, Multi-resolución.



Abstract. The latest breed of very high resolution (VHR) commercial satellites opens new possibilities for cartographic and remote sensing applications. In this way, object based image analysis (OBIA) approach has been proved as the best option when working with VHR satellite imagery. OBIA considers spectral, geometric, textural and topological attributes associated with meaningful image objects. Thus, the first step of OBIA, referred to as segmentation, is to delineate objects of interest. Determination of an optimal segmentation is crucial for a good performance of the second stage in OBIA, the classification process. The main goal of this work is to assess the multiresolution segmentation algorithm provided by eCognition software for delineating greenhouses from WorldView-2 multispectral orthoimages and to find the relationship between the goodness of the segmentation and the accuracy of the supervised classification through Nearest Neighbour classifier. Specifically, the focus is on finding the optimal parameters of the multiresolution segmentation approach (i.e., Scale, Shape and Compactness parameters) for plastic greenhouses. Moreover, different segmentation results were attained by using different combinations of Shape and Scale values. Assessment of segmentation quality based on the discrepancy between reference polygons and corresponding image segments was carried out to identify the optimal setting of multiresolution segmentation parameters. Three discrepancy indices were used: Potential Segmentation Error (PSE), Number-of-Segments Ratio (NSR) and Euclidean Distance 2 (ED2). Finally, we demonstrated that there was a clear relationship between the goodness of the segmentation on plastic greenhouses and the OBIA classification accuracy attained when features such as spectral, textural and vegetation indices were used. The best overall accuracy attained with the best multiresolution segmentation was slightly better than 95%.

Keywords. Object Based Image Analysis (OBIA), WorldView-2, Greenhouses, Segmentation, Supervised classification, Nearest Neighbour, Multiresolution segmentation.



AGRADECIMIENTOS

Este Trabajo Fin de Máster se ha podido llevar a cabo gracias al **Proyecto de I+D+i** con referencia **AGL2014-56017-R** del Programa Estatal de Investigación (RETOS DE LA SOCIEDAD), subvencionado por el Ministerio de Economía y Competitividad del Gobierno de España y la Unión Europea (Fondos FEDER). Agradecer también la colaboración del Campus de Excelencia Internacional Agroalimentario (ceiA3). También me gustaría agradecer el apoyo y colaboración de mis directores, por su tiempo y paciencia, sin los que este proyecto no habría podido ser terminado. Y por supuesto, agradecer también a todo el personal del Grupo de Investigación RNM-368: "Gestión integrada del territorio y tecnologías de la información espacial", especialmente Abderrahim Nemmaoui, Piotr Cichón, Malgorzata Betlej y Antonio Novelli.



INDICE

1. Introducción.....	8
2. Zona de estudio y set de datos.....	11
2.1. Zona de estudio.....	11
2.2. Imagen de satélite VHR.....	12
2.3. Verdad terreno para las clases Invernaderos y Otros.....	14
3. Metodología.....	17
3.1. Creación del proyecto con eCognition.....	17
3.2. Segmentación Multi-resolución.....	19
3.3. Clasificación OBIA.....	23
3.4. Evaluación de la segmentación.....	26
4. Resultados y discusión.....	28
4.1. Evaluación de la calidad de la segmentación.....	29
4.2. Clasificación OBIA básica.....	33
4.3. Clasificación OBIA avanzada.....	35
5. Conclusiones.....	38
6. Referencias.....	39



INDICE DE FIGURAS

Figura 1. Situación de la zona de estudio sobre una imagen Landsat 8 de Agosto de 2013. Sistema de coordenadas ETRS89 UTM Zona 30N.....	11
Figura 2. Ortoimagen MS correspondiente a la zona de estudio reducida.....	13
Figura 3. Digitalización manual sobre la ortoimagen fusionada de WV2 de la zona de estudio reducida en las clases binarias Invernaderos y Otros	15
Figura 4. Zona de estudio reducida con los 30 polígonos correspondientes a los invernaderos de referencia usados para evaluar la calidad de la segmentación.....	16
Figura 5. Extracción de objetos para muestras. Finalmente se usaron los centroides como muestras.....	16
Figura 6. Lectura de datos de la imagen MS de WV2 en eCognition.....	17
Figura 7. Creación del proyecto en eCognition.....	18
Figura 8. Algoritmo de segmentación multi-resolución de eCognition.....	19
Figura 9. Resultados de las segmentaciones realizadas con las combinaciones 3, 24, 45 y 66.....	22
Figura 10. Métodos de clasificación.....	23
Figura 11. Elección de las características empleadas en la clasificación NN. Caso de la clasificación básica con 8 valores medios por objeto.....	24
Figura 12. Definición de las muestras en el ensayo de segmentación con Escala=50, Shape=0.3 y Compactness=0.5.....	25
Figura 13. Ejemplo de matriz de confusión en eCognition.....	26
Figura 14. Ilustración de las discrepancias geométricas entre los polígonos de referencia, los candidatos y los del conjunto de segmentos correspondientes.....	27
Figura 15. Detalles de los resultados de la segmentación multi-resolución (polígonos verdes) para diferentes combinaciones de parámetros. Los parámetros de Escala y Compactness se mantuvieron constantes en valores de 50 y 0.5 respectivamente, mientras que el factor de forma (Shape) tomó valores de 0.1, 0.3, 0.5, 0.7 y 0.9. Invernaderos de referencia en rojo.....	30
Figura 16. Representación del índice PSE (discrepancias geométricas) frente a la escala elegida y para los tres valores de Shape. El parámetro Compactness se mantuvo fijo en 0.5.....	31
Figura 17. Representación del índice NSR (discrepancias aritméticas) frente a la escala elegida y para los tres valores de Shape. El parámetro Compactness se mantuvo fijo en 0.5.....	31



Figura 18. Representación de ED2 como métrica descriptora de la bondad de la segmentación frente a la escala elegida y para los tres valores de Shape. Compactness constante en 0.5.....**32**

Figura 19. Detalle de los valores mínimos de ED2 frente al rango óptimo de escalas.....**33**

Figura 20. Valores de precisión global (Overall Accuracy, OA) en tantos por uno para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA básica.....**34**

Figura 21. Valores del coeficiente Kappa para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA básica.....**35**

Figura 22. Valores de precisión global (Overall Accuracy, OA) en tantos por uno para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA avanzada.....**36**

Figura 23. Valores del coeficiente Kappa para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA avanzada.....**36**

Figura 24. Comparación entre: a) el ground truth digitalizado en la zona de trabajo (TTA Mask) y, b) el resultado de la clasificación OBIA avanzada con una segmentación multi-resolución con escala de 50, Shape de 0.3 y Compactness de 0.5. En rojo la clase Invernaderos y en verde la clase Otros.....**37**

INDICE DE TABLAS

Tabla 1. Combinación de bandas para visualización.....**18**

Tabla 2. Combinaciones de parámetros.....**21**

Tabla 3. Valores de NSR, PSE y ED2 para las combinaciones mostradas en la Figura 9...**29**



1. Introducción.

Sin lugar a dudas, es prioritario para cualquier entidad empresarial conocer la situación existente y en *tiempo real* de sus homónimos dentro de su sector, de tal forma, que llega a determinar el curso de su trayectoria profesional. Esto valdría tanto para cualquier actividad profesional, como para la Agricultura. Al fin y al cabo hace mucho que dejó de ser un mero medio de subsistencia y se convirtió en una actividad de gran importancia estratégica con base fundamental en el desarrollo autosuficiente, y por ende, tributo de riqueza para las naciones más desarrolladas.

Partiendo de esta base, ¿qué podría suponer para el desarrollo agrario de una sociedad tener el conocimiento de que es lo que existe en el Mercado?. La agricultura es un proceso cíclico. Cada cultivo obedece a una estación, unas pautas y procesos que siguen siempre una misma línea. Es decir, se conoce el periodo de inicio y fin de un cultivo y en que determinada época del año se desarrolla, así como las condiciones externas (clima, terreno, ...) que permiten su idoneidad.

Si se pudiese conocer que áreas o parcelas concretas están o no cultivadas en cualquier parte del mundo, se podría también estar cerca de saber, a su vez, que se está cultivando, gracias al proceso estacional y cíclico de los cultivos. Pero tener que desplazarnos a todas y cada una de estas áreas es absolutamente inviable.

En este contexto es necesario tener en cuenta la existencia de la última generación de imágenes de satélites comerciales de muy alta resolución (Very High Resolution, VHR) que ha sido lanzada con éxito en estos últimos años (e.g., GeoEye-1, WorldView-2 y WorldView-3). Las imágenes de satélite VHR están siendo intensamente utilizadas para detección y clasificación de diferentes usos o coberturas de suelo (land use/land cover). La mayoría de estos trabajos fueron realizados utilizando técnicas de análisis de imágenes basado en objetos o teledetección orientada a objetos (Object Based Image Analysis, OBIA) (e.g., Carleer y Wolff, 2006; Stumpf y Kerle, 2011; Pu *et al.*, 2011; Pu y Landry, 2012; Aguilar *et al.*, 2013; Fernández *et al.*, 2014; Heenkenda *et al.*, 2015).

El análisis de imágenes OBIA ha sido definido en teledetección como una subdisciplina de la ciencia de la información geográfica (GIScience) dedicada a



desarrollar métodos automáticos para dividir imágenes en objetos significativos (Hay et al., 2008). Un proyecto de clasificación OBIA se compone siempre de dos etapas: **Segmentación**, formación de objetos mediante la unión de píxeles, y **Clasificación**, utilizando las características de los objetos generados previamente.

Las herramientas de Segmentación y Clasificación proporcionan un enfoque para extraer entidades de imágenes basadas en objetos. Estos objetos se crean mediante un proceso de segmentación de imágenes en el que aquellos píxeles que están cerca y que tienen características espectrales similares se agrupan en un segmento. Si la segmentación es adecuada, los objetos extraídos de la imagen mediante segmentación representarán elementos del mundo real (e.g, árboles, edificios, balsas, parcelas agrícolas, invernaderos,...). Una vez obtenida la segmentación óptima de nuestra fuente de información (imagen) con respecto al tipo de objetos que pretendemos extraer o reconocer en la imagen, se pasa a la fase de clasificación. Mediante esta fase, y usando algoritmos de clasificación basados en características intrínsecas de cada objeto segmentado, estos pueden ser agrupados en clases que representan entidades del mundo real sobre el terreno.

Dicho esto, se ha de tener en cuenta que una de las cuestiones más importantes en los análisis de clasificación de imágenes OBIA es la correcta segmentación de la imagen. De hecho, la calidad de la segmentación influirá directamente en las precisiones obtenidas posteriormente en la fase de clasificación (Liu y Xia, 2010). La segmentación de imágenes se remonta a la década de los años 70. Las primeras aplicaciones de los métodos de segmentación se aplican en áreas de procesamiento de imágenes de carácter industrial y médico, y no se utilizan ampliamente en teledetección espacial hasta los años 1980 y 1990 (Blaschke, 2010). Entre los algoritmos de segmentación destaca la segmentación multi-resolución (*Multiresolution Segmentation*, algoritmo basado en el crecimiento de regiones), consiste en la agrupación de píxeles a partir de un conjunto de semillas distribuidas por la imagen en función de un criterio previo. Es uno de los más utilizados en OBIA y está implementado en el software *eCognition Developer* (Lucieer, 2004, Benz et al., 2004). Los detalles del algoritmo se pueden consultar en Baatz et al., (2000).

El algoritmo de segmentación multi-resolución, en un procedimiento de optimización que, para un determinado número de objetos o segmentos, minimiza la heterogeneidad media y maximiza su respectiva homogeneidad. El resultado de este algoritmo de segmentación es controlado por tres términos principales, tales como: (i)



el criterio de homogeneidad o parámetro de escala, el cual determina la heterogeneidad máxima permitida de los objetos imagen resultantes (Escala), (ii) el peso del color y los criterios de forma en el proceso de segmentación (Shape), (iii) el peso de la compacidad (Compactness) y los criterios de suavizado (i.e. cuanto mayor sea el peso de la compacidad, los objetos serán más compactos). La determinación óptima de estos tres parámetros, algo abstractos por otra parte, no es ni mucho menos trivial. Normalmente es necesaria una validación de los posibles errores sistemáticos mediante una inspección visual de la calidad de los objetos resultantes de la segmentación (i.e. ensayo y error) para establecer el valor apropiado de dichos parámetros (Mathieu *et al.*, 2007; Tian y Chen, 2007). Por otra parte, los parámetros de configuración óptimos dependen de los objetos que queremos segmentar (e.g. Tian y Chen, 2007).

Para ayudar al usuario con la selección "objetiva" de los parámetros que dominan el algoritmo de segmentación multi-resolución, recientemente se han propuesto métodos no supervisados basados en la varianza local como las herramienta ESP y ESP2 (Estimation of Scale Parameters tool) publicadas por Dragut *et al.* (2010) y Dragut *et al.* (2014) respectivamente. También se han propuesto métodos supervisados basados en la medida de la similitud existente entre los resultados de la segmentación automática y los objetos ideales generalmente digitalizados manualmente por el usuario (e.g., Clinton *et al.*, 2010; Liu *et al.*, 2012). De todos los parámetros que controlan el comportamiento de este algoritmo, el conocido como **parámetro de escala** es el más importante. De forma muy sintetizada se puede definir como el parámetro que controla el tamaño de los objetos, ya que funciona como umbral a la hora de permitir o no la fusión de dos objetos contiguos. Parámetros de escala bajos suelen producir objetos muy pequeños y con escasa variabilidad espectral; por el contrario, parámetros de escala altos producen objetos de mayor tamaño en los que la variabilidad espectral de los píxeles que los forman es mucho mayor.

La digitalización o extracción automática de invernaderos a partir de teledetección presenta un gran desafío para los investigadores debido a las características tan específicas y únicas de estas estructuras agrícolas. El primer trabajo publicado que usó técnicas OBIA en invernaderos (concretamente eCognition y segmentación multi-resolución) fue realizado por Tarantino y Figorito (2012), usando una ortoimagen aérea en formato RGB en Italia. La segmentación óptima (300, 0.5 y 0.8 para Escala, Shape y Compactness respectively) fueron obtenidas aplicando técnicas de ensayo y error. En otros trabajos más recientes de detección de invernaderos usando imágenes de satélite (Aguilar *et al.*, 2014; Aguilar *et al.*, 2015) la segmentación se realizó de forma manual, evitando tener que encontrar los parámetros óptimos en la fase de segmentación.



Este trabajo se centra en la fase de segmentación de invernaderos de plástico en entornos OBIA, intentando estimar los parámetros óptimos (i.e., Escala, Shape y Compactness) del algoritmo de segmentación multi-resolución incluido en eCognition a partir de una ortoimagen multispectral del satélite WorldView-2. Se intentará también relacionar la bondad de la segmentación con la precisión en la fase posterior de clasificación.

2. Zona de estudio y set de datos.

2.1. Zona de estudio.

El trabajo fue realizado en el poniente almeriense, en el lugar del mundo con mayor concentración de invernaderos conocido como “Mar de Plástico”. La zona de estudio comprende un área rectangular de 8000 ha (8 km x 10 km) centrado en coordenadas geográficas WGS84 36.7824°N y 2.6867°W (Figura 1). Comprende parte de los Términos Municipales de Vicar, El Ejido, Roquetas de Mar y La Mojonera, siendo una zona principalmente de uso agrícola, presentando parcelas con y sin invernaderos, además de algunos núcleos de población.

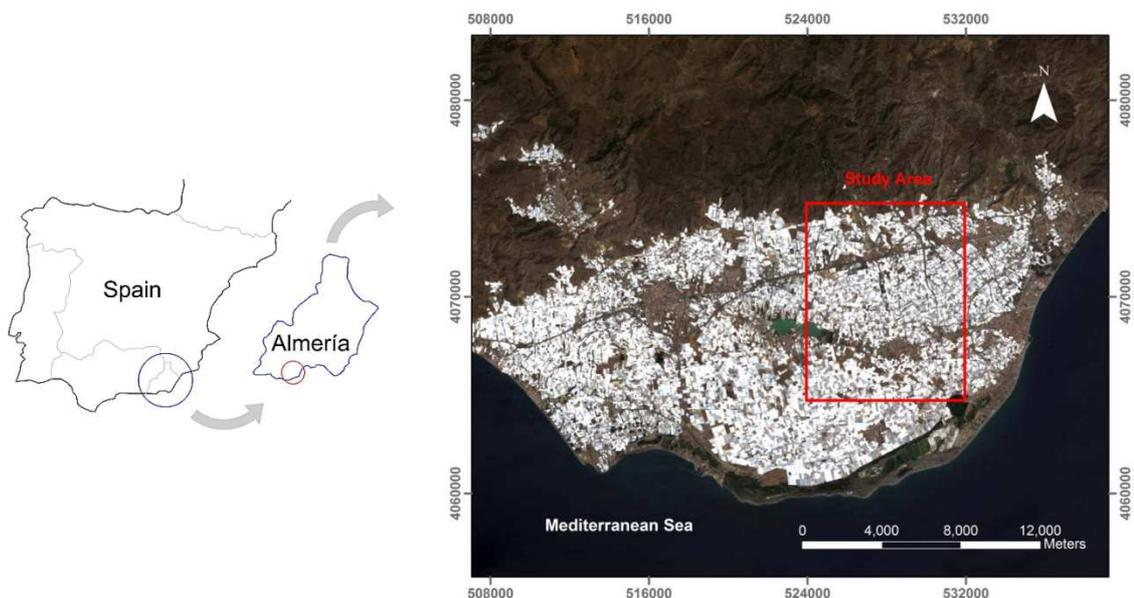


Figura 1. Situación de la zona de estudio sobre una imagen Landsat 8 de Agosto de 2013. Sistema de coordenadas ETRS89 UTM Zone 30N.

2.2. Imagen de satélite VHR.

WorldView-2 (WV2) es un satélite VHR lanzado en Octubre de 2009. Este sensor es capaz de adquirir imágenes ópticas de la superficie terrestre con un tamaño de píxel o Ground Sample Distance (GSD) de 0.46 m y 1.84 m en su posición más nadiral en modo pancromático (PAN) y multiespectral (MS) respectivamente. Este satélite fue el primer sensor comercial en captar 8 bandas en su imagen MS. Estas bandas son: 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).

Una imagen de WV2, tomada el 30 de Septiembre de 2013 sobre la zona de estudio, fue usada para este Trabajo Fin de Máster. Fue recibida en formato Ortho Ready Standard Level-2A (ORS2A), conteniendo las imágenes PAN y MS. Esta imagen de satélite presentó un ángulo off-nadir de 11.8° y un 0% de nubes. El tamaño de píxel de las imágenes PAN y MS fueron de 0.4 m y 1.6 m. El formato ORS2A de WV2 presenta correcciones radiométricas y geométricas, y ya está georreferenciada respecto a una proyección cartográfica. Incluye los correspondientes datos de coeficientes racionales para poder reproducir el modelo de cámara. El producto empleado tenía un rango dinámico de 11 bit.

A partir de las imágenes PAN y MS se obtuvo una imagen pansharpened o fusionada con 0.4 m GSD y conteniendo todas las bandas RGB de la imagen MS. Para tal fin se utilizó el módulo PANSHARP del software Geomatica v. 2014 (PCI Geomatics, Richmond Hill, Canada). Para obtener las ortoimágenes finales se emplearon las coordenadas de 7 puntos de control de campo (ground control points, GCPs) y 32 puntos de comprobación independientes (independent check points, ICPs) que fueron obtenidas mediante GPS diferencial (GPS Topcon HiPer PRO station) trabajando en modo RTK. Estos puntos de campo fueron medidos con referencia al datum European Terrestrial Reference System 1989 (ETRS89) y con proyección UTM Zona 30. Una ortoimagen fusionada con tres bandas (RGB) y con 0.4 m GSD fue generada usando funciones racionales refinadas de grado cero y un modelo digital de elevaciones (MDE) con 10 m de resolución espacial y 1.34 m de error vertical de la Junta de Andalucía. La precisión planimétrica medida como error cuadrático medio (root mean square error, RMSE) en los 32 ICPs de esta ortoimagen resultó ser de 0.59 m.

Por otra parte, se generó también una ortoimagen MS con 1.6 m GSD con las 8 bandas originales de WV2. Se usaron los mismos 7 GCPs, el mismo modelo de sensor y MDE empleados para la obtención de la ortoimagen pansharpened o fusionada. Esta



ortoimagen fue la empelada para los ensayos de clasificación OBIA realizados en este Trabajo Fin de Máster. Por ello se la imagen MS de WV2 original fue corregida atmosféricamente decidió aplicarle usando el módulo ATCOR (atmospheric correction) incluido en Geomatica v. 2014. Mediante esta corrección atmosférica absoluta transformamos los valores digitales a valores de reflectancia de la superficie terrestre. Finalmente, una ortoimagen MS de WV2 corregida atmosféricamente con un error planimétrico de 2.20 m fue generada.

Debido al alto coste computacional necesario para llevar a cabo todas las repeticiones y combinaciones previstas en este estudio, se decidió tomar un recorte de las ortoimágenes fusionada y MS de WV2. En el caso de la ortoimagen MS esta área de trabajo se limitó a 2000 x 2000 píxeles, por tanto, el tamaño aproximado de la imagen en unidades terreno es de 3200 m x 3200 m (Figura 2).

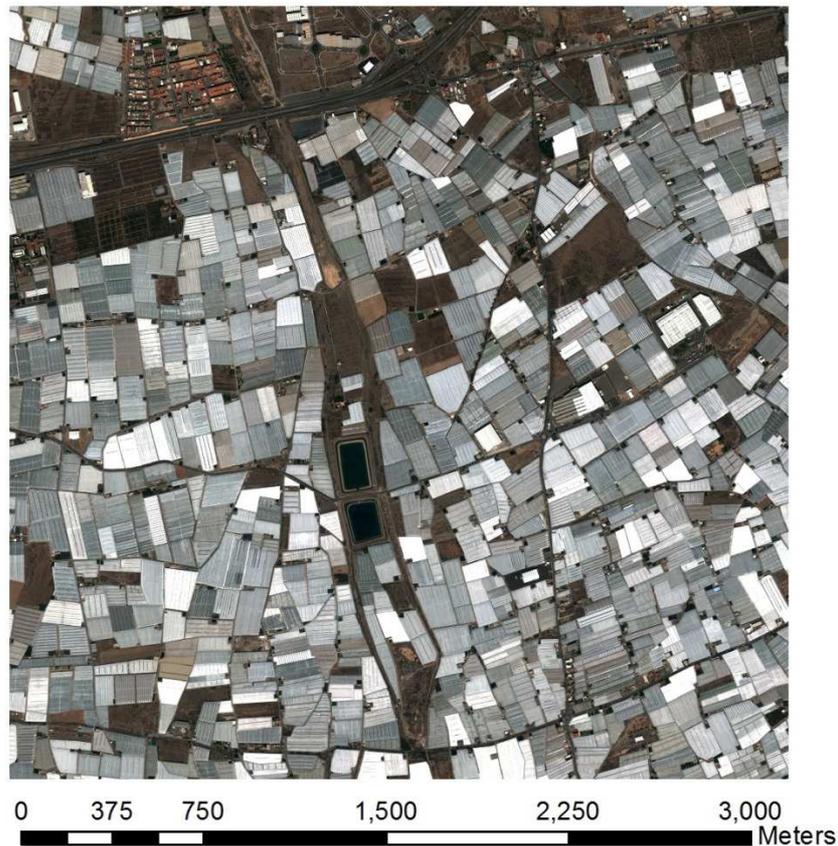


Figura 2. Ortoimagen MS correspondiente a la zona de estudio reducida.

2.3. Verdad terreno para las clases Invernaderos y Otros.

Para la estimación de la segmentación óptima, así como para la evaluación final de la clasificación OBIA realizadas, es necesario tener la verdad terreno o ground truth de la zona reducida de estudio. Para ello se decidió digitalizar manualmente sobre la fuente de mayor resolución disponible, es decir, la ortoimagen fusionada con 0.4 m GSD de WV2, todos los invernaderos existentes, y por ende, también definir todos la superficie perteneciente a la clase Otros (i.e, No Invernadero). En la Figura 3 se presenta el resultado de este trabajo de digitalización que usaremos como verdad terreno a lo largo de este trabajo.

Tomando como base la Figura 3, se extrajeron 30 polígonos correspondientes a invernaderos (Figura 4) con el objeto de evaluar la bondad de las segmentaciones multi-resolución generadas variando los tres parámetros fundamentales (i.e., Escala, Shape y Compactness). De la misma forma se extrajeron también 30 objetos correspondientes a la clase Invernadero y otros 30 de la clase Otros para ser usados como muestras de clase conocida en el proceso de clasificación supervisado que explicaremos posteriormente (Figura 5).



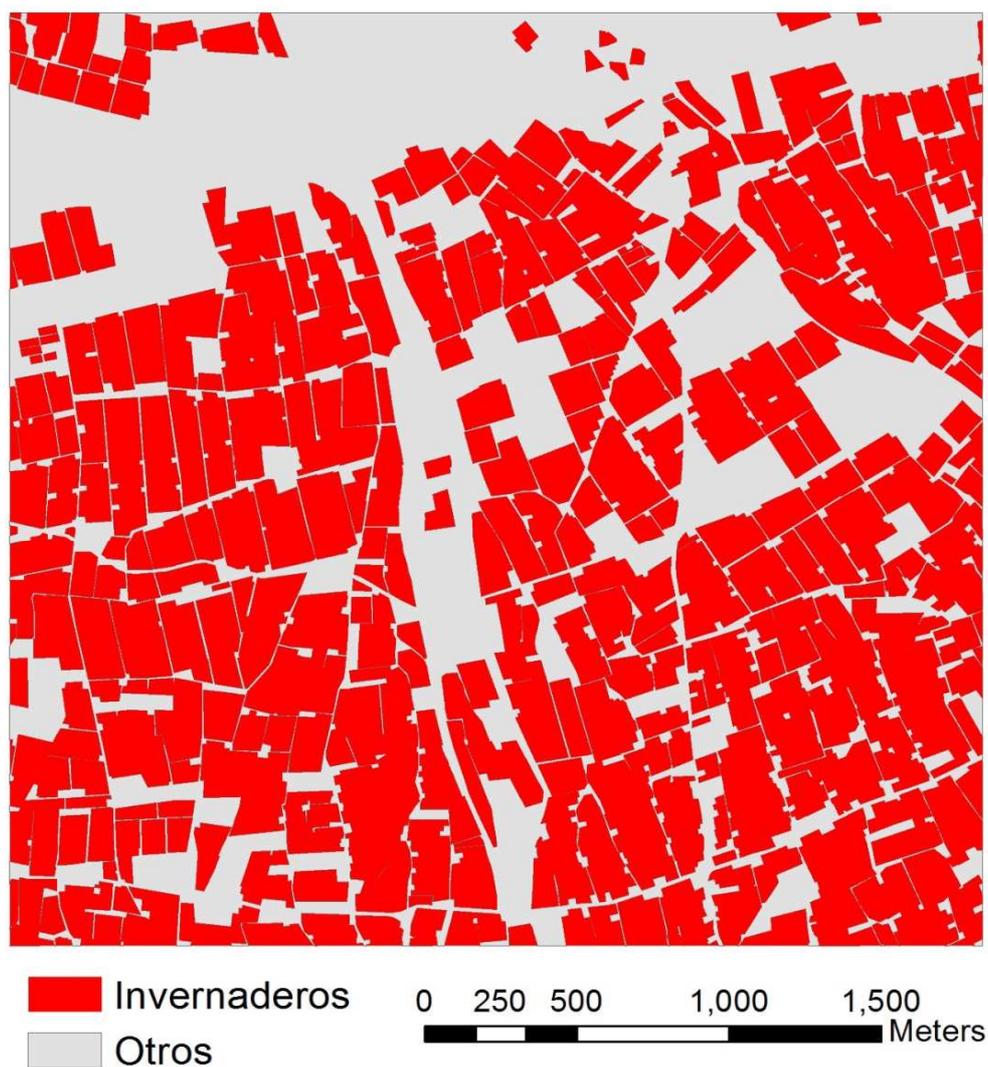


Figura 3. Digitalización manual sobre la ortoimagen fusionada de WV2 de la zona de estudio reducida en las clases binarias **Invernaderos** y **Otros**.



Figura 4. Zona de estudio reducida con los 30 polígonos correspondientes a los invernaderos de referencia usados para evaluar la calidad de la segmentación.



Figura 5. Extracción de objetos para muestras. Finalmente se usaron los centroides como muestras.

3. Metodología.

3.1. Creación del proyecto con eCognition.

Una vez ha sido recopilada la información previa, se puede proceder a realizar las segmentaciones con eCognition 8.8 (Trimble, Sunnyvale, California, United States) usando el algoritmo de segmentación multi-resolución y la posterior clasificación de esos objetos segmentados mediante el clasificador supervisado Nearest Neighbour (NN). Este software OBIA será empleado para tratar la ortoimagen MS corregida atmosféricamente de WV2 en la zona reducida.

El primer paso en eCognition es importar la información de la que disponemos. En este caso, la ortoimagen MS corregida atmosféricamente de WV2 en la zona reducida (*ATCOR corrected Ortho MS _MAAT_rec_Segment.pix*) en la que podemos observar la zona de estudio en el entorno eCognition. Los datos de la misma se pueden ver en la Figura 6.

Al importar la imagen MS de WV2 en el nuevo proyecto de eCognition aparece la información correspondiente a las 8 bandas que contiene (Figura 7).

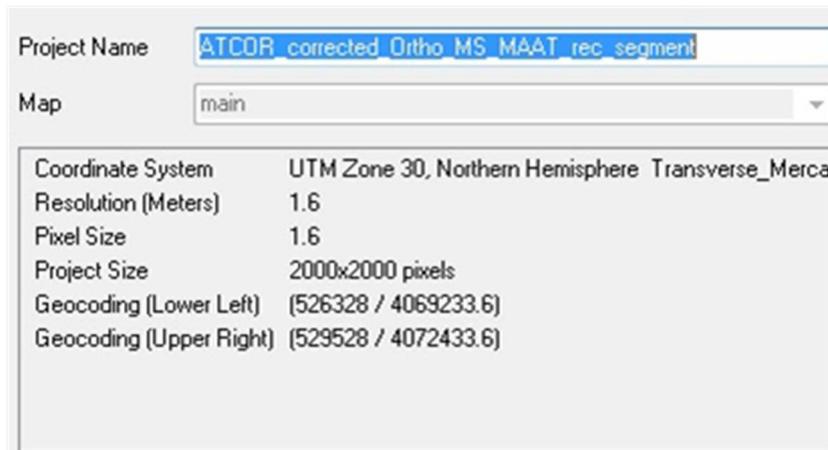


Figura 6. Lectura de datos de la imagen MS de WV2 en eCognition.

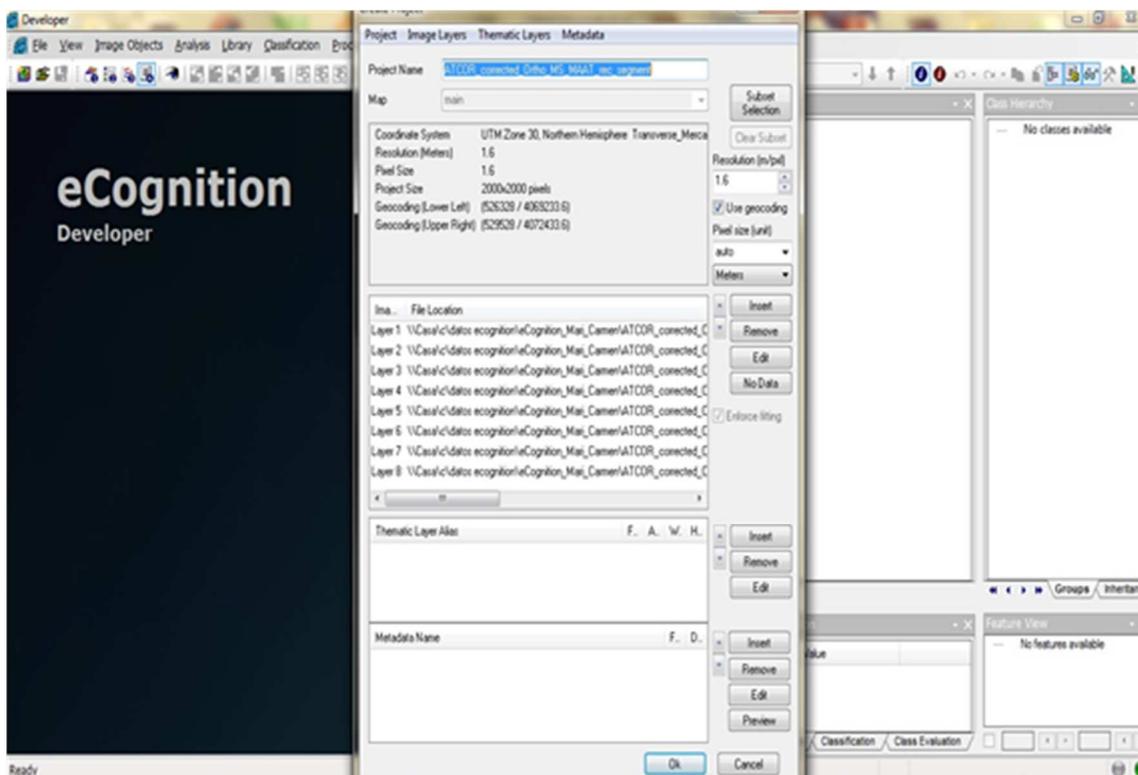


Figura 7. Creación del proyecto en eCognition.

Para la visualización de las bandas se eligió una combinación distinta a la predefinida por defecto con intención de tener una vista en verdadero color RGB (Tabla 1).

		Combinación por defecto			Nueva combinación (Color verdadero)		
		R	G	B	R	G	B
Coastal	Layer 1	x					
Blue	Layer 2		x				x
Green	Layer 3			x		x	
Yellow	Layer 4						
Red	Layer 5				x		
Red Edge	Layer 6						



Near Infrared 1	Layer 7						
Near Infrared 2	Layer 8						

Tabla 1. Combinación de bandas para visualización.

3.2. Segmentation Multi-resolución.

El primer proceso que vamos a realizar es la segmentación de la imagen, y dentro de los algoritmos de segmentación disponibles, utilizamos el algoritmo de segmentation multi-resolución. El programa comercial eCognition está considerado como uno de los softwares más eficaces en cuanto a eficiencia de segmentación se refiere. La segmentación multi-resolución de eCognition consigue los mejores resultados generales en comparación con otros softwares (Neubert y Meinel, 2003). La segmentación multi-resolución produce objetos de imagen altamente homogéneos utilizando diferentes resoluciones sobre diferentes tipos de datos. Aplicar esta técnica de segmentación permite obtener buenos resultados para diferentes tipos de datos y de imágenes.

Una vez creado el proyecto e importada la información de las 8 bandas de la imagen MS de WV2, procederemos a realizar la segmentación de la misma. Insertamos en el árbol de procesos una nueva segmentación multi-resolución y la editamos (Figura 8).



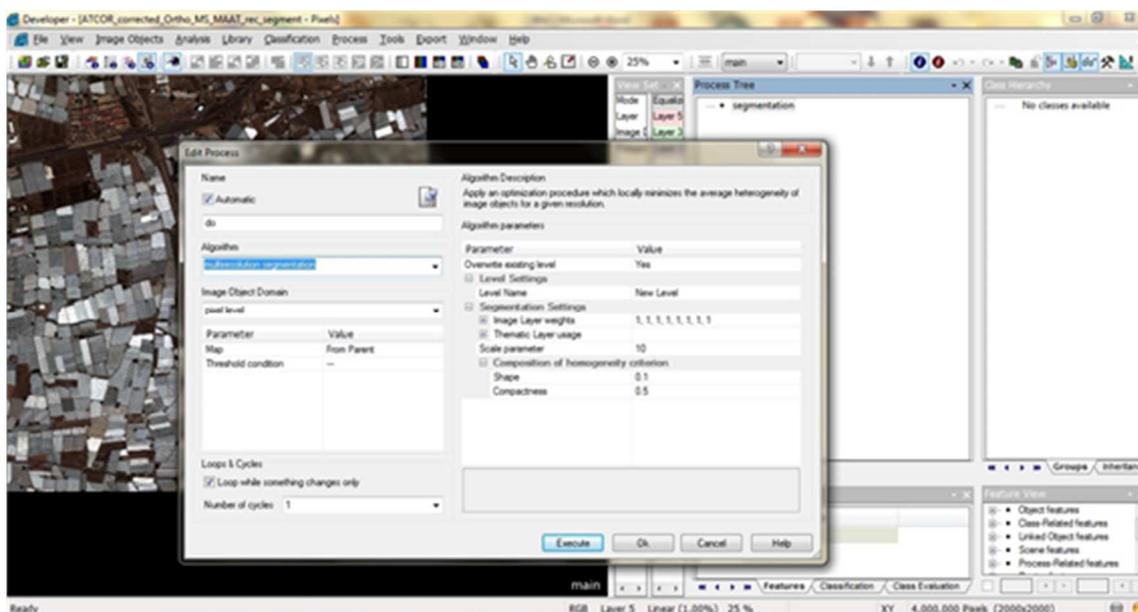


Figura 8. Algoritmo de segmentación multi-resolución de eCognition.

Combinando distintos valores de los parámetros de entrada del algoritmo de segmentación multi-resolución (i.e., Escala, Shape y Compactness), se obtienen diferentes salidos de segmentación, siendo el parámetro escala el más importante. Se han utilizado distintas combinaciones en busca de los resultados más óptimos para segmentar invernaderos. Es importante mencionar aquí que en todos los casos se computaron las distintas segmentaciones multi-resolución usando siempre las 8 bandas de la ortoimagen MS de VW2 con un peso de 1 para todas ellas. A partir de aquí, se han variado los valores de Escala y de Shape. El peso asignado al parámetro Compactness en literatura especializada ha sido usualmente fijado en 0.5 (Liu y Xia, 2010; Dragut *et al.*, 2014; Kavzoglu y Yildiz, 2014), por lo que el valor de este parámetro en nuestro estudio siempre se ha mantenido constante en 0.5.

Combinación	Escala	Shape	Compactness
1	15	0.1	0.5
2	15	0.2	0.5
3	15	0.3	0.5
4	20	0.1	0.5
5	20	0.2	0.5
6	20	0.3	0.5
7	25	0.1	0.5
8	25	0.2	0.5
9	25	0.3	0.5
10	30	0.1	0.5
11	30	0.2	0.5
12	30	0.3	0.5
13	35	0.1	0.5
14	35	0.2	0.5
15	35	0.3	0.5
16	40	0.1	0.5
17	40	0.2	0.5
18	40	0.3	0.5
19	45	0.1	0.5
20	45	0.2	0.5



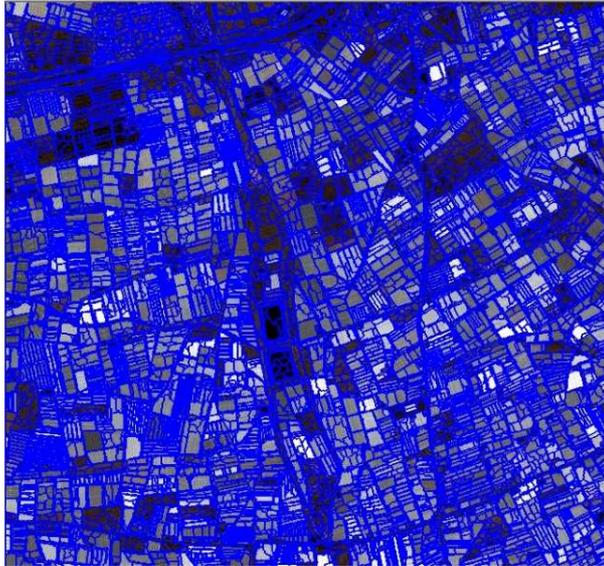
21	45	0.3	0.5
22	50	0.1	0.5
23	50	0.2	0.5
24	50	0.3	0.5
25	55	0.1	0.5
26	55	0.2	0.5
27	55	0.3	0.5
28	60	0.1	0.5
29	60	0.2	0.5
30	60	0.1	0.5
31	65	0.2	0.5
32	65	0.3	0.5
33	65	0.1	0.5
34	70	0.2	0.5
35	70	0.3	0.5
36	70	0.1	0.5
37	75	0.2	0.5
38	75	0.3	0.5
39	75	0.1	0.5
40	80	0.1	0.5
41	80	0.2	0.5
42	80	0.3	0.5
43	85	0.1	0.5
44	85	0.2	0.5
45	85	0.3	0.5

Combinación	Escala	Shape	Compactness
46	90	0.1	0.5
47	90	0.2	0.5
48	90	0.3	0.5
49	95	0.1	0.5
50	95	0.2	0.5
51	95	0.3	0.5
52	100	0.1	0.5
53	100	0.2	0.5
54	100	0.3	0.5
55	105	0.1	0.5
56	105	0.2	0.5
57	105	0.3	0.5
58	110	0.1	0.5
59	110	0.2	0.5
60	110	0.3	0.5
61	115	0.1	0.5
62	115	0.2	0.5
63	115	0.3	0.5
64	120	0.1	0.5
65	120	0.2	0.5
66	120	0.3	0.5

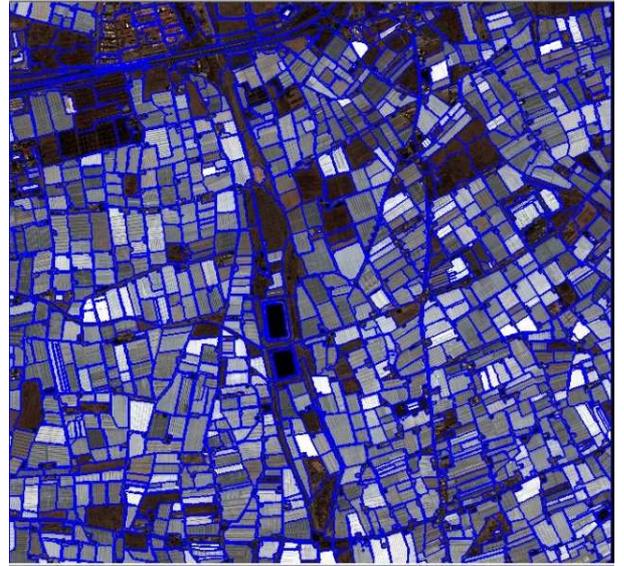
Las 66 combinaciones usadas para los proyectos de segmentación se muestran en la Tabla 2. De la misma forma, los resultados de cuatro de estas combinaciones de parámetros se muestran en la Figura 9. Cada una de las segmentaciones obtenidas se exporta a formato Shape (.SHP) para proceder a la posterior evaluación de la segmentación.

Tabla 2. Combinaciones de parámetros.

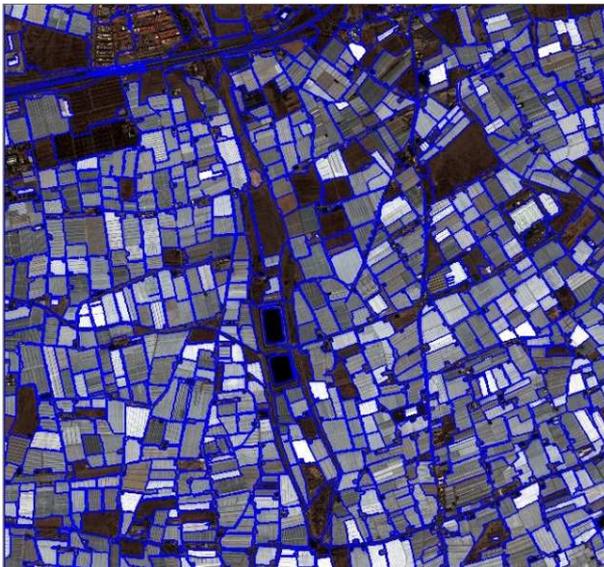




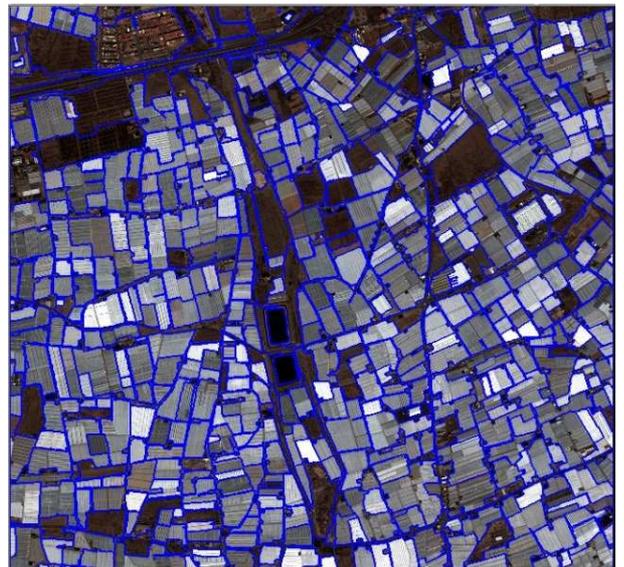
(a) Combinación 3



(b) Combinación 24



(c) Combinación 45



(d) Combinación 66

Figura 9. Resultados de las segmentaciones realizadas con las combinaciones 3, 24, 45 y 66.

Posteriormente, y debido a que la escala óptima estaba alrededor de una escala de 50, se realizaron las segmentaciones con escalas entre 40 y 50, saltando solo 1, para tener mayor exactitud en la determinación de la segmentación óptima. Por tanto se realizaron un total de 114 proyectos de segmentación.

3.3. Clasificación OBIA.

Una vez obtenidas las distintas segmentaciones a evaluar, pasamos al siguiente proceso siguiendo un procedimiento OBIA, la Clasificación de los objetos segmentados. Básicamente, existen dos métodos de clasificación en teledetección. La Clasificación basada en píxeles, en el que el elemento a clasificar es el píxel, y la Clasificación basada en objetos, en el que se generarán segmentos mediante la integración de los píxeles similares al primero, y luego, estos segmentos serán asignados a la cobertura del suelo mediante el proceso de Clasificación. La Clasificación basada en objetos está especialmente indicada para la clasificación basada en imágenes de satélite de alta o muy alta resolución (Figura 10).

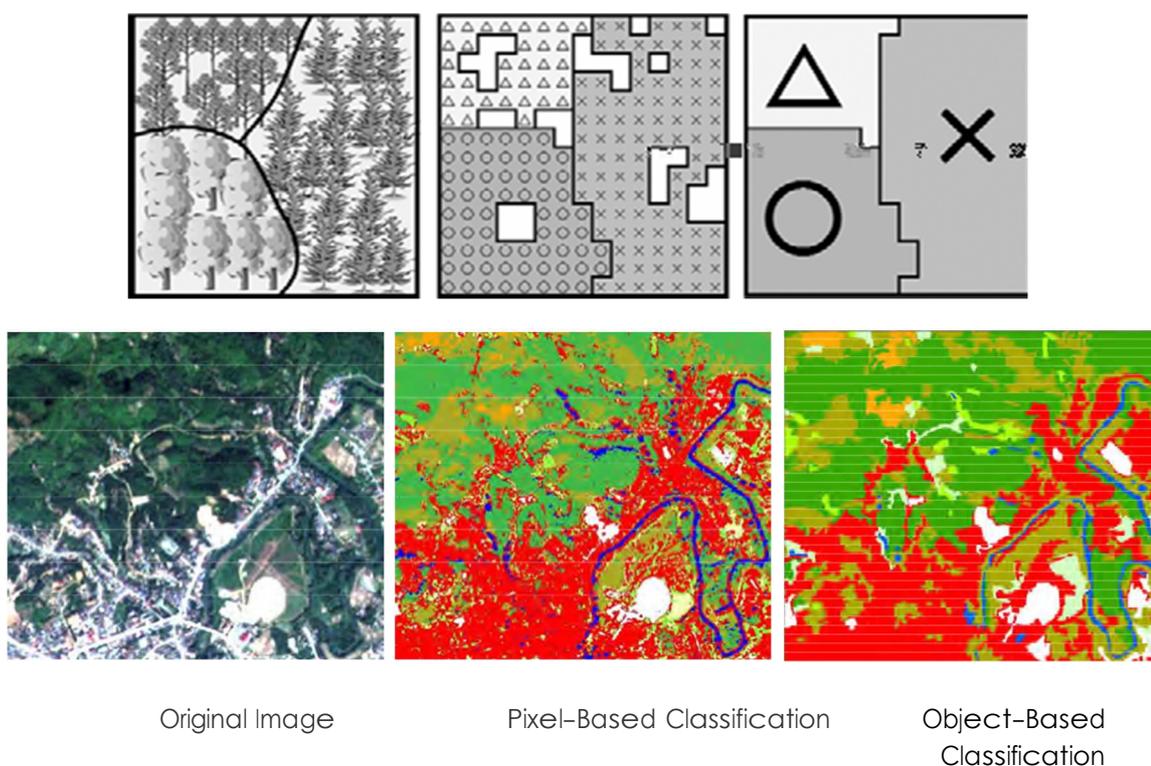


Figura 10. Métodos de clasificación.

En este caso, vamos a utilizar una clasificación basada en objetos usando eCognition. Para ello, editamos un nuevo proceso de Clasificación. A continuación para clasificar con el clasificador supervisado Nearest Neighbour (NN) se debe editar el método de clasificación, es decir, que características van a ser utilizadas en el espacio de trabajo para clasificar. En un primer intento, solo se consideró una clasificación básica, usando solamente los valores medios de cada una de las 8 capas de la imagen MS de WV2. Es decir, la media de los píxeles que entran dentro de cada uno de los



objetos segmentados para cada una de las bandas de información. En un segundo intento se decidió proponer una clasificación avanzada donde, además de los valores medios de cada banda, se añadieron como característica de cada objeto, un índice de vegetación muy usado como el NDVI (Rouse *et al.*, 1973), y un descriptor de textura de Haralick (Haralick *et al.*, 1973), concretamente la entropía. Estas dos últimas características dependerán de forma importante de que la delimitación del objeto real (por ejemplo un invernadero) sea realizada correctamente, por tanto estará directamente relacionado con la bondad de la segmentación.

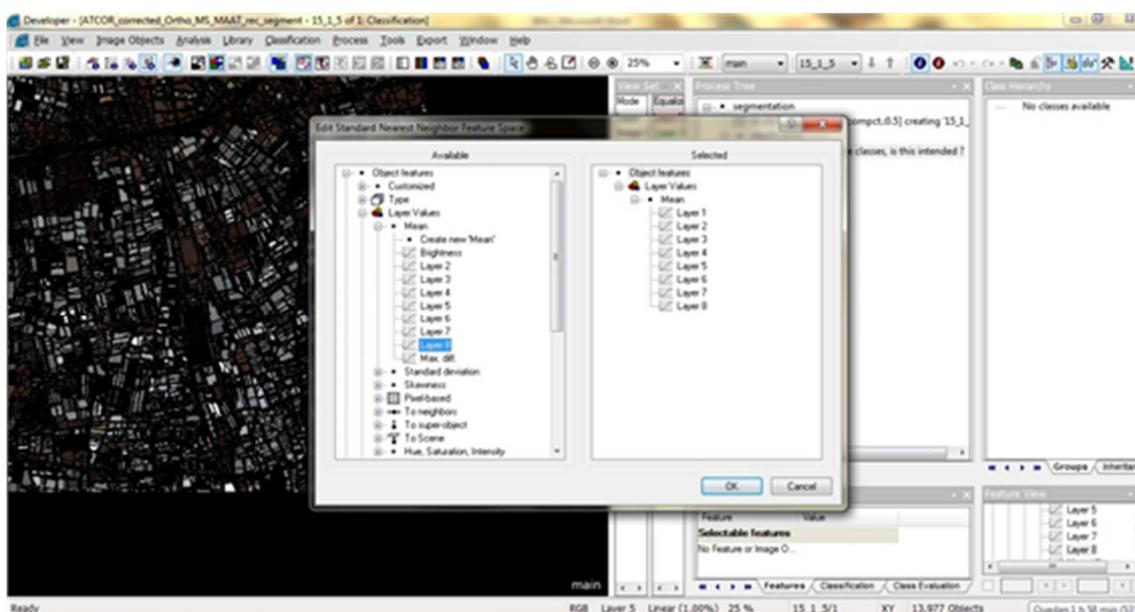


Figura 11. Elección de las características empleadas en la clasificación NN. Caso de la clasificación básica con 8 valores medios por objeto.

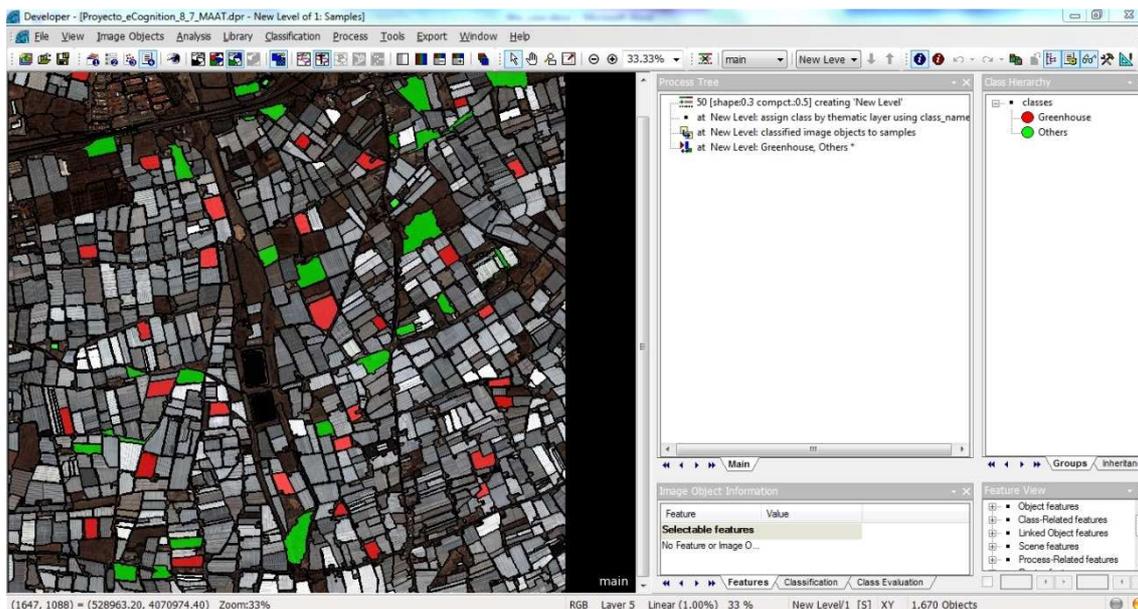


Figura 12. Definición de las muestras en el ensayo de segmentación con Escala=50, Shape=0.3 y Compactness=0.5.

La clasificación que se va a hacer de forma binaria, diferenciando entre dos clases: Invernaderos y Otros (No Invernaderos). Por lo tanto, el siguiente paso es insertar los centroides de las muestras que conozco y que sé su clasificación (Figura 5), es decir 30 de la clase Invernaderos y 30 de la clase Otros. Los 60 objetos que se correspondan con los centroides de las muestras serán usados como ejemplo de clases (Figura 12). El resto de objetos para cada segmentación serán clasificados mediante NN dependiendo de su cercanía en el espacio euclideo a las muestras conocidas en las clases Invernaderos y Otros. En otras palabras, al ejecutar, el software clasifica automáticamente todos los objetos. Me indica de todos los objetos que tengo, cuáles de ellos se parecen más a las muestras que se han definido como Invernaderos, los colorea de rojo y los añade a la clase Invernaderos, y cuáles de ellos se parecen más espectralmente a los elementos de otras clases, los colorea de verde y los añade a la clase Otros. Es importante tener en cuenta que las 60 muestras (30 Invernaderos y 30 Otros) permanecen siempre constantes para todos los proyectos realizados.

Una vez realiza la clasificación binaria, pasamos a la fase de evaluación de la clasificación que se realiza mediante la matriz de confusión o de error (Congalton, 1991). Las medidas de precisión de la clasificación extraídas de las matrices de confusión (Figura 13) fueron la precisión global (Overall Accuracy, OA) y el coeficiente kappa (κ). Para ello debo cargar la imagen raster de la verdad terreno realizada manualmente (Figura 3), de la que previamente hemos eliminado los objetos



seleccionados como muestras en cada proyecto. Sobre esta imagen raster es donde se va a medir la precisión de la clasificación, seleccionando la opción de computo por píxeles (Error Matrix base don TTA Mask).

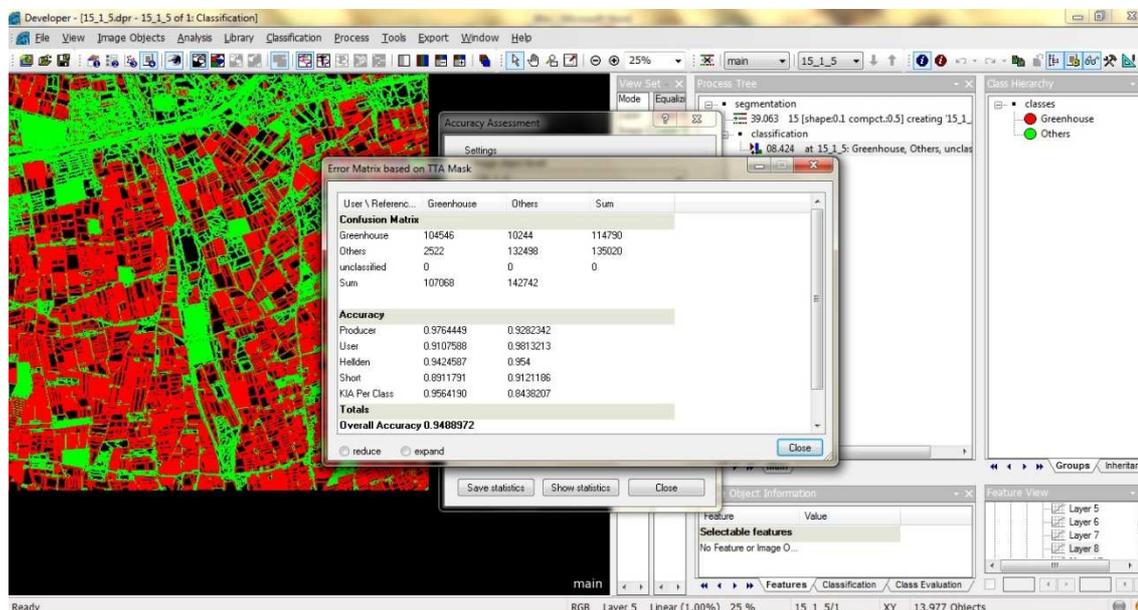


Figura 13. Ejemplo de matriz de confusión en eCognition.

3.4. Evaluación de la segmentación.

Las métricas usadas para la evaluación supervisada de la segmentación están centradas en el escenario donde los objetos de referencia (invernaderos e nuestro caso) han sido digitalizados previamente. Los resultados de la calidad de la segmentación automática generada son comparados con estos objetos de referencia para ver su similitud. En este trabajo, las salidas (ficheros .SHP) de cada combinación de segmentación multi-resolución generada, fue comparada con 30 invernaderos digitalizados manualmente (Figura 4). Este número de objetos de referencia es el recomendado por Liu *et al.* (2012). Aunque hay muchos métodos supervisados para evaluar la calidad de la segmentación (Zhang, 1996; Clinton *et al.*, 2010), quizás la medida de discrepancia conocida como Euclidean Distance 2 (ED2), recientemente propuesta por Liu *et al.* (2012), sea la que ha demostrado un comportamiento mejor. En resumen, ED2 intenta optimizar en un espacio Euclideo 2D las discrepancias geométricas (mediante el error potencial de la segmentación, potential segmentation error, PSE) y la discrepancia aritmética entre los objetos de la segmentación a evaluar y los objetos de referencia (Relación entre el número de segmentos, the number-of-segmentation ratio, NSR).



Para calcular ED2, Liu *et al.* (2012) definieron el conjunto de segmentos correspondientes que puede ser extraído de la segmentación a evaluar y que solo contiene los polígonos que se solapan con los objetos de referencia. Un segmento es incluido en este conjunto de segmentos correspondientes si el área de intersección entre el polígono de referencia y el segmento candidato es mayor de la mitad del área del segmento candidato o del segmento de referencia.

La Figura 14 muestra los segmentos candidatos y correspondientes extraídos de dos segmentaciones multi-resolución para el mismo invernadero de referencia (polígono). La segmentación mostrada en la Figura 14a se corresponde con escala de 50, shape de 0.1 y compactness de 0.5, mientras que la Figura 14b presenta una segmentación con escala de 62, shape de 0.5 y compactness de 0.5. Las posibles discrepancias geométricas que nos podemos encontrar son: sobre segmentación (over-segment), poca segmentación (under-segment) y el área de solape (overlapped). ED2 mide las discrepancias geométricas mediante PSE, que se define como el cociente entre el área el área total under-segment y el área total de los polígonos de referencia (Ecuación 1), donde r_k es el polígono de referencia k -th ($k = 1, 2, \dots, m$) y s_i representa los segmentos correspondientes de los objetos candidatos asociados al polígono de referencia i -th ($i = 1, 2, \dots, v$). Un valor de PSE de cero indica que no hay under-segment. Un valor grande implica un grado importante de under-segmentation (ver Figura 14).

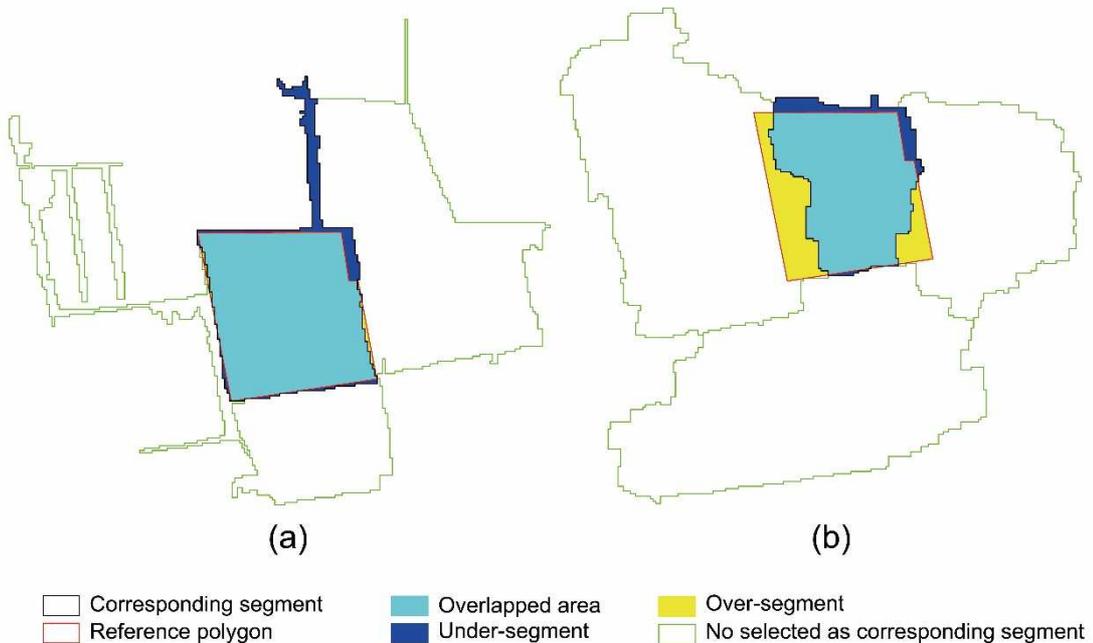


Figura 14. Ilustración de las discrepancias geométricas entre los polígonos de referencia, los candidatos y los del conjunto de segmentos correspondientes.

$$PSE = \frac{\sum |s_i - r_k|}{\sum |r_k|} \quad (1)$$

Sin embargo, aunque las relaciones geométricas son necesarias, no son suficientes para describir los diversos tipos de discrepancias entre los polígonos de referencia y el conjunto de objetos correspondientes. Así, una discrepancia aritmética es incluida también en la métrica ED2 a través del índice NSR. NSR se define como la diferencia absoluta entre el número de polígonos de referencia (m) y el número de segmentos correspondientes (v), dividido por el número de polígonos de referencia (Ecuación 2).

$$NSR = \frac{abs(m - v)}{m} \quad (2)$$

Finalmente, ED2 se puede calcular como un índice compuesto, considerando tanto discrepancias geométricas como aritméticas (Ecuación 3).

$$ED2 = \sqrt{(PSE)^2 + (NSR)^2} \quad (3)$$

De acuerdo con el trabajo de Liu *et al.* (2012), un valor de ED2 igual a cero indica una correspondencia ideal, tanto de geoméricamente como aritméticamente, del conjunto de objetos de referencia digitalizados manualmente (invernaderos en nuestro caso) y la segmentación obtenida (en nuestro caso mediante segmentación multi-resolución). Geométricamente, lo deseable es que no exista ni over-segments ni under-segments. Aritméticamente, lo ideal es que el número de polígonos de referencia y el número de segmentos correspondientes coincidan, es decir, que cada objeto delineado manualmente se corresponda con un único objeto de la segmentación a evaluar. Por otro lado, valores muy grandes de ED2 indican que hay unas discrepancias geométricas importantes, que existe una gran discrepancia aritmética, o ambas cosas.

4. Resultados y discusión.



4.1. Evaluación de la calidad de la segmentación.

Si nos fijamos de nuevo en las segmentaciones presentadas anteriormente en la Figura 9, podemos ver como cuando el factor de Escala es muy pequeño (15 en la Figura 9a), los segmentos obtenidos son excesivamente pequeños. Es decir, cada invernadero estaría representado por muchos más de un objeto que sería la situación ideal. En este caso tenemos un exceso de segmentación (over-segmentation). En el otro extremo, la Figura 9d muestra una segmentación con Escala de 120, donde observamos que algunos segmentos contienen más de un invernadero. En este caso tenemos una segmentación demasiado baja (under-segmentation). Sin embargo, los dos casos intermedios (i.e., Figura 9b con una Escala de 50 y Figura 9c con una Escala de 85) es difícil a simple vista tomar una decisión sobre cuál de ellas es mejor, ya que ambas parecen representar de forma apropiada a los invernaderos objeto de este trabajo.

Para ayudarnos a tomar la decisión de cuál es la segmentación óptima, nos vamos a apoyar en los valores de ED2 calculados según Liu *et al.* (2012) y en sus índices básicos (i.e., NSR, discrepancias aritméticas y PSE, discrepancias geométricas). Los valores de NSR, PSE y ED2 para las cuatro combinaciones mostradas en la Figura 9 se pueden ver en la Tabla 3. Podemos ver que en el caso de la segmentación con Escala de 15 (Figura 9a) que presenta una gran over-segmentation, los principales errores que provocan un ED2 muy alto (segmentación muy mala) son los correspondientes a las discrepancias aritméticas (NSR). Los límites de cada invernadero están bien definidos (bajo valor de PSE) pero están formados por muchos segmentos (valor alto de NSR). En el caso opuesto, con una Escala de 120 y gran under-segmentation, el principal error es el PSE. De los otros dos casos, fijándonos en los valores de ED2 obtenidos, podemos inferir que la escala 50 conduce a una mejor segmentación que la escala 85, para la misma combinación de los parámetros Shape y Compactness.

	Escala	Shape	Compactness	NSR	PSE	ED2
Figura 9a	15	3	5	6.800	0.044	6.800
Figura 9b	50	3	5	0.133	0.088	0.160
Figura 9c	85	3	5	0.000	0.457	0.457
Figura 9d	120	3	5	0.000	1.238	1.238

Tabla 3. Valores de NSR, PSE y ED2 para las combinaciones mostradas en la Figura 9.

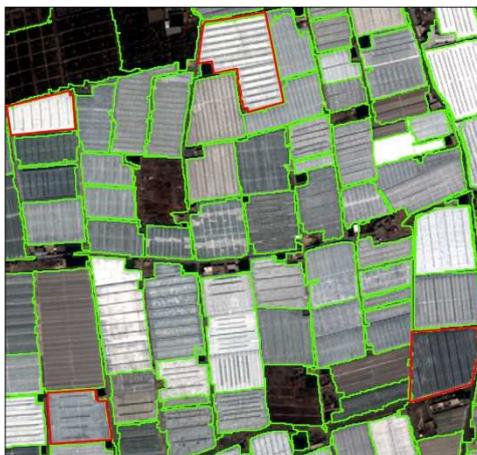




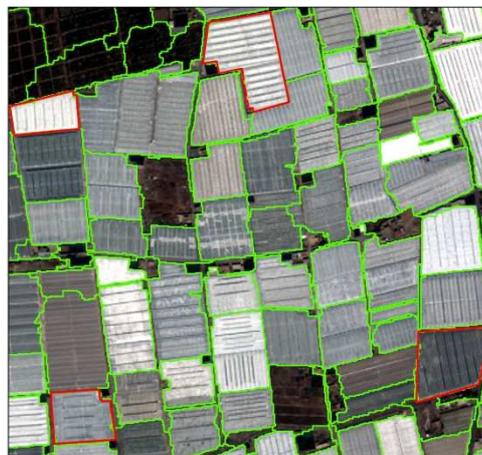
(a) Ortho VW2 MS



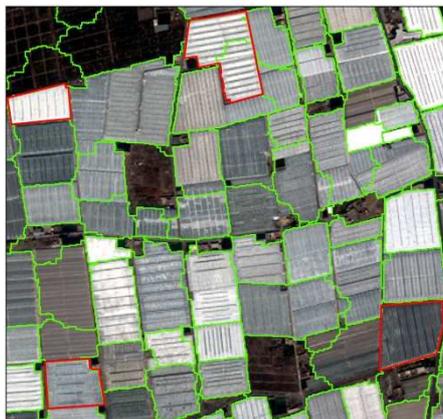
(b) ED2 = 0.19; Escala = 50; Shape = 0.1



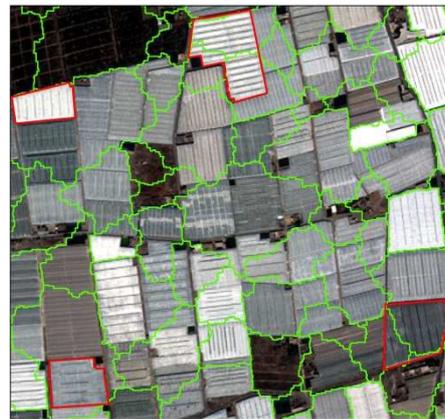
(c) ED2 = 0.16; Escala = 50; Shape = 0.3



(d) ED2 = 0.15; Escala = 50; Shape = 0.5



(e) ED2 = 0.45; Escala = 50; Shape = 0.7



(f) ED2 = 1.17; Escala = 50; Shape = 0.9

Figura 15. Detalles de los resultados de la segmentación multi-resolución (polígonos verdes) para diferentes combinaciones de parámetros. Los parámetros de Escala y Compactness se mantuvieron constantes en valores de 50 y 0.5 respectivamente, mientras que el factor de forma (Shape) tomó valores de 0.1, 0.3, 0.5, 0.7 y 0.9. Invernaderos de referencia en rojo.

En la Figura 15 se muestran detalles de la segmentación obtenida en 6 nuevas combinaciones, donde la Escala se mantiene constante en 50, el factor Compactness se fija en 0.5. El único parámetro que variamos es el factor de forma (Shape) que toma valores de 0.1, 0.3, 0.5, 0.7 y 0.9. Los resultados visuales obtenidos en la segmentación de invernaderos se corresponden muy bien con el índice ED2 calculado sobre los 30 polígonos de referencia. Los valores de Shape mayores de 0.5 produjeron unas segmentaciones con segmentos demasiado redondeados, por lo que fueron descartados para el resto de las combinaciones analizadas en este trabajo.

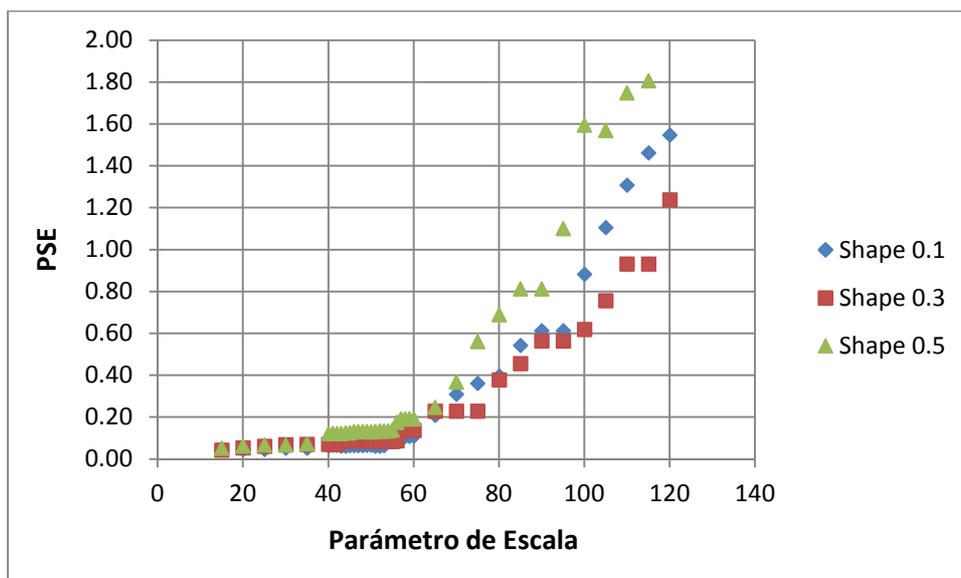


Figura 16. Representación del índice PSE (discrepancias geométricas) frente a la escala elegida y para los tres valores de Shape. El parámetro Compactness se mantuvo fijo en 0.5.

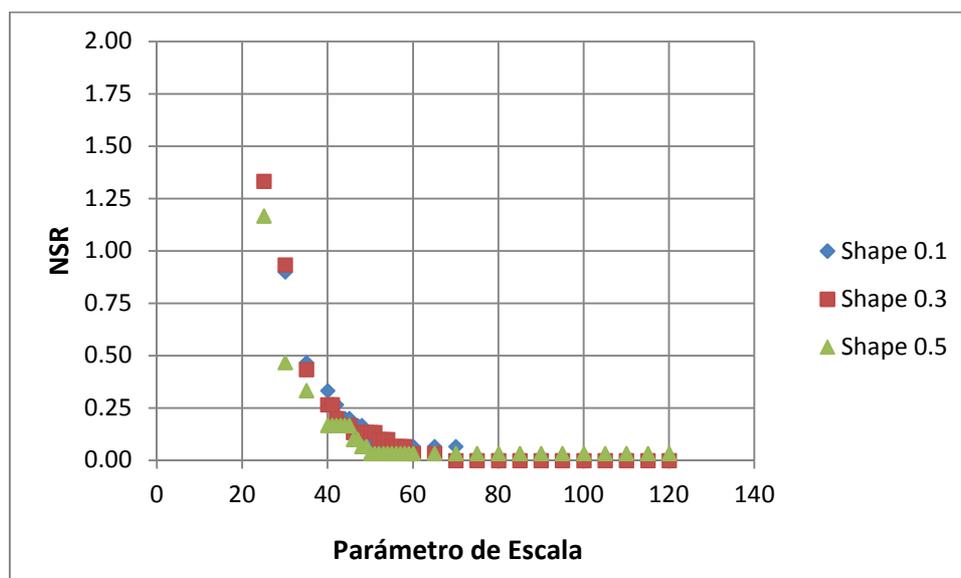


Figura 17. Representación del índice NSR (discrepancias aritméticas) frente a la escala elegida y para los tres valores de Shape. El parámetro Compactness se mantuvo fijo en 0.5.



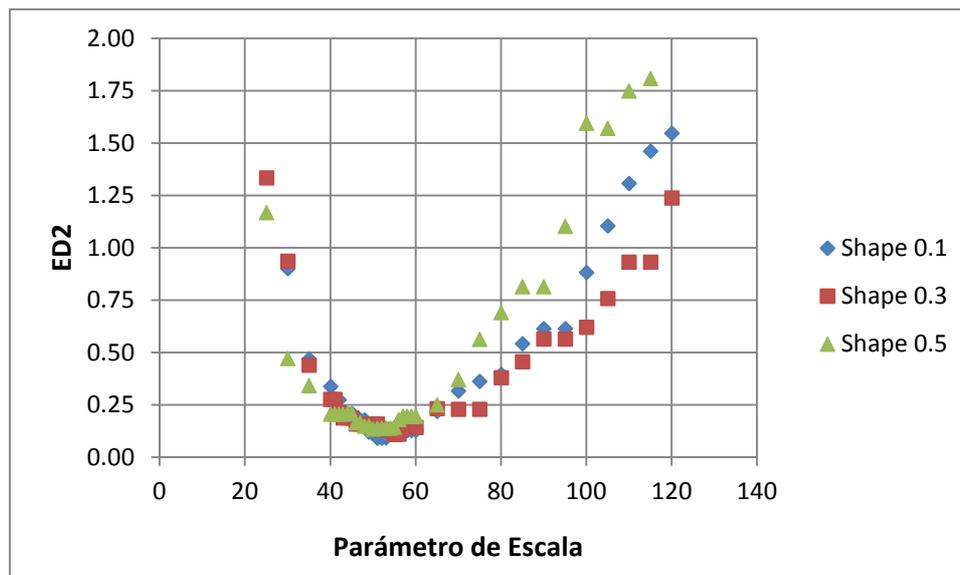


Figura 18. Representación de ED2 como métrica descriptora de la bondad de la segmentación frente a la escala elegida y para los tres valores de Shape. Compactness constante en 0.5.

En la Figura 16 se muestra el índice PSE que representa las discrepancias geométricas existentes entre la segmentación a evaluar y el conjunto de los 30 invernaderos de referencia, con respecto a la escala elegida y para los tres valores de Shape ensayados (0.1, 0.3 y 0.5). El parámetro Compactness se mantuvo siempre fijo en 0.5, por lo que no volveremos a mencionarlo. Los valores de PSE se acercan asintóticamente a cero cuando la escala de la segmentación decrece, produciéndose los valores más elevados a valores de escala mayores. Los valores de PSE obtenidos para un parámetro de Shape de 0.3 parecen ser ligeramente mejores que para factores de forma de 0.1 y 0.5.

En la Figura 17 se muestra el índice NSR que representa las discrepancias aritméticas existentes entre la segmentación a evaluar y el conjunto de los 30 invernaderos de referencia, con respecto a la escala elegida y para los tres valores de Shape ensayados (0.1, 0.3 y 0.5). Los valores de NSR se acercan asintóticamente a cero cuando la escala de la segmentación aumenta, produciéndose los valores más elevados a valores de escala más pequeños, cuando hay over-segmentation. Los valores de NSR obtenidos son bastante variables, no existiendo ningún valor del parámetro Shape que funcione bien en todas las escalas ensayadas.

En la Figura 18 se muestra los valores de ED2 con respecto a la escala elegida y para los tres valores de Shape ensayados (0.1, 0.3 y 0.5). Los valores de ED2 forman una



especie de parábola con un mínimo claramente definido entre las escalas 40 y 60. Si nos fijamos en la Figura 19, donde se muestra un detalle de los valores mínimos de ED2 frente al rango óptimo de escalas para los tres valores de Shape ensayados (i.e., 0.1, 0.3 y 0.5), el valor mínimo de ED2 de 0.091 se obtuvo para Shape = 0.1 a una escala de 51. Para un Shape de 0.3, la escala óptima resultó ser de 55 y el valor de ED2 fue de 0.108. Para un Shape de 0.5, se calculó un valor de ED2 de 0.135 para una escala de 50. A la vista del global de los resultados, parece que los valores más adecuados para el parámetro Shape a la hora de segmentar invernaderos a partir de una imagen MS del satélite WV2 son 0.1 y 0.3. Los resultados se corresponden bastante bien con los obtenidos por Novelli *et al.* (2016) y Aguilar *et al.* (2016), aunque estos autores se inclinan más por un Shape de alrededor de 0.3, concretamente entre 0.2 y 0.4.

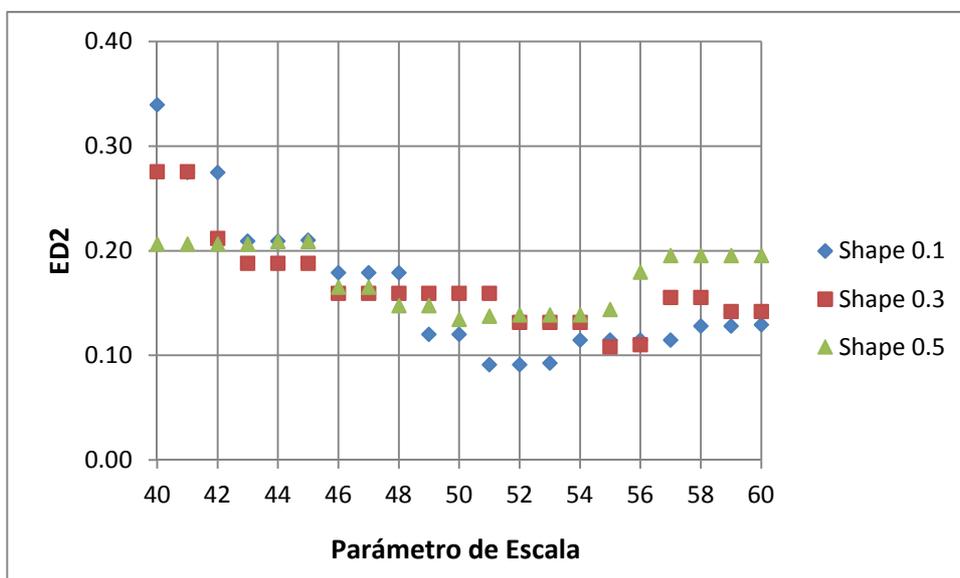


Figura 19. Detalle de los valores mínimos de ED2 frente al rango óptimo de escalas.

4.2. Clasificación OBIA básica.

Comencemos recordando que las clasificaciones OBIA llevadas a cabo en este trabajo se realizaron con el clasificador supervisado NN, usando siempre las mismas 60 muestras (30 invernaderos y 30 de la clase Otros) para entrenar al clasificador. En la clasificación OBIA básica se usaron únicamente 8 características o features para clasificar la imagen MS de WV2. Estas 8 características fueron los valores medios para cada objeto segmentado de cada una de las bandas de WV2: coastal, blue, green, yellow, red, red edge, near infrared-1 y near infrared-2.

En las Figuras 20 y 21 podemos observar las precisiones de las clasificaciones OBIA básicas, Overall Accuracy (OA) y Kappa, obtenidas para cada una de las segmentaciones generadas con un parámetro Shape de 0.3. Teniendo en cuenta que, como vimos en el apartado anterior, las segmentaciones óptimas se producen para escalas alrededor de 50, podríamos deducir que, en el caso de la clasificación básica, las mejores precisiones en clasificación medidas como OA o Kappa, no están ligadas a las mejores segmentaciones. Es más, los mejores proyectos de clasificación se produjeron cuando teníamos un claro exceso de objetos en la segmentación, cosa que se producía a escalas muy pequeñas. En ese caso, los errores en la delimitación global de un invernadero son muy pequeños (hay poca superficie over-segment y under-segment según la Figura 14). Esta mejora de la segmentación geométrica (PSE) unido a que las características espectrales básicas se mantienen también en pequeños objetos, podía ser la clave para explicar estos resultados, que no habían sido descritos hasta ahora.

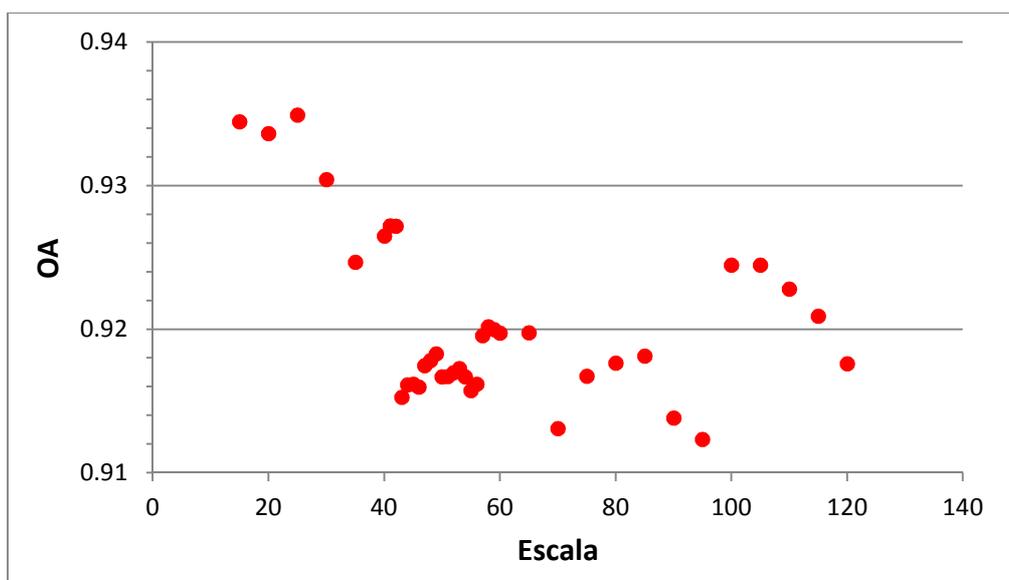


Figura 20. Valores de precisión global (Overall Accuracy, OA) en tantos por uno para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA básica.

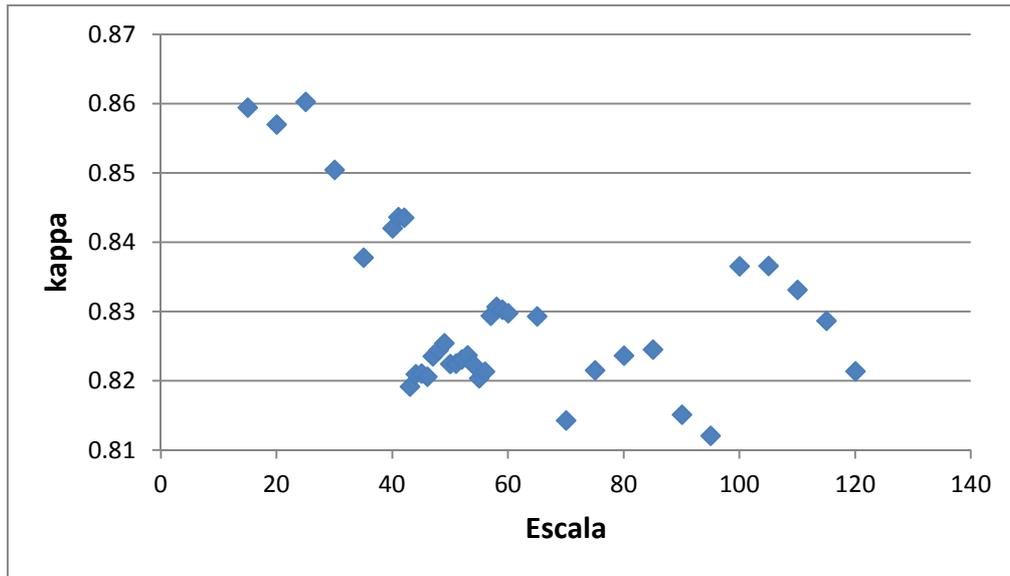


Figura 21. Valores del coeficiente Kappa para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA básica.

4.3. Clasificación OBIA avanzada.

En la clasificación OBIA avanzada, además de los valores medios de cada banda, se añadieron como característica de cada objeto, el índice de vegetación NDVI (Rouse *et al.*, 1973), y la entropía como descriptor de textura (Haralick *et al.*, 1973). En este caso y por motivo de tiempo, solo probamos Escalas de 15 a 120 con intervalos de 5, y solo para valores fijos de Shape y Compactness de 0.3 y 0.5 respectivamente.

En las Figuras 22 y 23 podemos observar las precisiones de las clasificaciones OBIA avanzada, Overall Accuracy (OA) y Kappa, obtenidas para cada una de las segmentaciones generadas con un parámetro Shape de 0.3. En este caso sí que la calidad de la clasificación parece estar ligada a la bondad de la segmentación, que como vimos en el apartado anterior, se producen para escalas de alrededor de 50. El mejor valor de OA es de 95.02% y se produce exactamente para una escala de 50. A esa misma escala se genera también el valor más alto del coeficiente Kappa (0.872). En el caso de la clasificación OBIA avanzada, estamos empleando características, especialmente la textura, que dependerán en gran medida de que el objeto real sea o no representando de manera fiable en la segmentación. Eso explicaría que en este caso, a diferencia de lo que ocurría en el apartado anterior con la clasificación básica, sí que exista una clara relación entre la calidad de la segmentación y la precisión final obtenida en la clasificación. Esto sí que se había documentado previamente (e.g., Liu y Xia, 2010).



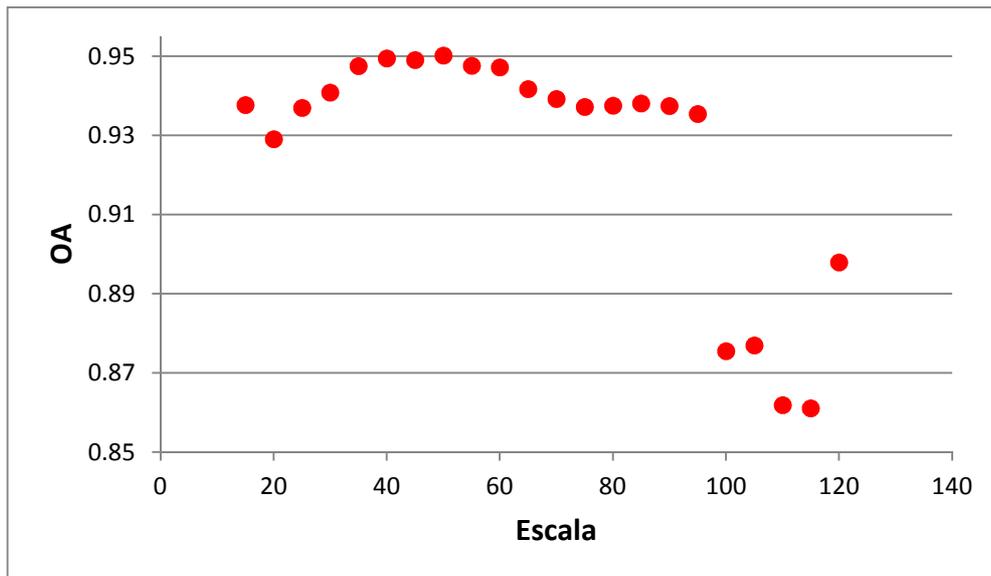


Figura 22. Valores de precisión global (Overall Accuracy, OA) en tantos por uno para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA avanzada.

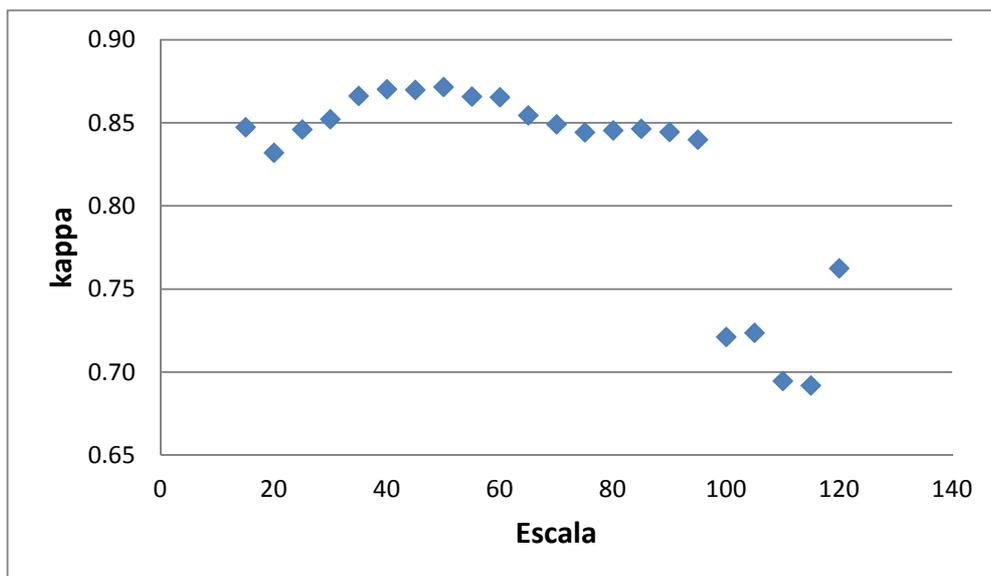


Figura 23. Valores del coeficiente Kappa para cada una de las segmentaciones obtenidas con Shape = 0.3 en la clasificación OBIA avanzada.

En la Figura 24 mostramos la Comparación entre el ground truth digitalizado en la zona de trabajo e importado a eCognition mediante una TTA Mask (raster) y el resultado de la clasificación OBIA avanzada con una segmentación multi-resolución con escala de 50, Shape de 0.3 y Compactness de 0.5. Recordemos que la OA para



este caso superaba ligeramente el 95%. En la Figura 24b podemos observar en verde oscuro y en rojo oscuro los objetos mal clasificados.



a)



b)

Figura 24. Comparación entre: a) el ground truth digitalizado en la zona de trabajo (TTA Mask) y, b) el resultado de la clasificación OBIA avanzada con una segmentación multi-resolución con escala de 50, Shape de 0.3 y Compactness de 0.5. En rojo la clase Invernaderos y en verde la clase Otros.

5. Conclusiones.

En una primera parte este trabajo se ha centrado en la identificación de los parámetros óptimos del algoritmo de segmentación multi-resolución incluido en el software comercial eCognition (i.e., Escala, Shape y Compactness). Hemos trabajado en una zona piloto situada en los invernaderos del poniente almeriense, con una imagen MS de WV2 con 8 bandas. La selección de los parámetros óptimos del algoritmo de segmentación estudiado no es una tarea sencilla, pero que puede resultar crucial para lograr una buena clasificación en el contexto de teledetección basada en objetos (OBIA).

La métrica ED2 presentó una muy buena relación de calidad visual en las segmentaciones multi-resolución de invernaderos de plástico. ED2 estuvo muy claramente relacionado con el parámetro de Escala, y también, pero en menor medida, con el parámetro de forma (Shape). En cuanto al Shape, los valores ideales para segmentar invernaderos resultaron ser 0.1 y 0.3. De esta forma, los parámetros para la segmentación multi-resolución en una ortoimagen MS de WV2 con 8 bandas corregidas atmosféricamente para delinear invernaderos de plástico fueron que arrojaron el valor más pequeño de ED2 (i.e., la mejor segmentación) de entre las 114 combinaciones ensayadas fueron: Parámetro de Escala de 51, Parámetro de forma (Shape) de 0.1 y Compactness en 0.5. A efectos prácticos, se recomienda realizar una evaluación particular del parámetro Escala de la segmentación multi-resolución usando la métrica ED2 cuando se trabaje con otra imagen de invernaderos, manteniendo Shape y Compactness fijos en 0.3 y 0.5 respectivamente.

Respecto a las clasificaciones básica (8 características espectrales) y avanzada (8 características espectrales, más un índice de vegetación (NDVI) y un descriptor de textura de Haralick (Entropía)), observamos dos comportamientos muy diferentes. La clasificación básica los resultados muestran que las mejores precisiones en clasificación medidas como OA o Kappa, no estuvieron ligadas a las mejores segmentaciones (Escala aproximadamente igual a 50). Por el contrario, los mejores valores de OA y Kappa se obtuvieron cuando teníamos un claro exceso de objetos en la segmentación, cosa que se producía a escalas muy pequeñas. Concretamente, el mejor valor de OA es de 93.48% y se produce para una escala de 25. Sin embargo, al incluir NDVI y la Entropía en la clasificación avanzada, sí que la calidad de la clasificación parece estar ligada a la bondad de la segmentación. De hecho, el mejor valor de OA es de 95.02% y se produce exactamente para una escala de 50.



Estos resultados hay que tomarlos con cautela, ya que se corresponden con un único caso de estudio muy localizado, pero podría ser el inicio de una nueva línea de investigación relativamente reciente como es la teledetección orientada a objetos, y concretamente aplicada a la detección de invernaderos de plástico.

6. Referencias.

Aguilar, M.A., Saldaña, M.M., Aguilar, F.J., 2013. GeoEye-1 and WorldView-2 pan-sharpened imagery for object-based classification in urban environments. *International Journal of Remote Sensing*, 34(7), pp. 2583-2606.

Aguilar, M.A., Bianconi, F., Aguilar, F.J., Fernández, I., 2014. Object-based greenhouse classification from GeoEye-1 and WorldView-2 stereo imagery. *Remote Sensing*, 6, pp. 3554-3582.

Aguilar, M.A., Vallario, A., Aguilar, F.J., García Lorca, A., Parente, C., 2015. Object-Based Greenhouse Horticultural Crop Identification from Multi-Temporal Satellite Imagery: A Case Study in Almeria, Spain. *Remote Sensing*, 7, pp. 7378-7401.

Aguilar, M.A., Nemmaoui, A., Novelli, A., Aguilar, F.J., García Lorca, A., 2016. Object-Based Greenhouse Mapping Using Very High Resolution Satellite Data and Landsat 8 Time Series. *Remote Sensing*, 5, 513.

Baatz, M., Schäpe, M., 2000. Multiresolution segmentation - An optimization approach for high quality multi-scale image segmentation. In: *Strobl, J., Blaschke, T., Griesebner, G. (Eds.), Angewandte Geographische Informations-Verarbeitung XII*. Wichmann Verlag, Karlsruhe, pp. 12-23.

Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004. Multiresolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry & Remote Sensing*, 58, 239-258.

Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(2010), pp. 2-16.

Carleer, A.P., Wolff, E., 2006. Urban land cover multi-level region-based classification of VHR data by selecting relevant features. *International Journal of Remote Sensing*, 27(6), pp. 1035-1051.

Clinton, N., Holt, A., Scarborough, J., Yan, L., Gong, P., 2010. Accuracy assessment measures for object-based image segmentation goodness. *Photogrammetric Engineering and Remote Sensing*, 76 (3), pp. 289-299.

Congalton, R.G., 1991. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, 37: 35-46

Dragut, L., Tiede, D., Levick, S., 2010. ESP: a tool to estimate scale parameters for multiresolution image segmentation of remotely sensed data. *International Journal of Geographical Information Science*, 24(6), pp. 859-871.

Dragut, L., Csillik, O., Eisank, C., Tiede, D., 2014. Automated parameterisation for multi-scale image segmentation on multiple layers. *ISPRS Journal Photogrammetry and Remote Sensing*, 88(2014), pp. 119-127.



Fernández, I., Aguilar, F.J., Aguilar, M.A., Álvarez, M.F., 2014. Influence of data source and training size on impervious surface areas classification using VHR Satellite and aerial imagery through an object-based approach. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(12), pp. 4681-4691.

Haralick, R.M., Shanmugam, K., Dinstein, I.H., 1973. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3: 610– 21.

Hay, G., Castilla, G. 2008. *Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline*, en *Object-Based Image Analysis. Spatial Concepts for Knowledge-Driven Remote Sensing. Applications*, Springer, 75-89.

Heenkenda, M.K., Joyce, K.E., Maier, S.W., 2015. Mangrove tree crown delineation from high-resolution imagery. *Photogrammetric Engineering and Remote Sensing*, 81(6), pp. 471-479.

Kavzoglu, T., Yildiz, M., 2014. Parameter-Based Performance Analysis of Object-Based Image Analysis Using Aerial and QuikBird-2 Images. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-7, pp. 31-37.

Marpu, P. R., Neubert, M., Herold, H., Niemeyer, I., 2010. Enhanced Evaluation of Image Segmentation Results. *Journal of Spatial Science*, 55(1), pp. 55-68.

Mathieu, R., Aryal, J., Chong, A. K., 2007. Object-Based Classification of Ikonos Imagery for Mapping Large-Scale Vegetation Communities in Urban Areas. *Sensors*, 7: 2860–80.

Neubert, M., & Meinel, G., 2003. Evaluation of segmentation programs for high resolution remote sensing applications. In *International ISPRS Workshop "High resolution mapping from space"*.pp.6-8.

Novelli, A.; Aguilar, M.A.; Nemmaoui, A.; Aguilar, F.J.; Tarantino, E., 2016. Performance evaluation of object based greenhouse detection from Sentinel-2 MSI and Landsat 8 OLI data: A case study from Almería (Spain). *Int. J. Appl. Earth Obs. Geoinf.*, Vol. 52, pp. 403-411.

Liu, D., Xia, F., 2010. Assessing object-based classification: Advantages and limitations. *Remote Sensing Letters*, 1(4), pp.187-194.

Liu, Y., Biana, L., Menga, Y., Wang, H., Zhanga, S., Yanga, Y., Shao, X., Wang, B., 2012. Discrepancy measures for selecting optimal combination of parameter values in object-based image analysis. *ISPRS Journal of Photogrammetry and Remote Sensing*, 68(2012), pp. 144-156.

Lucieer, A. 2004. Uncertainties in Segmentation and their Visualisation. Tesis Doctoral, Universiteit Utrecht.

Pu, R., Landry, S., Yu, Q., 2011. Object-based urban detailed land cover classification with high spatial resolution IKONOS imagery. *International Journal of Remote Sensing*, 32(12), pp. 3285-3308.

Pu, R., Landry, S., 2012. A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. *Remote Sensing of Environment*, 124(2012), pp. 516-533.



Rouse, J. W., R. H. Haas, J. A. Schell, and D. W. Deering (1973). Monitoring vegetationsystems in the Great Plains with ERTS, *Third ERTS Symposium*, NASA SP-351 I, 309-317.

Stumpf, A., Kerle, N., 2011. Object-oriented mapping of landslides using Random Forests. *Remote Sensing of Environment*, 115(2011), pp. 2564-2577.

Tarantino, E., Figorito, B., 2012. Mapping rural areas with widespread plastic covered vineyards using true color aerial data. *Remote Sensing*, 4, pp. 1913-1928.

Tian, J., Chen, D.M., 2007. Optimization in mult-scale segmentation of high resolution satellite images for artificial feature recognition. *International Journal of Remote Sensing*, 28(20), pp. 4625-4644.

Zhang, Y.J., 1996. A survey on evaluation methods for image segmentation. *Pattern Recognition*, 29(8), pp.1335-1346.



Resumen:

La última generación de satélites comerciales de muy alta resolución (VHR) abre nuevas posibilidades para las aplicaciones cartográficas y de teledetección. De esta manera, la aproximación del análisis de imágenes basada en objetos (OBIA) se ha demostrado como la mejor opción cuando se trabaja con imágenes de satélite VHR. OBIA considera atributos espectrales, geométricos, de textura y topológicos asociados a objetos de imágenes significativas. El primer paso de OBIA, conocido como segmentación, es delinear los objetos de interés. La determinación de una segmentación óptima es crucial para el éxito de la segunda etapa en OBIA, la clasificación. El objetivo principal de este trabajo es evaluar el algoritmo de segmentación de multi-resolución incluido en eCognition para delinear invernaderos a través de ortoimágenes multispectrales de WorldView-2, y encontrar la relación entre la bondad de la segmentación y la exactitud de la clasificación supervisada a través de clasificador del Vecino más Próximo (Nearest Neighbour). En concreto, la atención se centra en la búsqueda de los parámetros óptimos de la segmentación multi-resolución (Escala, Forma y Compacidad) para invernaderos de plástico. La evaluación de la calidad de la segmentación basada en las discrepancias entre los polígonos de referencia y los segmentos de imagen correspondientes se llevó a cabo para identificar la configuración óptima de los parámetros de la segmentación multi-resolución. Se utilizaron tres índices de discrepancia: Potencial de error de segmentación (PSE), Relación de número de segmentos (NSR) y Distancia Euclídea 2 (ED2). Por último, hemos demostrado que existe una clara relación entre la bondad de la segmentación en los invernaderos de plástico y la precisión de la clasificación OBIA alcanzada cuando se utilizaron las características como los índices espectrales, texturales y de vegetación. La mejor precisión global alcanzada con la mejor segmentación fue ligeramente superior al 95%

