



UNIVERSIDAD DE ALMERÍA

**ESCUELA POLITÉCNICA SUPERIOR Y FACULTAD DE
CIENCIAS EXPERIMENTALES**

**INGENIERÍA TÉCNICA AGRÍCOLA EN MECANIZACIÓN Y
CONSTRUCCIONES RURALES**

**DETECCIÓN REMOTA DE INVERNADEROS
A PARTIR DE ESTÉREO PARES PAN Y MS
DEL SATÉLITE WORLDVIEW-2
APLICANDO TÉCNICAS DE
CLASIFICACIÓN BASADA EN OBJETOS**

ALUMNO:

MIGUEL ÁNGEL MONTALBÁN AMURRIO

DIRECTORES:

DON MANUEL ÁNGEL AGUILAR TORRES

DOÑA M^a DEL MAR SALDAÑA DIAZ

AGRADECIMIENTOS

Este trabajo fin de carrera se ha podido llevar a cabo gracias al proyecto subvencionado por el Ministerio de Innovación y Ciencia del Gobierno de España y la Unión Europea (Fondos FEDER) en el marco del Proyecto de Investigación del Plan Nacional, con referencia CTM2010-16573, titulado “Generación de datos georreferenciados de muy alta resolución a partir de imágenes de los satélites GeoEye-1 y WorldView-2” .



Agradecer también el apoyo de la Junta de Andalucía a través del Proyecto de Investigación de Excelencia denominado: “Integración y análisis exploratorio de datos geoespaciales multifuente para el seguimiento y modelado de la evolución y vulnerabilidad de áreas costeras. Aplicación a una zona del Levante de Almería”, con referencia RNM-3575.



Agradecer, a mis directores de proyecto Don Manuel Ángel Aguilar Torres y Doña M^a del Mar Saldaña Díaz, por su tiempo, dedicación y apoyo. Gracias por ofrecerme este trabajo que me ha permitido adquirir gran cantidad de conocimientos del campo de la teledetección. Gracias por sus explicaciones y opiniones personales, que han hecho posible que realice este trabajo.

También agradecer el apoyo de mi familia durante todos los años que ha durado mi formación académica, por su paciencia y comprensión, además, del apoyo económico, sin ellos no hubiera sido posible realizar mis estudios.

Por ultimo agradecer a mi pareja, Ana Belén Álvarez Marín por su apoyo y ayuda durante el tiempo de mi formación universitaria.

ÍNDICE:

0.- RESUMEN.....	10-12
1.- INTRODUCCIÓN.....	13-16
1.1.- FUENTES DE INFORMACIÓN GEORREFERENCIADA.....	17-26
1.1.1 Imágenes de satélite.....	17-21
1.1.2 Modelos Digitales.....	21-23
1.1.3 Clasificación por píxeles y clasificación <i>OBIA</i>	23-24
1.1.4 Clasificación de Imágenes.....	24-26
a. Clasificación no supervisada	
b. Clasificación supervisada	
c. Clasificación mixta	
1.2.- ANÁLISIS DE IMÁGENES BASADO EN OBJETOS.....	26-38
1.2.1 El Esquema de Clasificación.....	29
1.2.2 Segmentación de imágenes con eCognition.....	30-34
1.2.2.1 Tipos de Algoritmos de Segmentación.....	30-34
a. Segmentación Multi-rresolución	
b. Segmentación <i>Chessboard</i>	
1.2.3 Clasificación de imágenes con eCognition.....	34-38
1.2.3.1 Proceso de Clasificación supervisada usando <i>Nearest Neighbor</i>	34-36
1.2.3.2 Proceso de Clasificación supervisada basada en reglas de integración del conocimiento.....	36-38
2.- INTERÉS Y OBJETIVOS.....	40-41
2.1.- INTERÉS.....	40
2.2.- OBJETIVOS.....	40-41
3.- MATERIALES Y MÉTODOS.....	42-76
3.1.- DESCRIPCIÓN DE LA ZONA DE TRABAJO.....	43-44
3.2.- MATERIALES EMPLEADOS.....	44-52
3.2.1 Ortoimagen Pansharpened.....	44-47
3.2.2 Modelo digital de superficies normalizado <i>nDSM</i>	48-50
3.2.3 Generación del Ground Truth.....	51-52
3.3.- METODOLOGÍA.....	53-76
3.3.1 Segmentación con eCognition Multi-rresolución.....	53-58
3.3.2 Segmentación con eCognition <i>Chessboard</i>	58-60
3.3.3 Mapa de referencia.....	61

3.3.4 Clasificación <i>Nearest Neighbor</i>	62-65
3.3.5 Clasificación basada en reglas de integración del conocimiento.....	66-76
a. Clasificación de vegetación	
b. Clasificación de invernaderos blanqueados	
c. Clasificación de los invernaderos tipo malla	
d. Clasificación edificios	
e. Clasificación suelo desnudo	
f. Clasificación carreteras	
g. Clasificación de invernaderos no blanqueados	
h. Clasificación otros invernaderos	
3.3.5.1 Estimación de la precisión de la clasificación.....	74-76
4.- RESULTADOS Y DISCUSIÓN.....	77-92
4.1.- RESULTADOS GLOBALES.....	78-80
4.1.1 Clasificación de vegetación.....	81-82
4.1.2 Clasificación invernaderos blanqueados cultivados.....	82-83
4.1.3 Clasificación invernaderos sin cultivar.....	83-84
4.1.4 Clasificación invernaderos tipo malla.....	84-85
4.1.5 Clasificación edificios.....	85-86
4.1.6 Clasificación suelo desnudo.....	86-87
4.1.7 Clasificación carreteras.....	87-88
4.1.8 Clasificación invernaderos no blanqueados cultivados.....	88
4.1.9 Clasificación invernaderos no blanqueados sin cultivar.....	89
4.1.10 Clasificación otros invernaderos.....	89-90
4.1.11 Resultado final.....	90-92
5.- CONCLUSIONES.....	93-95
6.- FUTUROS TRABAJOS.....	96-97
7.- BIBLIOGRAFÍA.....	98-101

ÍNDICE DE FIGURAS

Figura 1: Distribución geográfica de los invernaderos en el mundo.....	14
Figura 2: Evolución de las exportaciones de tomate de Marruecos a la UE.....	16
Figura 3: Esquema del proceso de obtención de imágenes de satélite.....	17
Figura 4: Comparación entre las longitudes de onda de las bandas almacenadas por los satélites <i>QuickBird</i> y <i>WorldView-2</i> , tanto en pancromático como en multiespectral.....	20
Figura 5: Plano analógico y <i>DEM</i>	22
Figura 6: Representación del Modelo Digital del Terreno y un Modelo Digital de Superficies. La diferencia entre los dos, nos permite obtener un Modelo Digital de Superficies normalizado (<i>nDSM</i>).....	23
Figura 7: Clasificación no supervisada.....	24
Figura 8: Clasificación supervisada.....	25
Figura 9: Proceso de análisis de imágenes mediante técnicas <i>OBIA</i>	28
Figura 10: Esquema del conjunto de segmentación jerárquica (<i>DEFINIENS, 2008b</i>). En la red jerárquica cada objeto está vinculado a su vecino, a su objeto superior y a sus objetos inferiores.....	31
Figura 11: Parámetros segmentación Multi-rresolución.....	34
Figura 12: Función de pertenencia creada por el clasificador de <i>Nearest Neighbor</i>	35
Figura 13. Función de pertenencia muestra las clases asignadas en dos dimensiones. Las muestras se representan con pequeños círculos. Los valores de pertenencia de las correspondientes clases roja y azul están sombreadas del mismo color, por lo que en áreas con objetos clasificados rojos, el valor de pertenencia azul es ignorado y viceversa.....	36
Figura 14: Situación de la zona de trabajo.....	43
Figura 15: Emplazamiento de la zona de trabajo.....	44
Figura 16: Imagen <i>PAN ORS2A de WV2 (0.5 m GSD)</i>	46
Figura 17: Imagen <i>MS ORS2A de WV2 (2 m GSD)</i>	46
Figura 18: Imagen Pansharpened (<i>RGB</i>) color verdadero de <i>WV2 (0.5 m GSD)</i>	47
Figura 19: Imagen Pansharpened (falso color, <i>NIR1, R, G</i>) de <i>WV2 (0.5 m GSD)</i>	47
Figura 20: <i>DSM</i> a partir de estéreo par <i>PAN de WV2 (1 m grid)</i>	48
Figura 21: Generación <i>DEM</i> mediante el algoritmo <i>DSMsDEM</i> de Geomática 2013.....	49
Figura 22: <i>MDE</i> a partir del <i>DSM</i> generado del estéreo par <i>PAN de WV2 (1 m grid)</i>	49

Figura 23: <i>NDSM</i> por resta del <i>DSM</i> menos el <i>MDE</i> (1 m grid).....	50
Figura 24: <i>NDSM</i> de la zona de trabajo.....	50
Figura 25: Ground Truth de los 52 invernaderos.....	51
Figura 26: a) Segmentación a partir de ortoimagen pan-sharpened de <i>WorldView-2</i> y el <i>nDSM</i> . b) Segmentación a partir ortoimagen pan-sharpened de <i>WorldView-2</i>	54
Figura 27: Datos importados para la segmentación Multi-rresolución.....	55
Figura 28: Segmentación Multi-rresolucion con el parámetro forma 0.3 y compacidad 0.5 a diferentes escalas y <i>OI</i> generados a) Escala 100, <i>OI</i> 2241 b) Escala 150, <i>OI</i> 1181 c) Escala 200, <i>OI</i> 743 d) Escala 250, <i>OI</i> 533 e) Escala 300, <i>OI</i> 399 f) Escala 350, <i>OI</i> 311.....	56
Figura 29: Segmentación Multi-rresolucion con los parámetros de forma 0.3, compacidad 0.5 y escala 200, en la que se han generado 743 <i>OI</i>	58
Figura 30: a) Detalle de la segmentación Multi-rresolución. b) Detalle de la segmentación Óptima. La segmentación Óptima completa puede ser apreciada en la figura 38.....	59
Figura 31: Configuración de la segmentación chess board sobre pixel level.....	60
Figura 32: Configuración de la segmentación Multi-rresolución sobre el nivel invernaderos, creado en el paso anterior.....	60
Figura 33: Mapa de referencia sobre la segmentación Óptima.....	61
Figura 34. a) Índices de vegetación y valores medios espectrales de las 8 bandas. b) Índices de desviación estándar de las 8 bandas y ratios de escena. c) Índices de geometría d) Características seleccionadas por el <i>FSO</i>	65
Figura 35: Imagen clase vegetación y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1</i> y <i>NIR2</i>	67
Figura 36: Imagen invernaderos blanqueados cultivados y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1</i> y <i>NIR2</i>	68
Figura 37: Imagen invernaderos blanqueados cultivados y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1</i> y <i>NIR2</i>	68
Figura 38: Imagen invernaderos con malla y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green,</i>	

<i>Yellow, Red Red-Edge, NIR1 y NIR2</i>	69
Figura 39: Imagen edificios y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2</i>	70
Figura 40: Imagen suelo desnudo y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2</i>	71
Figura 41: Imagen carreteras y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2</i>	71
Figura 42: Imagen invernaderos cultivados y no cultivados y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2</i>	72
Figura 43: Imagen invernaderos destruidos o en construcción y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras <i>Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2</i>	73
Figura 44: Proceso de clasificación por umbrales.....	74
Figura 45: Clases originales para la clasificación y agrupamiento realizado.....	75
Figura 46: a) Segmentación Multi-rresolución clasificada con <i>NN</i> . b) Segmentación Multi-rresolución clasificada por medio de reglas de interacción del conocimiento c) Segmentación Óptima clasificada con <i>NN</i> . b) Segmentación Óptima clasificada por medio de reglas de interacción del conocimiento.....	91
Figura 47: a) Mapa de referencia sobre la segmentación Multi-rresolución b) Mapa de referencia sobre la segmentación Óptima.....	92

ÍNDICE DE TABLAS

Tabla 1: Satélites de muy alta resolución existentes en la actualidad y lanzamientos previstos en los próximos años.....	18
Tabla 2. Características de las imágenes pancromáticas de <i>WorldView-2 (ORS2A)</i> adquiridas en el lugar de estudio.....	45
Tabla 3. 42 características (<i>features</i>) utilizadas para el <i>FSO</i>	63
Tabla 4: Ejemplo matriz de error.....	76
Tabla 5: Matriz de error segmentación Multi-rresolución clasificada con <i>NN</i> . Matriz de error segmentación Multi-rresolución clasificada por medio de reglas de interacción del conocimiento Matriz de error segmentación Óptima clasificada con <i>NN</i> . Matriz de error segmentación Óptima clasificada por medio de reglas de interacción del conocimiento.....	79-80
Tabla 6: Precisiones obtenidas sobre la clase vegetación.....	82
Tabla 7: Precisiones obtenidas sobre invernaderos blanqueados cultivados.....	83
Tabla 8: Precisiones obtenidas sobre invernaderos sin cultivar.....	84
Tabla 9: Precisiones obtenidas sobre mallas.....	85
Tabla 10: Precisiones obtenidas sobre edificios.....	86
Tabla 11: Precisiones obtenidas sobre suelo desnudo.....	87
Tabla 12: Precisiones obtenidas sobre carreteras.....	88
Tabla 13: Precisiones obtenidas sobre invernaderos cultivados.....	88
Tabla 14: Precisiones obtenidas sobre invernaderos sin cultivar.....	89
Tabla 15: Precisiones obtenidas sobre otros invernaderos.....	90

CAPÍTULO 0

RESUMEN

0.- RESUMEN

El objetivo de este trabajo es la detección de invernaderos aplicando técnicas de análisis de imágenes basada en objetos (*Object-Based Image Analysis, OBIA*), a partir de imágenes de satélites comerciales de muy alta resolución (*Very High Resolution, VHR*), en nuestro caso de *WorldView-2* que es actualmente el único satélite civil *VHR* que ofrece 8 bandas en su imagen multispectral (*MS*). La resolución tanto geométrica como espectral de este novedoso satélite supone un desafío en la clasificación de usos del suelo. Además, el área Mediterránea acoge una de las mayores concentraciones de invernaderos del mundo. Este sistema productivo está teniendo un gran desarrollo también en el norte de África, sobre todo en Marruecos. En este sentido, la mayor apertura del mercado de la Unión Europea a las importaciones de Marruecos, propiciada por el nuevo acuerdo agrícola, junto con el mal funcionamiento de los controles en frontera, están afectando de manera importante a la competitividad del sector agrícola de España, y por consiguiente se hace necesaria una forma automatizada de estudio del suelo dedicado a invernaderos en Marruecos, para poder obtener datos actualizados de una forma rápida.

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 *WorldView-2*, que contiene imágenes *MS* y pancromáticas (*PAN*).

El objetivo principal es desarrollar una metodología basada en la aplicación de técnicas *OBIA*, clasificando específicamente dentro de los usos del suelo, la superficie destinada a invernaderos. En las técnicas *OBIA* el primer paso consiste en la segmentación o creación de objetos que posteriormente serán clasificados. En nuestro caso se ha partido de dos segmentaciones diferentes. La primera de ellas a la que denominamos Multi-resolución se generó a partir de la ortoimagen *pan-sharpened* (imagen fusionada) de *WorldView-2* y el modelo digital de superficies normalizado (*normalized digital surface model, nDSM*), empleando el algoritmo de segmentación Multi-resolución implementado en eCognitionV.8, que fue el software *OBIA* utilizado en este trabajo. En este caso se usó una escala de 200, un factor de forma de 0.3 y un valor de compacidad de 0.5. A las 8 bandas de la ortoimagen y a la capa de información correspondiente al

nDSM, le fueron asignados pesos iguales. La segunda segmentación, a la que denominaremos segmentación Óptima, tuvo el objetivo de respetar fielmente la digitalización manual (*Ground Truth*) del contorno de los 52 invernaderos presentes en la zona de estudio. Esto se consiguió realizando una primera segmentación *chessboard* usando el archivo vectorial (*shp*) que contenía la digitalización de los 52 invernaderos como capa temática. Tras esta segmentación previa que contenía 53 objetos de interés (*OI*) o segmentos (52 invernaderos y un objeto que contenía el resto del territorio), se realizó una segmentación Multi-rresolución al nivel de los objetos obtenidos previamente. En este segundo paso, sólo los *IOs* con un tamaño superior a 400000 píxeles serían segmentados. Posteriormente se han clasificado las dos segmentaciones por dos métodos distintos: (i) Usando el clasificador supervisado *Nearest Neighbor* (*NN*) implementado en eCognition, que realiza la clasificación en virtud de las características previamente obtenidas de unas áreas de entrenamiento. Estas características fueron obtenidas, empleando la herramienta de optimización del espacio de características (*Features Space Optimización, FSO*), incluida en eCognition. (ii) La segunda clasificación basada en reglas de integración del conocimiento, clasifica las clases usando umbrales, relativos a las 8 bandas, índices de vegetación, *nDSM*.

Los índices de precisión de la clasificación usados en este trabajo estuvieron basados en la matriz de error. El mejor de los casos ensayados, fue cuando la clasificación se realizó con *NN* por medio de áreas de entrenamiento y partiendo de una clasificación óptima. En este caso se obtuvieron precisiones globales de 92.4%. En el caso de la clasificación por medio de umbrales, partiendo de una segmentación Óptima, las precisiones globales obtenidas son del 87%. En los casos de la segmentación Multi-rresolucion, la clasificación por medio de *NN* obtuvo unos resultados de precisión globales de 84.4% y la clasificación por medio de umbrales del 66,4%.

CAPÍTULO 1

INTRODUCCIÓN

1.- INTRODUCCIÓN

La superficie de invernaderos en el mundo se concentra en dos áreas geográficas: en el Extremo Oriente (especialmente China, Japón y Corea) se agrupa el 80% de los invernaderos del mundo, en la cuenca mediterránea cerca de un 15% y el 5% restante, se concentra en los países de América central y en países del sur de África (Figura 1). En lo referente a los países europeos del área mediterránea, el crecimiento en superficie de invernaderos es lento, pero en los países de la cuenca mediterránea pertenecientes a África y en Oriente Medio está siendo del 15 al 20% anual.

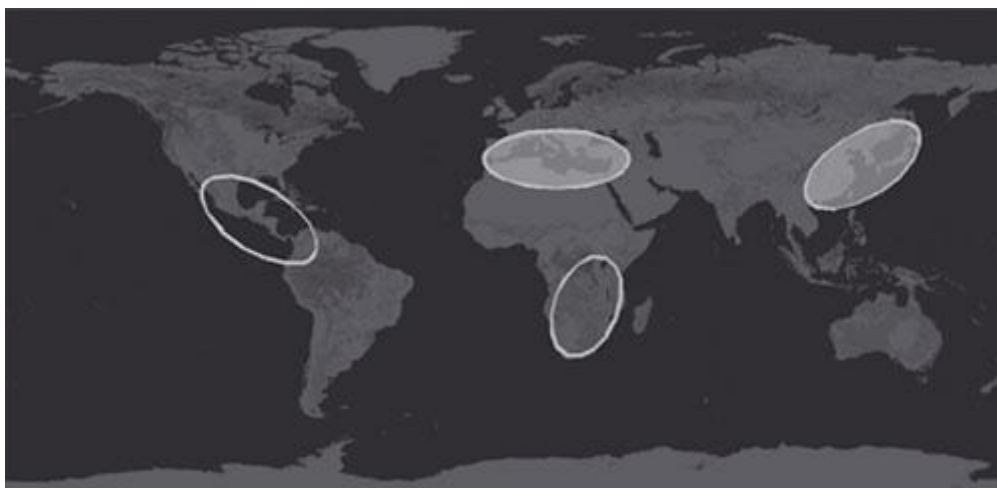


Figura 1: Distribución geográfica de los invernaderos en el mundo. (Fundacion Cotec, 2009)

El área mediterránea acoge una de las mayores concentraciones de cultivos protegidos del mundo con más de 400.000 Ha. España es una muestra del rápido desarrollo de los invernaderos que ha tenido lugar en las últimas décadas, situándose a la cabeza de los países mediterráneos y europeos en superficie dedicada a invernaderos con 66.000 Ha (Magrama, 2008), aunque su crecimiento se ha frenado en los últimos años. Tras España, seguido y a gran distancia estarían Italia, Turquía y Marruecos. Los dos últimos son los mercados emergentes que más están creciendo en esta actividad, en el caso de Marruecos la superficie de cultivos protegidos ha pasado de 11.000 Ha en 1999 (FAO, 2002) a 17.000 Ha en 2006 (Torrens, 2006). La agricultura es además uno de los

sectores económicos de relevancia en las relaciones bilaterales entre España y Marruecos. El convenio, pactado por europeos y marroquíes hace cerca de cuatro años (en noviembre de 2009), que liberaliza el comercio agroalimentario mutuo, muy conocido y criticado en España por las concesiones a las importaciones de frutas y hortalizas. Entra en vigor tras una larga y controvertida tramitación en las instituciones de la Unión Europea (UE), durante la cual se han oído muchas quejas de los agricultores españoles, de zonas como Canarias, Andalucía, Murcia o la Comunidad Valenciana.

Las asociaciones españolas que representan a los exportadores hortofrutícolas (*Fepex*) y las organizaciones agrarias han advertido del impacto que puede tener el nuevo acuerdo con el país norteafricano por las concesiones a sus productos. Entre las concesiones europeas a los productos marroquíes, las más polémicas son los incrementos de cuotas de frutas y verduras que ese país podrá vender con un trato ventajoso al mercado comunitario. La UE aprobó los llamados "precios de entrada" que en general gravan las importaciones de fruta y verdura, para garantizar que se venden a una cotización mínima en el mercado europeo, aunque las organizaciones del sector hortofrutícola han denunciado insistentemente que la burla de ese sistema ha provocado la inundación del mercado europeo de frutas y verduras marroquíes, que coinciden en el calendario de exportación con las de Canarias, Almería o Murcia.

El principal producto exportado por Marruecos a la UE es el tomate y su entrada al mercado comunitario viene incrementándose de manera constante en los últimos años (figura 2). Entre las campañas 1999/2000 y 2008/2009 se ha producido un aumento del 97,8%, pasando de 184.776 tn en la 1999/00 hasta las 365.499 tn record de la campaña 08/09. También se acrecientan las concesiones de importación con trato preferente para productos como fresas, calabacines, pepinos, ajos y clementinas.




Figura 2: Evolución de las exportaciones de tomate de Marruecos a la UE

Fuente: elaboración a partir de datos de la Comisión Europea-Comext (2009)

De esta forma se pone de manifiesto la necesidad de poder conocer y actualizar los datos de usos del suelo del país magrebí, y así tener datos de su superficie real dedicada a invernaderos. Este conocimiento de la superficie de invernaderos nos permitirá poder estimar la producción de cultivos hortícolas, en el caso de obtener información del tipo de invernadero y el estado de desarrollo de la plantación que alberga, podremos identificar el tipo de cultivo al que está dedicado, puesto que los diferentes cultivos utilizan distintos medios de protección y su cultivo se realiza en épocas más o menos diferenciadas. Esta información se puede obtener a través de imágenes de satélite de muy alta resolución (*Very High Resolution, VHR*). Tradicionalmente, la extracción de información espacial de imágenes procedentes de sensores remotos ha sido llevada a cabo de forma manual. Sin embargo, este tipo de tareas son lentas, requieren operadores bien entrenados, y son por consiguiente caras. Por eso se hace necesaria una metodología de técnicas que automaticen lo máximo posible la extracción de la información espacial de imágenes procedentes de sensores remotos. En este trabajo intentaremos generar una metodología para clasificar usos de suelo, a partir de imágenes del satélite *Worldview-2*, mediante técnicas de análisis de imágenes basado en objetos (*Object-Based Image Analysis, OBIA*).

1.1.- FUENTES DE INFORMACIÓN GEORREFERENCIADA

1.1.1 Imágenes de satélite

La teledetección se conoce como el conjunto de conocimientos y técnicas para determinar características físicas y biológicas de objetos mediante mediciones a distancia, sin el contacto material de los mismos (*Lasselin y Darteyre, 1991*) (Figura 3).

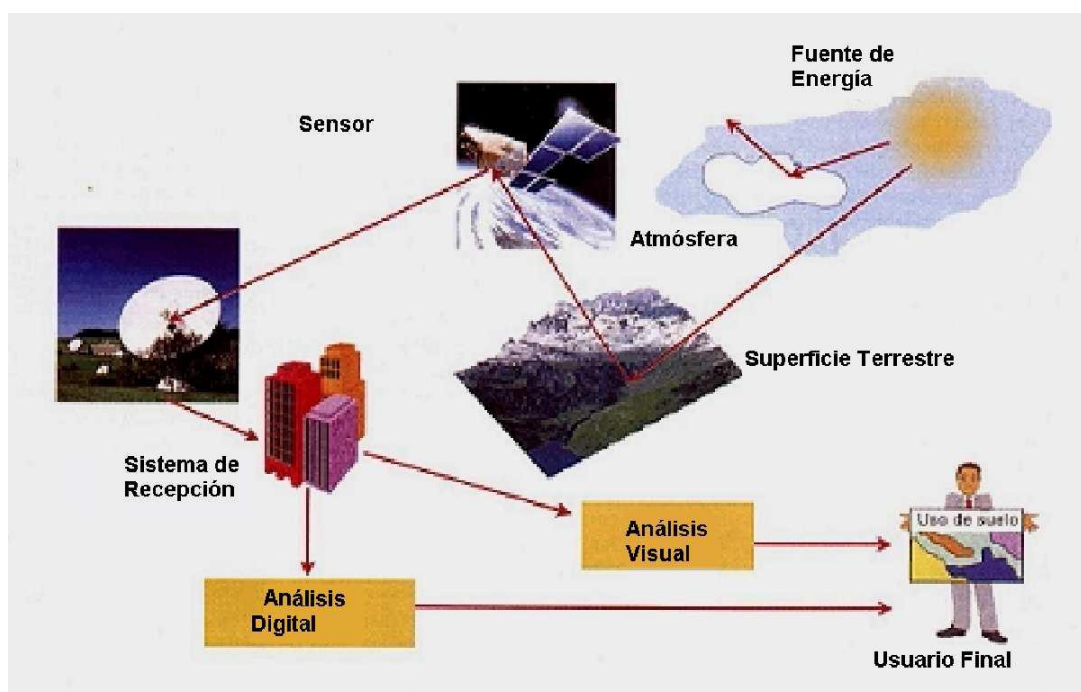


Figura 3: Esquema del proceso de obtención de imágenes de satélite

La teledetección comenzó en 1859 con la utilización de cámaras fotográficas a bordo de globos sobre la ciudad de París por Gaspar Félix de TourNación, en 1904 se realizó el primer mapa topográfico a partir de fotografías aéreas por *Fourcade*. En 1957 se envía el primer satélite al espacio lanzado por la Unión Soviética (*Sputnik*) que contaba con dos transmisores de radio (20,007 y 40,002 MHz), al que siguieron numerosos satélites meteorológicos. A finales de la década de los 90 la última serie de satélites comerciales de muy alta resolución (*VHR*) abre nuevas posibilidades para las aplicaciones de cartografía y teledetección. Una de las aplicaciones más comunes en teledetección es la extracción de información de cobertura de suelo, para efectuar mapas

temáticos de usos del suelo por medio de técnicas de clasificación automatizadas. Actualmente existen orbitando sobre la tierra y recogiendo imágenes de su superficie doce satélites comerciales *VHR*. Estos satélites se caracterizan por tener una gran resolución geométrica en sus bandas pancromáticas (*PAN*) y multiespectrales (*MS*) (Tabla 1). La gran proliferación de este tipo de satélites en los últimos años ha supuesto una mejora en la disponibilidad y coste de estos productos.

Satélite	País	Lanzamiento	Resolución <i>PAN</i> (m)	Resolución <i>MS</i> (m)	Tamaño Escena (km)
IKONOS	US	09/24/99	1.0	4	11
QuickBird	US	10/18/01	0.61	2.44	16
EROS B1	Israel	04/25/06	0.7		7
Resurs DK-1	Rusia	06/15/06	1.0	3	28
KOMPSAT-2	Korea	07/28/06	1.0	4	15
IRS Cartosat 2	India	01/10/07	0.8		10
WorldView-1	US	09/18/07	0.5		16
GeoEye-1	US	06/09/08	0.41*	1.65*	15
WorldView-2	US	08/10/09	0.46*	1.84*	16
Pleiades-1	Francia	16/12/11	0.7	2.8	20
Pleiades-2	Francia	02/12/12	0.7	2.8	20
KOMSAT-3	Korea	17/05/12	0.7	3.2	20
GeoEye-2	US	Previsto 2013	0.34*	1.36*	14.5
WorldView-3	US	Previsto 2014	0.31*	1.24*	16

Tabla 1: Satélites de muy alta resolución existentes en la actualidad y lanzamientos previstos en los próximos años

El primer satélite de muy alta resolución denominado *IKONOS*, fue lanzado en 1999 por la empresa *Espaceimage (USA)* y es capaz de captar imágenes terrestres tanto en modo *PAN*, con 0.82 m (*Ground Sample Distance, GSD*) (remuestreadas a 1 m) de tamaño de píxel, como *MS*, con un tamaño de píxel de 3.28 m *GSD* (remuestreado a 4 m) y cuatro bandas (*R-rojo, G-verde, B-azul e NIR-infrarrojo cercano*). En 2001 fue lanzado el satélite *QuickBird*, de *DigitalGlobe (USA)*, con una resolución en el nadir de 0.61 m y 2.44m *GSD* en *PAN* y *MS* (*R, G, B e NIR*) respectivamente, lo que le ha otorgado, hasta hace poco tiempo, el honor de ser el satélite comercial con la mayor resolución espacial.

En 2008 se lanzó *GeoEye-1* un satélite comercial estadounidense *VHR*, es actualmente el satélite comercial que ofrece una mayor resolución espacial con un tamaño de píxel de 0.41 m en pancromático y 1.65 m, aunque las limitaciones actuales que pone el gobierno de Estados Unidos no permiten la comercialización de imágenes de satélite con una resolución superior a 0.50 m *GSD* en *PAN* y 2 m *GSD* en *MS*. Los primeros resultados de georreferenciación y ortorectificación obtenidos con escenas de *GeoEye-1* están siendo bastante superiores a los que se habían obtenido hasta ahora usando escenas de otros satélites comerciales de muy alta resolución como *Ikonos* o *QuickBird*. *Fraser y Ravanbakhsh (2009)* han conseguido precisiones verticales de 0.25 m y horizontales de 0.10 m con un estéreo-par de *GeoEye-1*. *Croft (2008)*, incluso llegó a calificar de prodigiosas las capacidades de *GeoEye-1* para la generación de mapas.

En 2009 se lanzó *WorldView-2* un nuevo satélite comercial norteamericano, este nuevo satélite, que es capaz de capturar imágenes con una gran resolución geométrica en imágenes *PAN* (0.46 m *GSD*) y *MS* (1.84 m *GSD* aunque ligeramente inferior a la obtenida por *GE-1*). La banda *PAN* tiene un rango espectral desde 450 hasta 800nm. Sin embargo, su principal novedad es que tiene la capacidad de almacenar 8 bandas en la imagen *MS*: *Coastal Blue* (400-450 nm), *Blue* (450-510 nm), *Green* (510-580 nm), *Yellow* (585-625 nm), *Red* (630-690 nm), *Red-Edge* (705-745nm), *NIR1* (770-895 nm) y *NIR2* (860-1040 nm), ya que todos los satélites anteriores solo contenían 4 bandas *MS* con unas longitudes de onda parecidas (*R,G,B* y *NIR*) (Figura 4). Su alta resolución espacial permite la detección de detalles pequeños, y su alta resolución espectral lo

capacita para obtener información detallada sobre superficies asfaltadas, profundidad del mar, o incluso sobre el estado de salud de cultivo.




Figura 4: Comparación entre las longitudes de onda de las bandas almacenadas por los satélites *QuickBird* y *WorldView-2*, tanto en pancromático como en multiespectral

Las dos compañías punteras en la comercialización de imágenes de satélite *VHR*, *DigitalGlobe* y *GeoEye*, llegaron a un acuerdo de fusión, el pasado verano. Actualmente operan bajo el nombre de *DigitalGlobe* y tienen previsto para los años 2013 y 2014 el lanzamiento de dos nuevos satélites que se denominarán *GeoEye-2* y *WorldView-3*. Ambos tendrán una resolución geométrica en *PAN* y *MS* impensable hace tan sólo una década. Además *WorldView-3* será el primer satélite *VHR* “super-espectral”, ya que contará con 8 bandas espectrales (coincidentes con las que ya implementa *WorldView-2*) con 1.24m de *GSD* en el nadir, y otras 8 nuevas bandas en el rango de longitudes de onda que va desde los 1400 nm a los 3000 nm. Estas nuevas bandas en el Infrarrojo de onda corta (*Short Wave Infrared, SWIR*) tendrán una resolución de 3.7 m *GSD* y permitirán operar en condiciones atmosféricas adversas (niebla, humos, polvo en suspensión...). Como podemos observar, aunque los satélites *VHR* llevan con nosotros sólo algo más de una década, los progresos técnicos que han sufrido durante este corto período de tiempo han sido de tal magnitud que están abriendo un amplio e interesante campo de investigación.

Desde el lanzamiento de los dos primeros satélites *VHR*, *IKONOS* y *QuickBird*, muchos investigadores los han considerado como posibles sustitutos de las clásicas imágenes

aéreas para la obtención de cartografía a grandes escalas (*Fraser, 2002a; Kay et al., 2003; Chmiel et al., 2004; Pecci et al., 2004; Aguilar et al., 2006; Aguilar et al., 2007a*). Además, las imágenes de satélites *VHR* han sido utilizadas para numerosas aplicaciones como son: la detección de edificios (*Fraser et al., 2002b; Weber y Ranchin, 2003; Lee et al., 2003; Kim et al., 2006; Mayunga et al., 2007; Gamba et al., 2007*), mapeado automático de carreteras (*Yan y Zhao, 2003; Jin y Davis, 2005*), clasificación de vegetación (*Nichol y Lee, 2005; Castillejo-González et al., 2009; Martínez-Casasnovas et al., 2009*), detección de invernaderos (*Agüera et al., 2006; Agüera et al., 2008*), e incluso localización de daños ocasionados por desastres naturales (*Al-Khudhairy et al., 2005*).

1.1.2 Modelos Digitales

Una gran fuente de información en las clasificaciones *OBIA* son los modelos digitales. Un modelo digital de elevaciones (*Digital Elevation Models, DEM*) es una representación digital y matemática de un terreno existente o virtual, por medio del almacenamiento de las elevaciones de tierra que sustituye, en cierto modo, a los planos analógicos basados en curvas de nivel (Figura 5). Existen diversas maneras de obtener un *DEM*, ya sea aplicando interpolación de datos puntuales, a partir de curvas de nivel digitalizadas, extrayéndolos de pares estereoscópicos de fotografías aéreas o imágenes de satélite mediante procedimientos fotogramétricos,... (Oñate-Valdivieso, 2007). Se acepta que la elevación representada en un *DEM* es la altura ortométrica a partir de un geoide de referencia. Podemos destacar dos sistemas de referencia: (i) El sistema geodésico oficial español es el *Europea Datum 50* establecido como oficial en el Decreto 2303/1970. El *ED50* es un sistema de referencia local basado en el elipsoide internacional de Hayford de 1924 y cuyo sistema de representación plano es la proyección conforme *Universal Transversa de Mercator (UTM)*, (ii) El sistema de referencia *WGS84* es el sistema utilizado por la técnica de posicionamiento de *GPS*. Es un sistema global geocéntrico (el origen de coordenadas es el centro de masas de la Tierra). Un *DEM*, se acepta que se trata de la elevación de la superficie del terreno por lo que deberíamos obviar estructuras como edificios o elementos como árboles. En el caso de incluir estos elementos, se suele hablar de modelos digitales de superficie (*Digital Surface Models, DSM*). Este término se está usando cada vez con mayor frecuencia debido a que algunos nuevos métodos de captura de datos de elevación

(LIDAR, por ejemplo) incluyen todos los elementos superficiales, sin aislar el terreno del resto de estructuras.




Figura 5: Plano analógico y DEM

Un modelo digital de superficies normalizado (*Normalized Digital objetos Surface Modal; nDSM*) se genera mediante la sustracción del DEM a un DSM, y solo contendrá los objetos sobre el terreno. En la Figura 6 puede observarse la diferencia entre un DEM también conocido como modelo digital del terreno (*MDT*) y un DSM.




Figura 6: Representación del Modelo Digital del Terreno y un Modelo Digital de Superficies. La diferencia entre los dos nos permite obtener un nDSM

Los satélites *VHR* ofrecen la posibilidad de generación de *DEM* a partir de estéreo pares de imágenes, pudiéndose obtener errores medios cuadráticos (*root mean squared error*, *RMSE*) de entre 1 a 2 veces el tamaño de píxel, dependiendo, entre otros factores, de lo accidentado de la orografía, del sensor usado, del modelo de sensor utilizado en la triangulación y de la calidad de los *GCPs* empleados (*Ridley et al., 1997; Toutin 2004; Toutin 2006; Aguilar et al., 2007b*). Estos errores han sido mucho menores, en torno a 0.5 veces el tamaño de píxel terreno (*GSD*), cuando el *DEM* fue generado a partir de un estéreo par de *GE-1* (*Fraser y Ravanbakhsh, 2009*).

1.1.3 Clasificación por píxeles y clasificación OBIA

Una clasificación basada en objetos se compone siempre de dos etapas: la segmentación de la imagen y la clasificación. La primera consiste en la formación de objetos mediante la unión de píxeles, posteriormente la clasificación se realiza utilizando las características de los objetos. Se ha comprobado que este enfoque es capaz de ofrecer mejores resultados que los obtenidos por un enfoque tradicional basado en píxeles (*Blumberg y Zhu, 2007; Chen et al., 2007; Platt y Rapoza, 2008; Smith, 2008; Yan et al., 2006*), muy especialmente cuando se trata con imágenes de alta resolución espacial (*Lu y Weng, 2007; Yu et al., 2006*). Además, se han señalado otras ventajas del análisis de imágenes basado en objetos frente al enfoque basado en píxeles (*Jyothi et al., 2008; Lang, 2008; Liua y Xiab, 2010*): la segmentación reduce la variabilidad espectral intra-clase; pone a disposición del análisis un gran número de variables para caracterizar desde el punto de vista estadístico las clases; el uso de objetos reduce en orden de

magnitud el número de elementos a procesar por el clasificador estadístico, de manera que es posible el uso de técnicas más complejas. Pero también es posible encontrar algunas desventajas, como que los resultados de la clasificación son muy sensibles a la calidad de la segmentación (Hermosilla Gómez, 2011; Liua y Xiab, 2010; Recio Recio, 2009).

1.1.4 Clasificación de imágenes

La mayoría de las técnicas usadas para la extracción de información son clasificaciones basadas en parámetros estadísticos deducidos de zonas de la imagen estudiada cuya realidad se conoce como clasificación supervisada, clasificación no supervisada y clasificación mixta.

a. Clasificación no supervisada

Es un método computarizado sin ninguna dirección desde el análisis en el que con número digital similar son agrupados en clases espectrales utilizando procesos estadísticos como el vecino más cercano y análisis en grupo. La imagen resultante puede ser entonces interpretada mediante comparación de los grupos generados con mapas, fotos aéreas y otros materiales relacionados con la imagen (Figura 7).




Figura 7: Clasificación no supervisada

b. Clasificación supervisada

En una clasificación supervisada el analista identifica algunas áreas en la imagen que representan características conocidas, o cubiertas. Estas áreas conocidas se denominan áreas de entrenamiento, donde grupos de píxeles u objetos son buenos representantes de una cubierta o fenómeno. Utilizando la información del píxel, el ordenador mediante un algoritmo busca en las restantes áreas que tienen similar asociación y valor de píxel. El analista decide sobre las áreas de entrenamiento y así supervisa el proceso de clasificación (Figura 8).




Figura 8: Clasificación supervisada

c. Clasificación mixta

Tanto el método supervisado como el no supervisado cuentan con ventajas e inconvenientes. El primero resulta muchas veces subjetivo, pues el usuario establece a priori unas categorías sin valorar las características espectrales de la imagen. El segundo, no asegura que las clases deducidas tengan significado para el usuario del producto, además de ser de difícil verificación.

Con objeto de paliar los inconvenientes de ambos métodos, se han propuesto diversas alternativas que los combinan de alguna forma (Pinilla, 1995). Estos métodos mixtos pueden agruparse en dos bloques:

- Por un lado, se sitúan aquellos trabajos que emplean el análisis supervisado para “guiar” el no supervisado. En este caso, el conocimiento del intérprete se utiliza para orientar la búsqueda de esos grupos espectrales homogéneos.
- Por otro lado, el análisis supervisado y el no supervisado pueden combinarse gracias a aplicarlos separadamente sobre la misma imagen para luego sintetizar las medidas extraídas por ambos. Se asume que las categorías deducidas por los dos métodos pueden complementarse mutuamente, ganando en significado espectral e informacional de las clases resultantes.

1.2.- ANALIS DE IMÁGENES BASADO EN OBJETOS

Tradicionalmente, la generación de información cartográfica sobre usos o coberturas del suelo se ha realizado mediante técnicas de fotointerpretación apoyadas en revisiones de campo, utilizando como fuente principal de información fotografías aéreas de escalas similares a las que actualmente ofrecen las imágenes de satélite de alta resolución espacial. El problema de esta metodología es que es muy intensiva en mano de obra especializada, requiere mucho tiempo y está notablemente influenciada por la subjetividad de los técnicos. Hasta finales de los 90 la gran mayoría de los métodos de clasificación utilizaban como elemento de análisis el píxel. Este enfoque ha sido el predominante durante tres décadas, hasta que se planteó una cuestión crítica: por qué tanta preocupación en el análisis estadístico de los píxeles sin prestar atención alguna a los patrones espaciales que generan (Blaschke y Strobl, 2001).

Mediante las técnicas *OBIA* se permite explotar todas las dimensiones contenidas en las imágenes de teledetección, incluyendo aspectos espectrales, espaciales, contextuales, morfológicos y temporales, superando algunos de los inconvenientes asociados a los clasificadores estadísticos basados únicamente en la respuesta espectral de los píxeles:

-El procesamiento de las imágenes se convierte en un proceso iterativo, de forma que es posible la extracción de información semántica tras los procedimientos iniciales de clasificación.

-La información espacial tenida en cuenta incluye proximidad, accesibilidad, conexiones con elementos próximos, etc. Así, se pueden emplear procedimientos estadísticos que evalúen estas variables y permitan una mejora en la clasificación.

-Aunque las características espectrales son la mayor fuente de información para la clasificación, según aumenta la resolución espacial de las imágenes, las características texturales y contextuales se convierten en información que es muy conveniente tener en cuenta.

-El uso de una estructura jerárquica permite identificar elementos presentes en las imágenes no sólo por su comportamiento espectral, sino también por la pertenencia a una jerarquía superior. Así, por ejemplo, se puede obtener un aumento de la exactitud en zonas residenciales de baja densidad o en zonas urbanas que incluyan espacios verdes.

Una clasificación basada en objetos se compone siempre de dos etapas: la segmentación de la imagen y la clasificación (Figura 9). La primera consiste en la formación de objetos mediante la unión de píxeles, posteriormente la clasificación se realiza utilizando las características de los objetos. Se ha comprobado que este enfoque es capaz de ofrecer mejores resultados que los obtenidos por un enfoque tradicional basado en píxeles (Blumberg y Zhu, 2007; 2007; Platt y Rapoza, 2008; Smith, 2008; Yan et al., 2006), muy especialmente cuando se trata con imágenes de alta resolución espacial. Además, se han señalado otras ventajas del análisis de imágenes basado en objetos frente al enfoque basado en píxeles (Jyothi et al., 2008; Lang, 2008; Liu y Xia, 2010): la segmentación reduce la variabilidad espectral intra-clase; pone a disposición del análisis un gran número de variables para caracterizar desde el punto de vista estadístico las clases; el uso de objetos reduce en orden de magnitud el número de elementos a procesar por el clasificador estadístico, de manera que es posible el uso de técnicas más complejas; y, por último, reduce el efecto sal y pimienta. Pero también es posible

encontrar algunas desventajas, como que los resultados de la clasificación son muy sensibles a la calidad de la segmentación (Gómez, 2011; Liu y Xia, 2010; Recio, 2009).

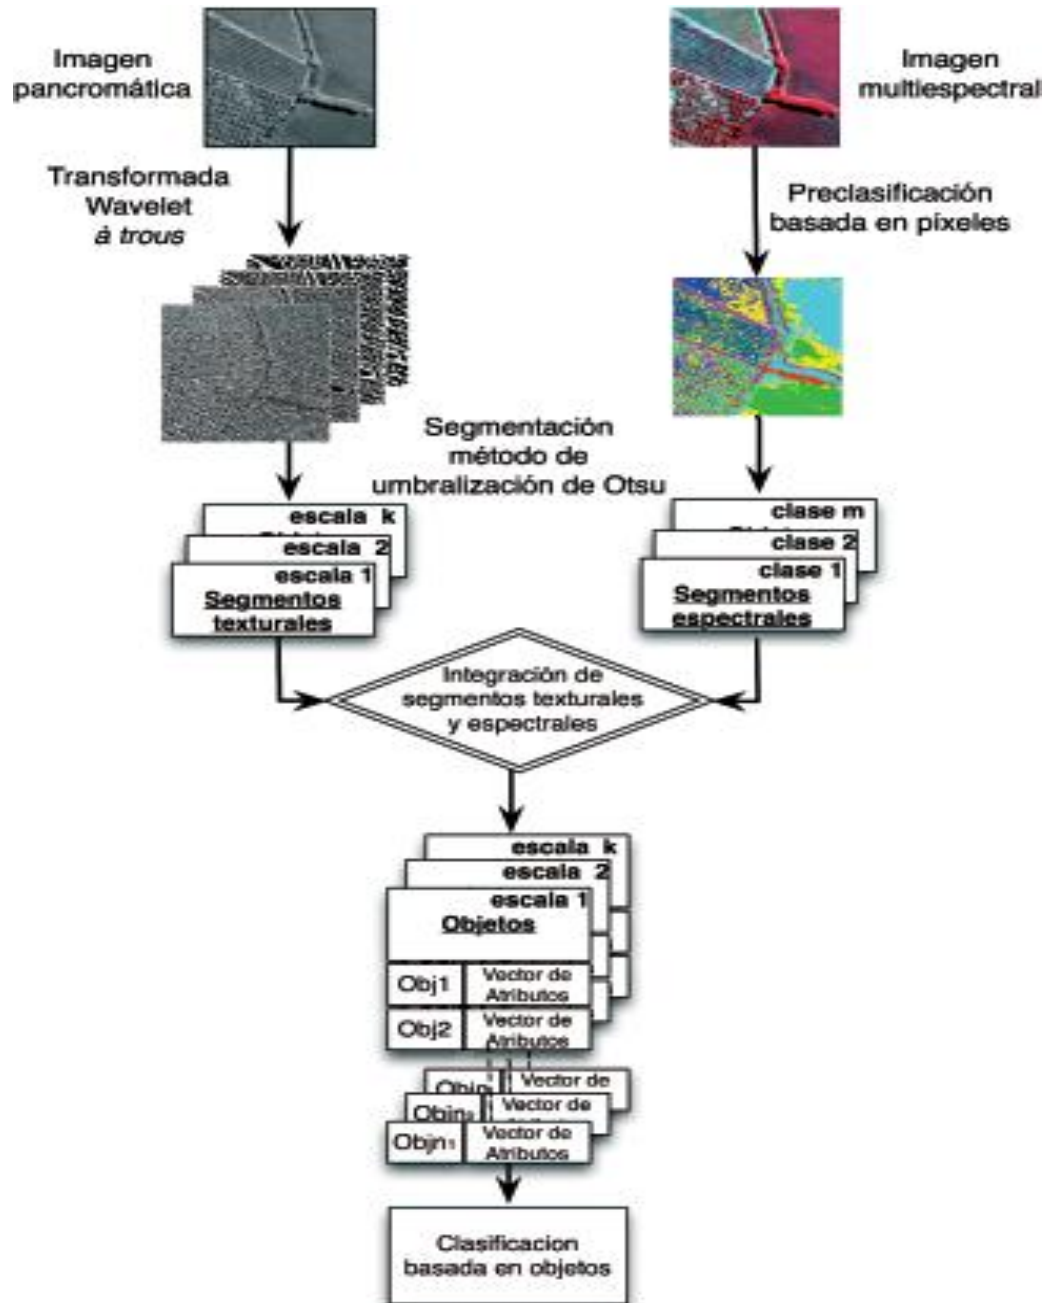


Figura 9: Proceso de análisis de imágenes mediante técnicas OBIA

1.2.1 El Esquema de Clasificación

El esquema de clasificación es el conjunto de clases en las que se pretende categorizar la zona de estudio y a las que puede ser asignado cada elemento del mapa temático, cada objeto. Es un aspecto fundamental de todo el proceso de análisis efectuado sobre las imágenes en un principio, y sobre los objetos con posterioridad. Este apartado se basa en el trabajo de Congalton y Green (2009), autores que han profundizado en el tema y cuyo aspecto más destacable es su capacidad para relacionar claramente el esquema de clasificación con el resto de cuestiones importantes en la evaluación de la exactitud en la clasificación de imágenes de teledetección.

En el esquema de clasificación se especifican las categorías del mapa temático, así se convierte en una herramienta conceptual para organizar la información espacial de una forma ordenada y lógica. El esquema de clasificación es muy importante en cualquier proyecto relacionado con la identificación de coberturas o usos del suelo, porque hace posible para el productor de la cartografía la caracterización de los elementos del paisaje, y para el usuario, la capacidad de reconocerlos. Si no se diseña un esquema de clasificación riguroso, no se puede realizar un trabajo de evaluación de la exactitud de forma adecuada, ya que será difícil identificar con claridad la correspondencia entre las muestras y el resultado de la clasificación. Tiene dos componentes críticos:

-Un conjunto de etiquetas mutuamente exclusivas y totalmente exhaustivas.

-Un conjunto de reglas que sirven para asignar las etiquetas, sin las que la asignación de las etiquetas a las clases podría ser arbitraria y con falta de consistencia.

Lu y Weng (2007) han señalado otros aspectos a tener en cuenta en la elaboración de un esquema de clasificación: necesidades del usuario de la cartografía; resolución espacial de las imágenes utilizadas; compatibilidad con estudios anteriores; disponibilidad de algoritmos de procesamiento de imágenes y clasificación; y tiempo disponible para la realización del trabajo.

1.2.2 Segmentación de imágenes con eCognition

Este punto trata sobre la segmentación de imágenes, un aspecto específico del análisis de imágenes basado en objetos que lo diferencia de manera sustancial del más tradicional en teledetección, el basado en píxeles. Segmentación es el proceso de dividir imágenes digitales en unidades cohesivas espacialmente, también llamadas objetos o regiones (Ryherd y Woodcock, 1996). Los objetos creados a partir de la segmentación deben ser, además de unidades discretas, contiguos y sin intersecciones entre ellos. Los píxeles que los componen normalmente presentan un elevado grado de homogeneidad interna.

1.2.2.1 Tipos de algoritmos de segmentación

-Los algoritmos de clasificación no supervisada se pueden considerar uno de los primeros intentos de segmentación de imágenes en teledetección. Estos miden la capacidad de formar grupos de los datos de partida mediante la delimitación de *clusters* en el espacio de datos de d -dimensiones. Dos de los métodos más utilizados son *k-means* e *isodata* (Adams y Gillespie, 2006).

-Los algoritmos basados en la identificación de bordes tratan de localizar los píxeles que funcionan como límites de los elementos del mundo real. A partir de estos se forman los objetos. Presentan varios problemas para su uso en imágenes de teledetección, por ejemplo, son muy sensibles al ruido de la escena y dividen objetos homogéneos por diferencias en iluminación. Además, la identificación de bordes es muy complicada en imágenes multiespectrales. En Escalera (2001) se puede encontrar una descripción de los algoritmos más utilizados.

-Los algoritmos basados en el crecimiento de regiones consisten en la agrupación de píxeles a partir de un conjunto de semillas distribuidas por la imagen en función de un criterio establecido de antemano. El método forma parte de los que funcionan de abajo a arriba (*bottom-up*), ya que comienza con píxeles individuales y finaliza con segmentos que son agrupaciones de estos, en el caso extremo, la imagen completa. Un aspecto muy importante de esta técnica es el criterio de crecimiento de las regiones, que irá determinando la asociación de los píxeles a los objetos ya formados.

Por ejemplo, la diferencia entre el nivel digital de un píxel y la media de nivel digital de un objeto, puede determinar su inclusión o no inclusión. A partir de estos métodos se ha formulado el concepto de segmentación jerárquica (Marpu, 2009), donde los objetos quedan representados en diferentes niveles, tal y como se muestra en la Figura 10. La geometría de los diferentes niveles viene determinada por el umbral que se haya definido en el criterio de agrupación, también llamado criterio de heterogeneidad.

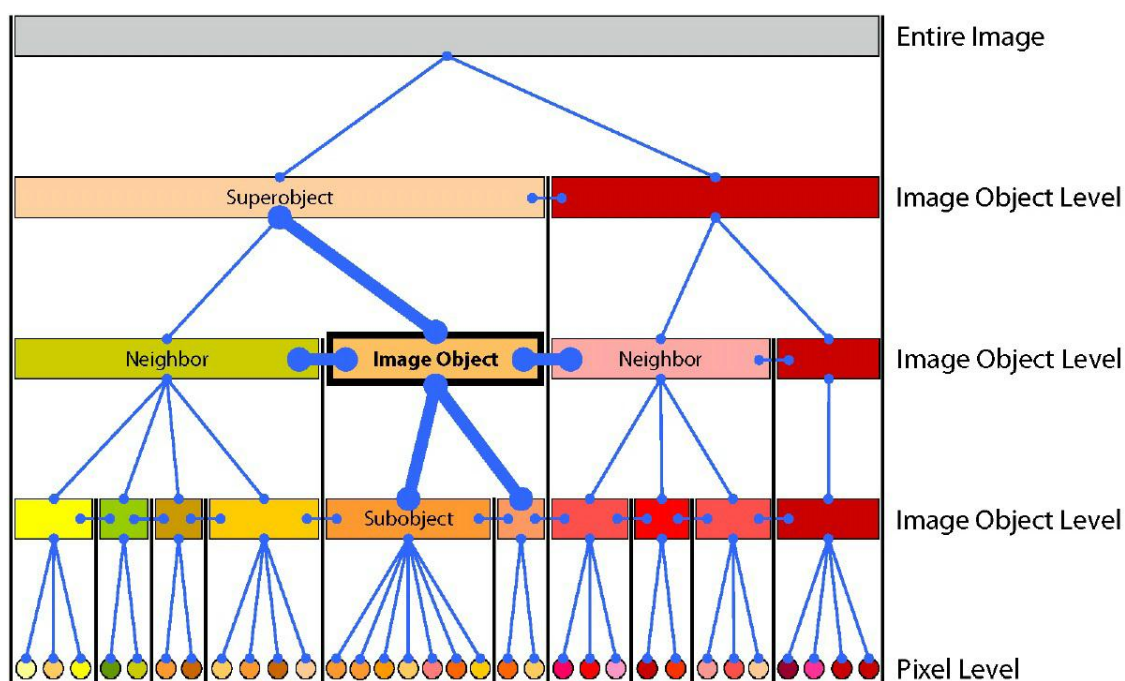


Figura 10: Esquema del concepto de segmentación jerárquica (DEFINIENS, 2008b). En la red jerárquica cada objeto está vinculado a su vecino, a su objeto superior y a sus objetos inferiores.

En los siguientes apartados se profundizará en este último tipo de segmentación, ya que es la más habitual de utilizar actualmente. De hecho está implementada en el software *OBIA* de referencia denominado *eCognition* (Definien, 2009), ofrece varios enfoques para la segmentación, que van desde algoritmos muy simples, tales como tablero de ajedrez (segmentación *chessboard*) y la segmentación *quadtree*, y otros basados en métodos altamente sofisticados como son segmentación Multi-resolución y la segmentación de filtro de contraste.

a. Segmentación Multi-rresolución

El algoritmo de segmentación Multi-rresolución, en un procedimiento de optimización que, para un determinado número de objetos de interés *IOs*, minimiza la heterogeneidad media y maximiza su respectiva homogeneidad, consiguiendo generar objetos tan grandes como sea posible y tan detallados como sea necesario para permitir la separación entre regiones, utiliza tanto color como le sea posible, manteniendo la forma tan alta como sea necesario para obtener objetos con el borde óptimo (suavidad y compacidad). Al darle peso a la forma, se le resta peso a la homogeneidad espectral de los objetos. Con este método se optimiza el tiempo de procesamiento.

El resultado de este algoritmo de segmentación es controlado por tres términos principales, tales como Figura 11:

- El criterio de homogeneidad o el parámetro de escala, es un término abstracto que determina la heterogeneidad máxima permitida para los objetos de la imagen resultante. A partir de datos heterogéneos, los objetos resultantes de un parámetro de escala dado serán menores que en para datos originales más homogéneos. Esto quiere decir que modificando el valor de este parámetro, se modifica el tamaño de los objetos de la imagen. El objetivo debe ser la producción de los objetos de imagen de la mayor escalan posible en los que todavía se distinguían las diferentes regiones de la imagen que deban ser clasificadas.
- Capas de la imagen y pesos. El sistema permite la selección de las capas de información que van a ser empleadas para la realización de la segmentación. Esto quiere decir que no todas las capas tienen que ser obligatoriamente tenidas en cuenta en este paso. Las capas de la imagen pueden ser ponderadas para considerar las capas en función de su importancia o la idoneidad para el resultado de la segmentación requerida. Cuanto mayor sea el peso asignado a una capa de imagen, más peso se le asignara a la información de los objetos de la capa durante el proceso de segmentación, en el supuesto de que la segmentación utilizara información de los objetos. En consecuencia, las capas de imagen que no contienen la información destinada a la representación de los *IO* de la imagen se debe dar poco o ningún peso.

-El peso de la compacidad y los criterios de suavizado (forma y compacidad).

Parámetro de Forma: Este parámetro constituye el criterio de homogeneidad que va a ser aplicado en la segmentación mediante la ponderación entre los parámetros de forma y color. El valor del campo forma se modifica con la relación entre la forma y el color (información de los niveles digitales), de forma que al modificar el umbral o peso que se le da a la forma, se está cambiando complementariamente el peso del color ($\text{color} = 1 - \text{forma}$). En efecto, al disminuir el valor asignado al campo de forma, se define a que porcentaje de los valores espectrales de las capas de imagen contribuirá con el criterio de homogeneidad completa. Esto es ponderado por el porcentaje de la homogeneidad de la forma, que se define en el campo de forma. Cambiar el peso para el criterio de forma que se traducirá en objetos más optimizados para la homogeneidad espacial.

Compacidad: El criterio de compacidad se utiliza para optimizar los objetos de imagen con respecto a la compactación. Este criterio se debe utilizar cuando los diferentes objetos de imagen que son bastante compactas, pero están separados de los objetos no compactos de solo un contraste espectral relativamente débil.

La determinación óptima de estos 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 *IOs* de salida (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 queramos segmentar (e.g. Tian y Chen, 2007). Recientemente han surgido nuevas herramientas para una estimación rápida de los parámetros de escala de la segmentación Multi-resolución (Drăguț et al., 2010), así como para evaluar la precisión de la segmentación final (Marpu et al., 2010).

Segmentación con multiresolución

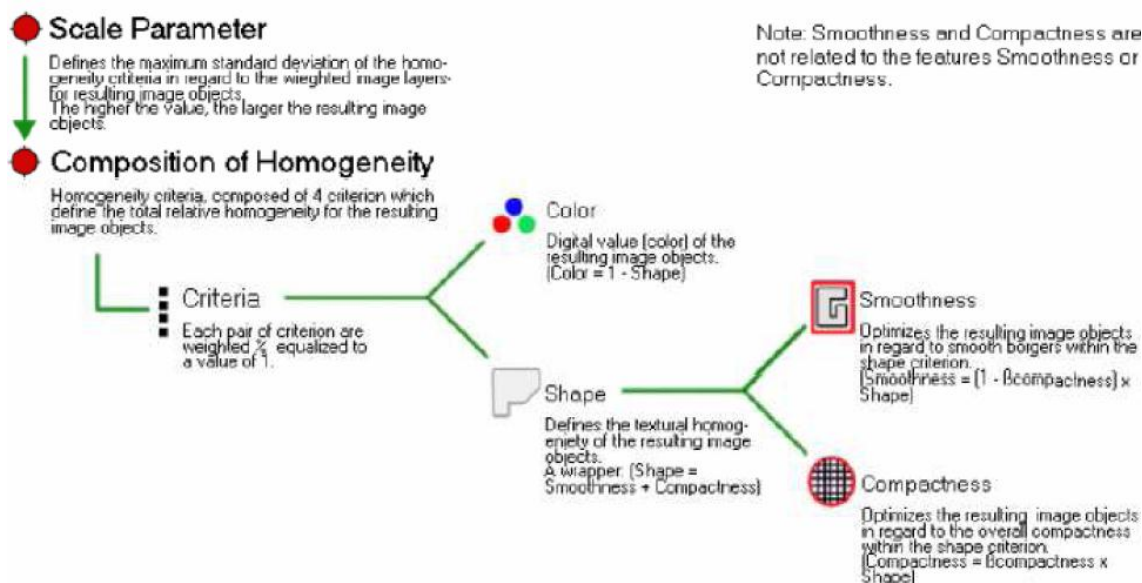


Figura 11. Parámetros segmentación Multi-resolución

1.2.3 Clasificación de imágenes con eCognition

Los algoritmos de clasificación analizan los objetos de la imagen de acuerdo con los criterios definidos y asignan cada uno a la clase que mejor se ajusta a esos criterios.

1.2.3.1 Proceso de clasificación supervisada usando Nearest Neighbor

Nearest Neighbor (vecino más cercano) es un algoritmo de clasificación basado en el muestreo. Se utiliza el algoritmo de *Nearest Neighbor*, en base a muestras definidas por el usuario y en combinación con conjuntos de características predefinidas para asignar objetos a las clases. Se recomienda el uso del clasificador *Nearest Neighbor* cuando es necesario utilizar una compleja combinación de características de un objeto.

El principio es simple, en primer lugar el software necesita muestras representativas, típicas de cada clase. En base a estas muestras, el algoritmo busca los objetos más cercanos a la muestra y evalúa su valor de pertenencia dentro del espacio de características de cada uno de los objetos.

La clasificación con función de pertenencia está basada en funciones uso/definición de las características de los objetos, mientras que la clasificación mediante *Nearest Neighbor* usa una serie de muestras de diferentes clases para asignarles valores asociados. El procedimiento consiste en dos importantes pasos:

- Enseñar al sistema dándole objetos certeros como muestras.
- Clasificar los objetos dentro del ámbito de los objetos basados en las muestras vecinas más cercanas.

El clasificador *Nearest Neighbor* como se muestra en la Figura 12 devuelve un valor de pertenencia entre cero y uno, basado en la característica espacial “distancia” de los objetos con sus vecinos más cercanos. El valor de pertenencia tiene un valor de 1 si el objeto es idéntico al de la muestra. Si el objeto es diferente a la muestra, la característica espacial “distancia” tiene una dependencia confusa de la muestra más cercana de una clase. El usuario podrá elegir las características que considere para la característica espacio.

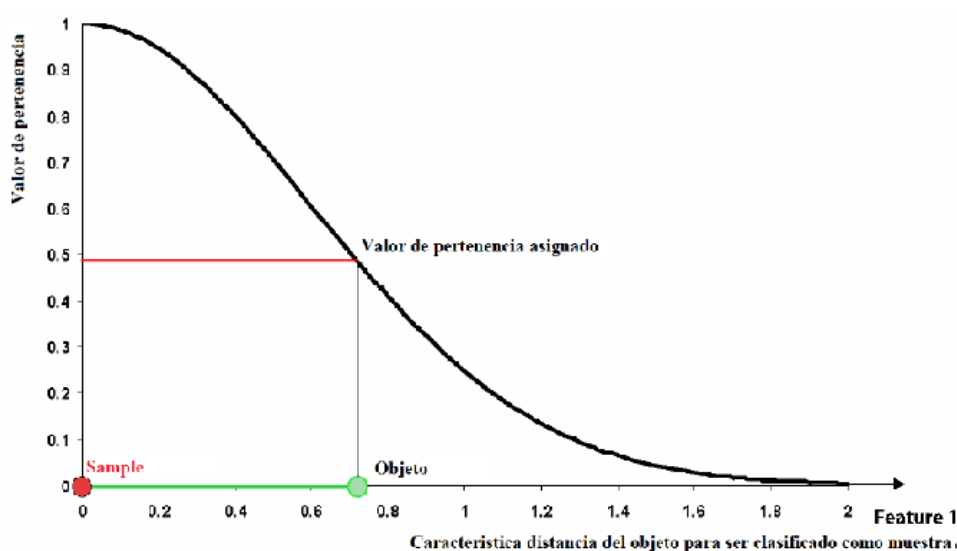


Figura 12: Función de pertenencia creada por el clasificador de *Nearest Neighbor*

Para que un objeto sea clasificado se utilizan funciones de pertenencia. La función de pertenencia efectiva para cada punto en el espacio de características es la combinación de la función confusa sobre todas las áreas de entrenamiento o simples de esa clase. Cuando la función de pertenencia es unidimensional, significa que está relacionada con una característica. En dimensiones mayores, dependiendo del número de características consideradas, es más difícil representar la función de pertenencia. Sin embargo, si se consideran dos características y dos clases, se podría representar como en la Figura 13.

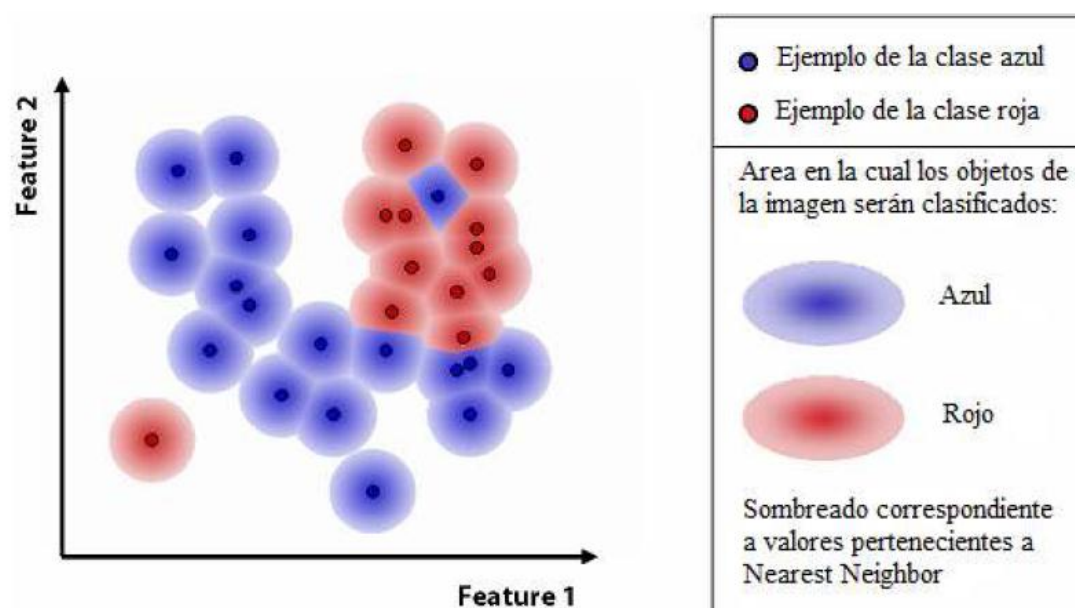


Figura 13. Función de pertenencia muestra las clases asignadas en dos dimensiones. Las muestras se representan con pequeños círculos. Los valores de pertenencia de las correspondientes clases roja y azul están sombreadas del mismo color, por lo que en áreas con objetos clasificados rojos, el valor de pertenencia azul es ignorado y viceversa.

1.2.3.2 Proceso de clasificación supervisada, basada en reglas de integración del conocimiento.

Un proceso de clasificación basada en el conocimiento, también conocido como clasificación basada en reglas de decisión se lleva a cabo sobre regiones segmentadas. Por lo tanto, es necesario reunir los conocimientos necesarios acerca de las regiones segmentadas. Descriptores espectrales y texturales, las relaciones contextuales entre los

diferentes tipos de objetos y descriptores estructurales pueden aportar conocimientos, basado en características de la escena.

-Descriptores espectrales: Las relaciones entre los valores de reflectancia de varias bandas espectrales se denominan coeficientes de índice; aquellos que pueden ser utilizados para establecer la base de la clasificación

-Descriptores texturales: Descriptores texturales pueden medirse sobre la base de las relaciones de niveles de grises entre cada objeto y sus vecinos en las regiones segmentadas previamente. Se refiere a la complejidad del reconocimiento de objetos, que utilizan más de un descriptor para la identificación de las características de textura de los objetos.

-Relaciones contextuales: Definición de relaciones de objetos contextuales entre vecinos pueden mejorar la precisión de los resultados de análisis de imágenes basadas en objetos. Los métodos basados en Contexto operan en el nivel de comprensión de imágenes, análisis de toda la imagen para recuperar la información necesaria (Peets y Etzion, 2010). Las relaciones de vecindad entre los objetos uso del suelo definen una poderosa herramienta para el reconocimiento de varios objetos adyacentes. Analizando frontera relativa, altura relativa y la inclusión de una región de objetos adyacentes se pueden definir como las relaciones contextuales comunes en uso del suelo.

-Descriptores estructurales: Cálculo de descriptores estructurales adecuados basados en las características espaciales y las alturas de las regiones segmentadas proporcionan una herramienta para refinar los resultados del proceso de clasificación a nivel de objeto. Descriptores estructurales 2D como el área, la elongación y solidez se utiliza junto con el alivio y la rugosidad de la superficie como descriptores estructurales 3D, éstos tienen un gran potencial en el campo de reconocimiento de objetos uso del suelo.

Después de la generación de los descriptores antes mencionados sobre la base de los datos de imagen y los productos de altura, una selección óptima de descriptores y sus umbrales de reconocimiento de cada uno de las clases de objetos individuales tiene el papel más eficaz en la generación de una base de conocimiento adecuada. Una

clasificación del nivel de objeto se puede realizar mediante la encapsulación de la base de conocimientos en un conjunto de reglas y la definición de una estrategia para el reconocimiento de objetos.

CAPÍTULO 2

INTERÉS Y OBJETIVOS

2.- INTERÉS Y OBJETIVOS

2.1.- INTERÉS

Después de todo lo expuesto en el punto anterior, es conveniente matizar la importancia de la extracción de información espacial de calidad a partir de imágenes procedentes de sensores remotos para el seguimiento y verificación de cambios en la superficie, e incluso la dedicación, de cultivos protegidos. Dicha extracción de información suele llevarse a cabo de forma manual en la mayoría de los casos. Sin embargo este tipo de tareas son lentas y además, requieren operadores bien entrenados, por lo que suelen resultar tareas muy caras y poco eficientes. Además, en zonas con una rápida dinámica en el cambio del uso del suelo, estas técnicas pueden no ser suficientes para tener actualizada la información espacial (Rüther et al., 2002). Según lo expuesto, se hace necesario desarrollar una metodología remota que automatice, manteniendo un alto nivel de precisión, la extracción de la información espacial relativa a invernaderos, a partir de imágenes de satélite de alta resolución. En nuestro caso concreto, se propone el uso de imágenes procedentes del satélite comercial *VHR* más novedoso en la actualidad, *WorldView-2*. Estas técnicas serán aplicadas y validadas en una zona agrícola piloto situada en el término municipal de Palomares (Almería).

2.2.- OBJETIVOS

El objetivo fundamental del proyecto es desarrollar una técnica de detección automática de invernaderos, incluso llegando a una estimación del cultivo que albergan, basada en objetos (*Object Based Image Analysis, OBIA*). Se pretende estudiar el nivel de precisión y calidad alcanzables por esta técnica, en condiciones operacionales y en nuestra zona piloto. La clasificación de los distintos tipos de invernaderos se realizará usando un software considerado como un estándar en técnicas *OBIA* (eCognition). La información a analizar mediante eCognition consistirá en ortoimágenes PAN, y una fusionada (*PAN+MS*), del satélite comercial *VHR* más novedoso e inexplorado (*WorldView-2*).

DETECCIÓN REMOTA DE INVERNADEROS A PARTIR DE ESTÉREO PARES PAN Y MS DEL SATÉLITE
WORLDVIEW-2 APLICANDO TÉCNICAS DE CLASIFICACIÓN BASADA EN OBJETOS

También se utilizará como capa de información en eCognition *nDSM*, obtenido a partir de un estéreo par de imágenes *PAN* de *WorldView-2* sobre la zona piloto.

CAPÍTULO 3

MATERIALES Y MÉTODOS

3.- MATERIALES Y MÉTODOS

3.1.- DESCRIPCIÓN DE LA ZONA DE TRABAJO

El estudio que vamos a realizar en este trabajo, se desarrolla en la provincia de Almería, más concretamente en el término municipal de Palomares (Figura 14 y 15). La zona de estudio está comprendida entre el pueblo de Palomares y el río Almanzora (centrada en las coordenadas *UTM 30N WGS84 607781 E, 4122675 N*), con una superficie total de unas 125ha. En la zona de estudio no se encuentra toda la superficie cubierta de invernaderos, aunque nos es de gran utilidad para poder diferenciar en la clasificación tanto suelo destinado a invernaderos, como suelo desnudo, suelo con vegetación... Se ha realizado en esta zona para poder utilizar los datos georreferenciados obtenidos en el marco del Proyecto de Investigación del Plan Nacional, con referencia *CTM2010-16573*, titulado “Generación de datos georreferenciados de muy alta resolución a partir de imágenes de los satélites *GeoEye-1* y *WorldView-2*” así como del Proyecto de Investigación de Excelencia denominado: “Integración y análisis exploratorio de datos geospaciales multifuente para el seguimiento y modelado de la evolución y vulnerabilidad de áreas costeras. Aplicación a una zona del Levante de Almería”, con referencia *RNM-3575*.

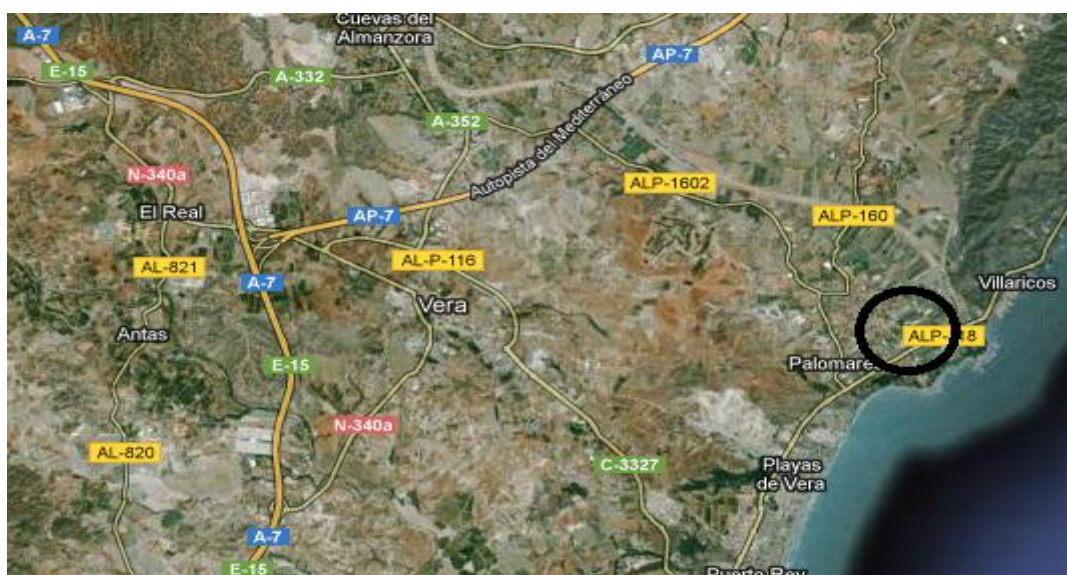


Figura14: Situación de la zona de trabajo



Figura 15: Emplazamiento de la zona de trabajo.

3.2.- MATERIALES EMPLEADOS

3.2.1 Ortoimagen Pansharpened

La ortoimagen *pansharpened* se obtuvo a partir de la imagen *PAN* y *MS* (8 bandas) del satélite *WorldView-2* (Figuras 16 y 17). Se trata de un estéreo par (dos imágenes con un 100% de solape, tomadas sobre el mismo sitio y casi al mismo tiempo, donde la única variación es la posición del satélite en el momento de la adquisición) Figura 18. 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. Los trabajos realizados mediante sistemas de posicionamiento global diferencial (*Differential Global Positioning System, DGPS*) se apoyaron en once puntos de campo conocidos, de los cuales cuatro pertenecen a la red geodésica nacional, uno a la red *REGENTE* (obtenido con técnicas de alta precisión espacial), y seis puntos fueron facilitados por la Red de Información Ambiental de Andalucía (*REDIAM*). Los valores de *RMSE* obtenidos en los puntos de coordenadas conocidas tras los ajustes correspondientes fueron de 5.6 cm, 3.3 cm y 7.6 cm en *X*, *Y*, *Z* respectivamente. El sensor utilizado fue el *RPCO* con un *RMSE* de 0.430m. Para los procesos de

ortorectificación desarrollados el *DEM* empleado fue proporcionado por la Junta de Andalucía, a partir de un vuelo fotogramétrico.

ID de la imagen	WV22	WV23
Producto	WV2 ORS2A	WV2 ORS2A
Fecha de Adquisición	18/08/2011	18/08/2011
Hora de Adquisición (GTM)	11:22	11:23
Cobertura de Nubes	0%	0%
Sentido de la Toma	Directo	Inverso
Azimut Solar	152.3°	152,8°
Elevación del Sol	63.7°	63.8°
Elevación del satélite	67.6°	80°
Azimut del satélite	4.7°	216.1°
Tamaño Real del Píxel Columna	0.499m	0.473
Tamaño Real del Píxel Fila	0.538m	0.48m
Tamaño de píxel del producto	0.5m	0.5m

Tabla 2. Características de las imágenes pancromáticas de WorldView-2 (ORS2A) adquiridas en el lugar de estudio

La generación de la ortoimagen fusionada (*Pansharpened*) de *WorldView-2*. Se realiza a partir de la ortoimagen *PAN* con 0.5 m de tamaño de píxel (*Ground Sample Distance; GSD*), y la ortoimagen *MS* de 2 m de *GSD*, obteniéndose una ortoimagen fusionada (*PAN + MS*) con 0.5 m de *GSD* y que incluye la información espectral de la imagen *MS* (8 bandas). Para la generación de la ortoimagen fusionada se empleó el algoritmo *PANSHARP* del software Geomática v. 2012 (*PCI Geomatics, Richmond Hill, Ontario, Canadá*). La imagen *Pansharpened* o fusionada contiene información radiométrica de las 8 bandas de *WV2*, ejemplo (Figura 18) muestra el verdadero color. La información radiométrica puede ser combinada para conseguir que resalten la vegetación o cualquier

tipo de superficie en estudio, como por ejemplo ocurre en la Figura 19, donde se muestra la imagen *Pansharpened* de WV2 en falso color (*Nir I, R, G*), en la que la vegetación aparece representada en tonos rojos.



Figura 16: Imagen PAN de WV2 (0.5 m GSD).



Figura 17: Imagen MS de WV2 (2 m GSD).



Figura 18: Imagen Pansharpened (RGB) color verdadero de WV2 (0.5 m GSD).




Figura 19: Imagen Pansharpened (falso color, NIR1, R, G) de WV2 (0.5 m GSD).

3.2.2 Modelo digital de superficies normalizado nDSM

Para generar el *nDSM* en la zona de estudio, se obtuvieron los datos georeferenciados que a continuación se detallan. En primer lugar, fue necesario crear un *DSM* a partir del estéreo par de *WorldView-2* trabajando en la banda *PAN*. Se trata de un *DSM* tipo *grid* con 1 m de paso de malla generado, mediante el módulo fotogramétrico de PCI-Geomática v. 2012, denominado *OrthoEngine* (Figura 20). Para comprobar la precisión se utilizó un *DSM LiDAR*, y el modelo de sensor utilizado fue un *RCPO* apoyado por 12 puntos *GCPs*, dando unas precisiones planimétricas de 0,44m y altimétricas de 0.19m.



Figura 20: DSM a partir de estéreo par PAN de WV2 (1 m grid).

A partir del *DSM* obtenido en el paso anterior, se ha generado un *DEM* (Figura 21) mediante el algoritmo de filtrado *DSMsDEM* de Geomática 2013 (Figura 22). Finalmente el *nDSM* se obtiene por sustracción del *DEM al DSM*. El *nDSM* tendrá formato *grid* con 1 m de Espaciamiento. En la Figura 23 se puede observar los errores que se han producido en la creación del *nDSM*, por ejemplo en los invernaderos tipo malla que presentan discontinuidades, dentro de un mismo objeto. En la figura 24 se puede observar un *nDSM* obtenida de la zona de trabajo.

DETECCIÓN REMOTA DE INVERNADEROS A PARTIR DE ESTÉREO PARES PAN Y MS DEL SATÉLITE WORLDVIEW-2 APLICANDO TÉCNICAS DE CLASIFICACIÓN BASADA EN OBJETOS

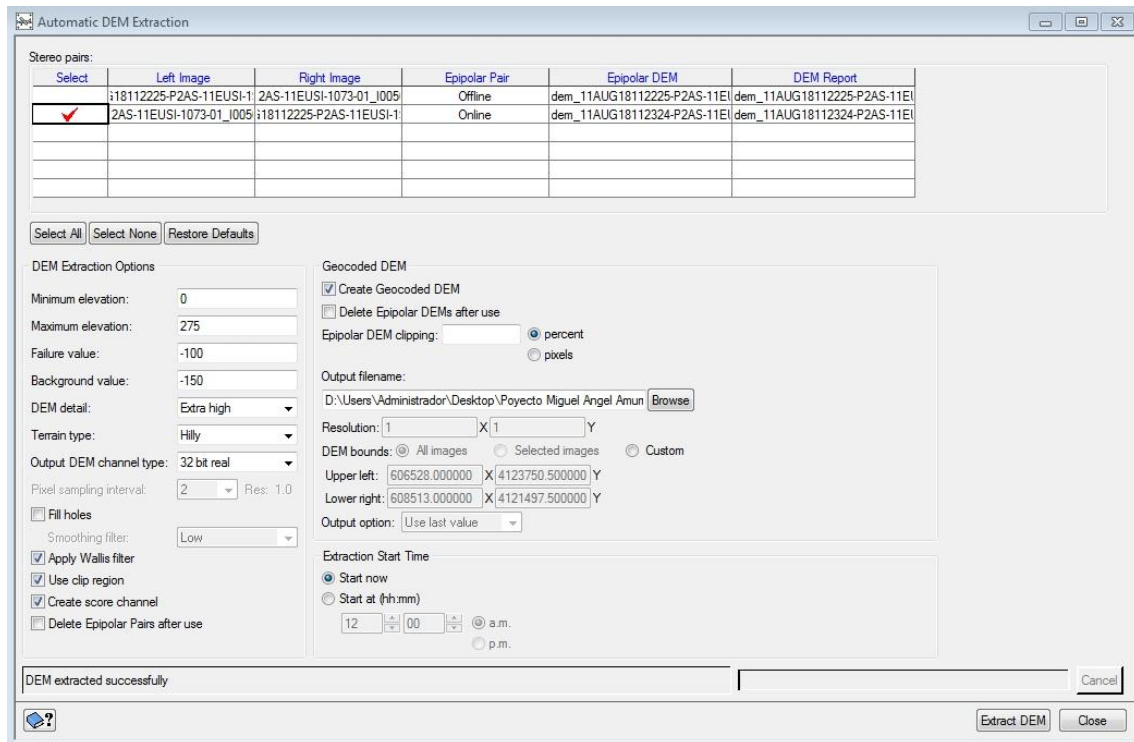


Figura 21: Generación DEM mediante el algoritmo orthoEngine de Geomática 2013



Figura 22: DEM a partir del DSM generado del estéreo par PAN de WV2 (1 m grid). Mediante el algoritmo DSMsDEM



Figura 23: $DSM-DEM = nDSM$. Mediante el algoritmo Ari de Geomática



Figura 24: nDSM de la zona de trabajo

3.2.3 Generación del Ground Truth.

Ground Truth es un término utilizado en la cartografía, la meteorología, el análisis de fotografías aéreas, imágenes de satélite y en otra serie de técnicas que recogen datos a partir de sensores remotos. El *ground truth* se refiere a la información que se recoge en el terreno mediante una clasificación o identificación manual por parte de un operario. En teledetección, esto es muy importante para poder relacionar los datos de la imagen a las características reales del terreno.

La generación del archivo vectorial de referencia (*Ground Truth*), ha sido desarrollada con el *software ArcGis*, sobre la ortoimagen fusionada de *WV-2* (Figura 25). Se ha realizado un esquema de clasificación de las clases en las que se pretende categorizar la zona de estudio.




Figura 25: Ground Truth de los 52 invernaderos

Para la correcta determinación de las clases se han utilizado ortoimágenes aéreas, de satélite, información catastral, *DEM*, *DSM*, *NDSM*, *Google Earth*, *Street View* y demás información geoespacial de la que se disponía sobre la zona de estudio. Se digitalizaron 52 polígonos, todos los que corresponden a invernaderos. Los polígonos correspondientes a invernaderos blanqueados cultivados fueron 6 y los invernaderos blanqueados sin cultivar 9. A continuación se clasificaron los invernaderos tipo malla cultivada, un total de 20 y los invernaderos de malla sin cultivar 7. Los polígonos correspondientes a invernaderos no blanqueados cultivados han dado un total de 3 y los invernaderos no blanqueados sin cultivar solo se encontraron 1 en la zona de estudio. Los invernaderos blanqueados o en construcción se agruparon en una sola clase por las dificultades de separarlos y se digitalizaron 6. Cada una de estas clases, han sido digitalizadas en su totalidad.

La digitalización en el *software ArcGis* es una tarea lenta debido a las irregularidades de los invernaderos, que no son totalmente rectangulares y algunos de ellos se encuentran prácticamente unidos, lo que hace muy difícil su digitalización. Para una correcta digitalización se requieren operadores bien entrenados con capacidades fotogramétricas para generar productos georreferenciados de la máxima calidad. Los polígonos han sido digitalizados correctamente, aunque en la clasificación manual no se ha podido verificar en campo ya que este trabajo se ha comenzado a realizar 2 años después de la toma de las imágenes de satélite.

Para la clasificación basada en reglas de interacción del conocimiento, se han obtenido valores medios del espectro electromagnético, del *nDSM* y del Índice de Vegetación de Diferencia Normalizado, *NDVI*, de cada uno de los polígonos digitalizados, de cuyos datos se espera poder obtener la información necesaria, sobre los rangos de valores que separen cada una de las clases.

3.3.- METODOLOGÍA

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 una segmentación Multi-rresolucion y una segmentación Óptima. Además se han realizado dos clasificaciones diferentes, la primera de ellas mediante el algoritmo *Nearest Neighbor* y la segunda clasificación basada en reglas de integración del conocimiento.

3.3.1 Segmentación con eCognition Multi-rresolución

La primera de las segmentaciones realizadas, a la que nos referiremos como “Multi-rresolucion”, que se ha generado a partir de la ortoimagen *pan-sharpened* de *WorldView-2* y el *nDSM*, empleando el algoritmo de segmentación Multi-rresolución implementado en eCognition. En un primer momento se generó una segmentación utilizando únicamente la ortoimagen *pan-sharpened*, y se produce una segmentación excesiva, a simple vista de los polígonos correspondientes a invernaderos. Para intentar corregir esa segmentación excesiva de los polígonos correspondientes a invernaderos, se utilizó además de la ortoimagen *pan-sharpened* de *WorldView-2*, el *nDSM* que contiene información de los invernaderos por sus datos de elevaciones, y se consiguió un menor número de objetos y más homogéneos. La diferencia entre las dos segmentaciones se puede observar en la figura 26.




Figura 26: a) Segmentación a partir de ortoimagen pan-sharpened de WorldView-2 y el nDSM. b) Segmentación a partir ortoimagen pan-sharpened de WorldView-2.

La segmentación Multi-resolución depende de una serie de parámetros: el parámetro de forma, la compacidad y la escala, estos parámetros se aplican sobre las capas que utilizamos para la segmentación. Las capas utilizadas para esta segmentación fueron las 8 bandas espectrales contenidas en la ortoimagen fusionada y el nDSM a las que se les asignaron pesos iguales (Figura 27).

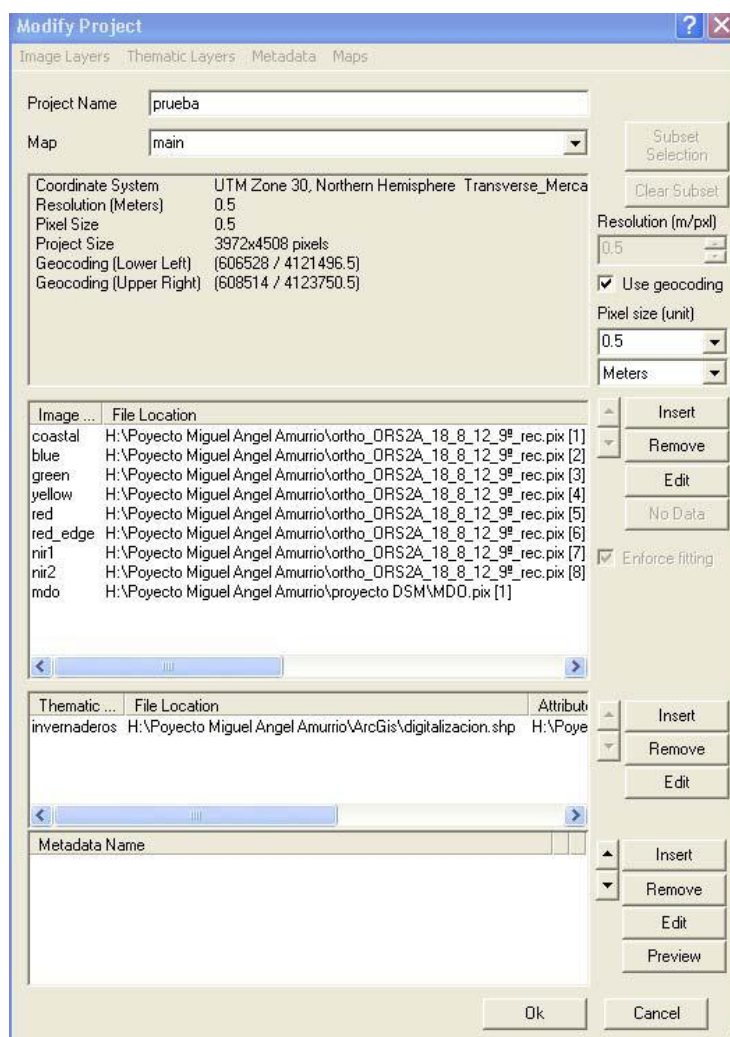



Figura 27: Datos importados para la segmentación Multi-rresolución


El análisis preliminar se llevó a cabo mediante la inspección visual, que es una práctica común en la selección de parámetros de segmentación. Previamente se fijó el criterio de 0.5 para la compacidad y 0.3 para la forma, en todas las segmentaciones llevadas a cabo. El parámetro de escala fue el seleccionado para variar hasta encontrar una segmentación adecuada. El mayor número de escala (por ejemplo, 350) genera objetos homogéneos de mayor tamaño, mientras que el número más pequeño de la escala (por ejemplo, 100), dará lugar a los objetos más pequeños. La decisión sobre el nivel de la escala depende del tamaño del objeto que se requiere para lograr el objetivo. A estos efectos, se probaron varias escalas diferentes (100, 150, 200, 250, 300 y 350) de segmentación de imágenes (Figura 28),

Figura 28. Segmentación Multi-rresolucion con el parámetro forma 0.3 y compacidad 0.5 a diferentes escalas y OI generados




a. Escala 100, OI 2241

b. Escala 150, OI 1181



c. Escala 200, OI 743

d. Escala 250, OI 533



e. Escala 300, OI 399

f. Escala 350, OI 311

De esta forma se generaron los objetos pertenecientes a la zona de estudio, que posteriormente se pretendían clasificar automáticamente. Finalmente se ha decidido utilizar el parámetro escala 200 generándose 743 objetos de interés (*OIs*) (Figura 29), mediante la cual se consigue que los polígonos correspondientes a invernaderos no se segmenten en exceso, ni se produzca una segmentación deficiente.




Figura 29. Segmentación Multi-rresolucion con los parámetros de forma 0.3, compacidad 0.5 y escala 200, en la que se han generado 743 OI.

3.3.2 Segmentación con eCognition Chessboard

La segunda segmentación, a la que denominaremos segmentación “Óptima”, 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* (tablero de ajedrez) usando el archivo vectorial (*shp*) con los 52 invernaderos como capa temática (Figura 31). Tras esta segmentación previa que contenía 53 *IOs* (i.e. 52 invernaderos y un objeto que contenía el resto del territorio), se

realizó una segmentación Multi-rresolucion al nivel de los objetos obtenidos previamente, con un factor de forma de 0.3, de compacidad 0.5 y escala 100 (Figura 32). En este segundo paso, sólo los *IOs* con un tamaño superior a 400000 píxeles serían segmentados. 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 de forma similar al caso anterior y 2137 *IOs* fueron generados. En la Figura 30 se puede observar un detalle de la segmentación Óptima, y puede ser comparada con la segmentación Multi-rresolución.

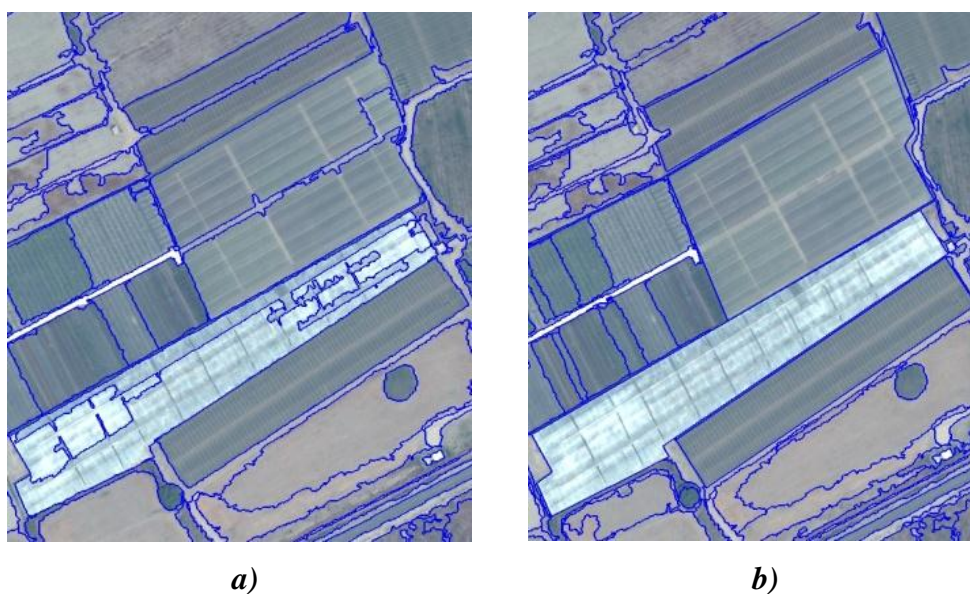


Figura 30: a) Detalle de la segmentación Multi-rresolución. b) Detalle de la segmentación Óptima. La segmentación Óptima completa puede ser apreciada en la figura 38.

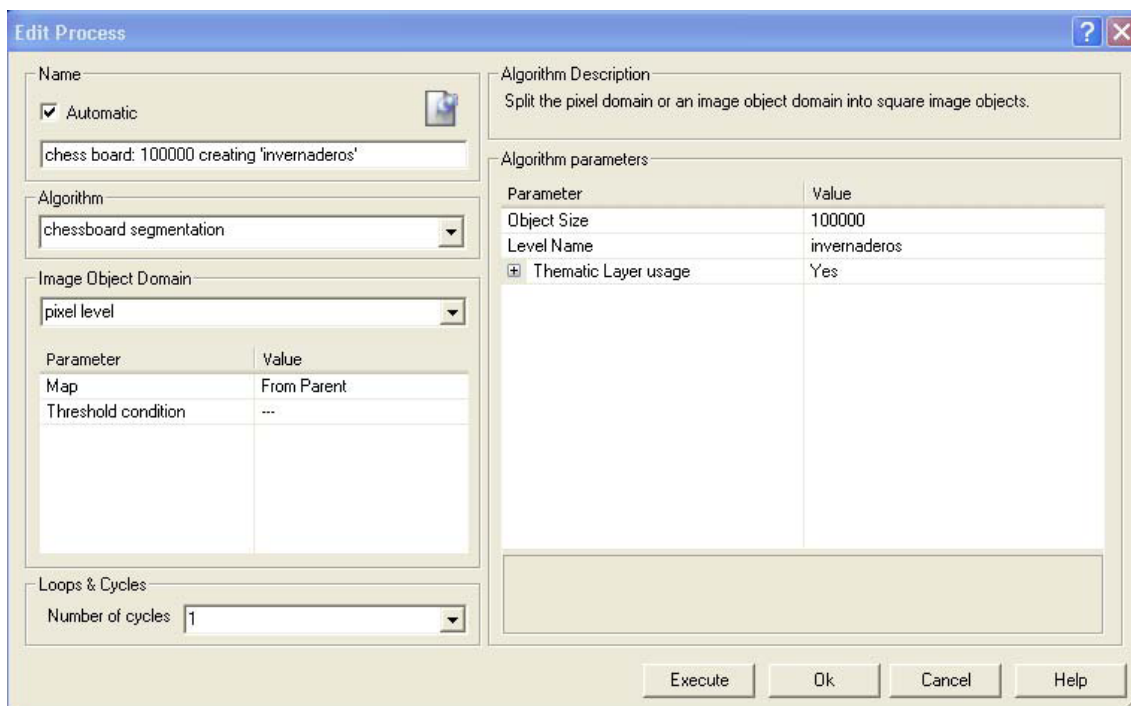


Figura 31: Configuración de la segmentación chess board sobre pixel level.

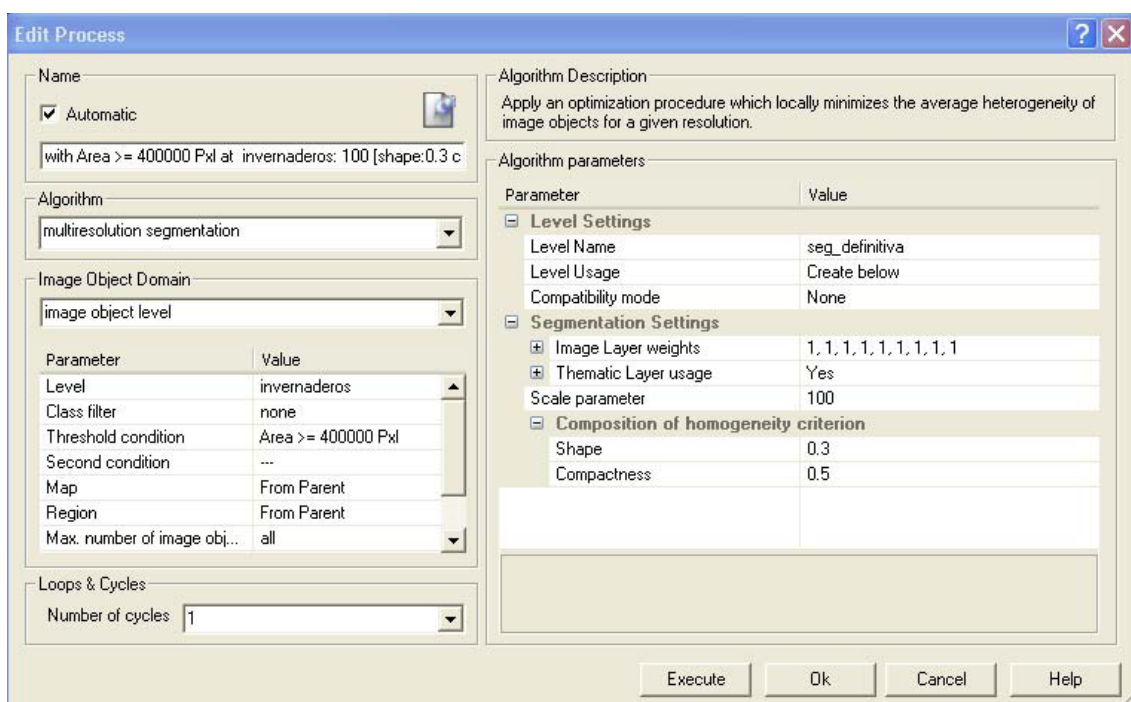


Figura 32: Configuración de la segmentación Multi-rresolución sobre el nivel invernaderos, creado en el paso anterior.

3.3.3 Mapa de referencia

Un total de 445 de los 2137 *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 33). 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, creado sobre la segmentación Óptima. Para la correcta determinación de las clases se han utilizado ortoimágenes aéreas, de satélite, información catastral, *DEM*, *DSM*, *nDSM*, y demás información geoespacial de la que se disponía sobre la zona de estudio.

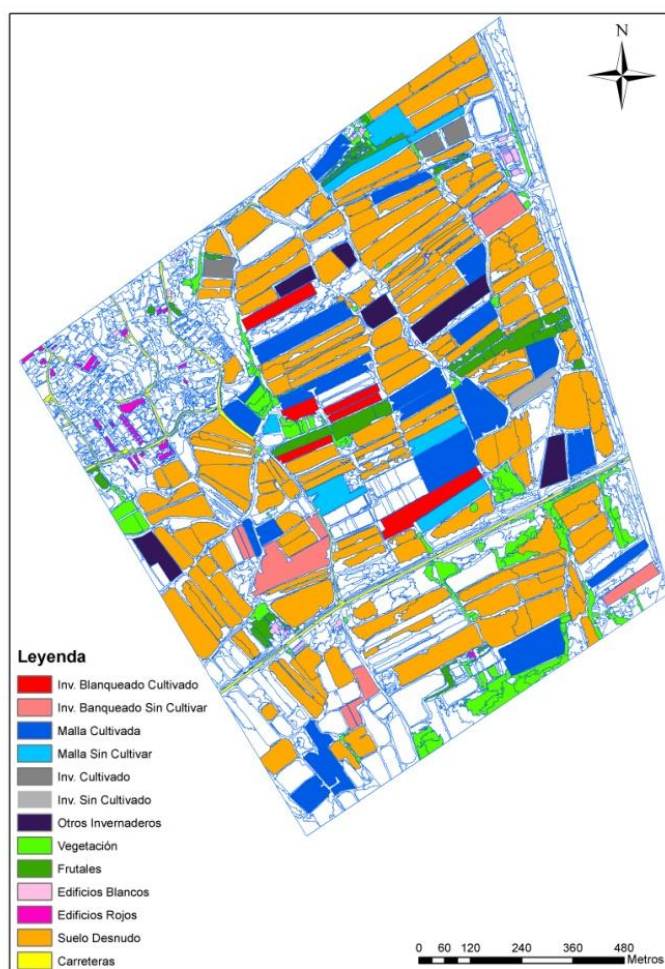


Figura 33: Mapa de referencia sobre la segmentación Óptima.

3.3.4 Clasificación Nearest Neighbor

El clasificador supervisado *Nearest Neighbor (NN)* implementado en eCognition, fue utilizado en la segmentación Óptima y en la segmentación “Multi-resolución”. En el proceso de clasificación de la imagen es necesario acumular un conocimiento previo sobre las características de las clases que se van a establecer en la leyenda del mapa temático que deseamos generar, de modo que, en referencia a él, el clasificador pueda asignar los objetos resultantes de la segmentación previamente descrita a cualquiera de las clases. El proceso de definición de las clases a partir de sus características dentro de la imagen se conoce como entrenamiento del clasificador.

De manera análoga al trabajo de Tarantino y Figorito (2012), para identificar el conjunto de características que arrojan una mayor distancia o separabilidad entre las distintas clases, se empleó la herramienta de optimización del espacio de características (*Features Space Optimization, FSO*). Esta herramienta es un algoritmo que compara las características de las clases seleccionadas para encontrar la combinación de características que produce la distancia mínima media más grande entre las muestras de la formación de diferentes clases. Comenzamos el análisis basado en *FSO* incluyendo 42 funciones que se muestran en la Tabla 3, 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 los objetos dentro del área de prueba, además, cuanto mayor es el número de variables utilizadas, más prolongado será el tiempo de procesamiento de la minería de datos. El objetivo será la extracción de las 9 características, de las 42 iniciales que maximicen la separabilidad del *NN*. En este proyecto se utilizó el procedimiento denominado supervisado en el cual el analista define en la escena una serie de parcelas, conocidas como campos de entrenamiento (training áreas), de las cuales se conoce su pertenencia a una clase concreta de las establecidas en el trabajo. Para este propósito, un subconjunto de muestras han sido utilizadas: 2 invernaderos blanqueados cultivados, 3 invernaderos blanqueados no cultivado, 4 invernaderos de malla cultivada, 2 de malla sin cultivar, 1 de invernaderos cultivados, 1 de invernaderos sin cultivar, 2 de otros invernaderos, 8 de vegetación, 5 de frutales, 6 construcciones blancas, 6 construcciones rojas, 8 de suelo desnudo y 5 de carreteras (objetos para cada clase) como áreas de entrenamiento.

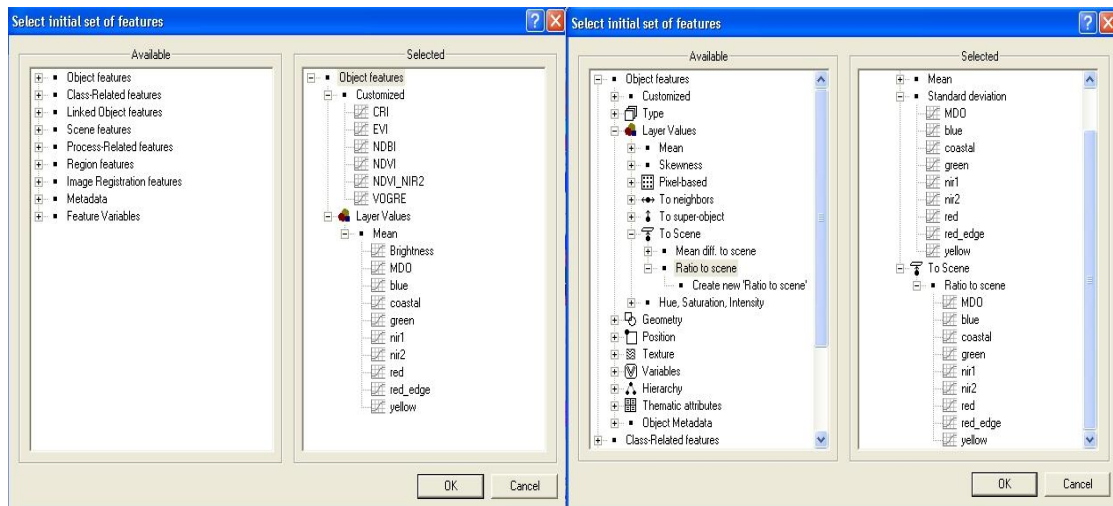
DETECCIÓN REMOTA DE INVERNADEROS A PARTIR DE ESTÉREO PARES PAN Y MS DEL SATÉLITE
WORLDVIEW-2 APLICANDO TÉCNICAS DE CLASIFICACIÓN BASADA EN OBJETOS

	CARACTERÍSTICAS	DESCRIPCIÓN
Información básica espectral	Brightness	Brillo
	Coastal	Media, desviación estándar y ratio de escena de la banda <i>Coastal</i> de la <i>pan-sharpened</i>
	Blue	Media, desviación estándar y ratio de escena de la banda <i>Blue</i> de la <i>pan-sharpened</i>
	Green	Media, desviación estándar y ratio de escena de la banda <i>Green</i> de la <i>pan-sharpened</i>
	Yellow	Media, desviación estándar y ratio de escena de la banda <i>Yellow</i> de la <i>pan-sharpened</i>
	Red	Media, desviación estándar y ratio de escena de la banda <i>Red</i> de la <i>pan-sharpened</i>
	Red Edge	Media, desviación estándar y ratio de escena de la banda <i>Red Edge</i> de la <i>pan-sharpened</i>
	NIR1	Media, desviación estándar y ratio de escena de la banda <i>NIR1</i> de la <i>pan-sharpened</i>
	NIR2	Media, desviación estándar y ratio de escena de la banda <i>NIR2</i> de la <i>pan-sharpened</i>
	nDSM	Media, desviación estándar y ratio de escena del <i>nDSM</i>
Índices de vegetación	CRI	Índice de reflectancia de los caratenoides (1/Band 3) – (1/Band 6); Gitelson et al. 2002
	EVI	Índice de vegetación mejorado $2.5 (Band\ 8 - Band\ 5) / (Band\ 8 + 6\ Band\ 5 - 7.5\ Band2 + 1)$; Huete et al. 1997
	NDBI	Índice de diferencia normalizado para la banda blue (Mean NIR - Mean Blue)/(Mean NIR + Mean Blue)
	NDVI	Índice de vegetación de diferencia normalizado de la banda <i>Nir 1</i> (Mean NIR 1 - Mean Red)/(Mean NIR 1 + Mean Red)
	NDVI_NIR2	Índice de vegetación de diferencia normalizado de la banda <i>NIR 2</i> (Mean NIR 2 - Mean Red)/(Mean NIR 2 + Mean Red)
	VOGRE	Vogelmann borde rojo 1 Band 6/Band 5; Vogelmann, Rock, and Moss 1993
Forma y Geometría	Área	Superficie del objeto
	Índice de borde	Número de bordes
	Compacidad	El cociente entre el área de un polígono y el área de un círculo con el mismo perímetro
	Densidad	Número de píxeles que forman el objeto de imagen dividida por su radio aproximado, basado en la matriz de covarianza
	Forma rectangular	Relación de zona dentro del rectángulo equi-areal apropiado dividido por el área del objeto fuera del rectángulo
	Redondez	Número de bordes que forman el polígono
	Índice de forma	Perímetro de un <i>IO</i> dividido entre cuatro veces la raíz cuadrada de su área
Esqueleto	Longitud/Anchura	Línea principal

Tabla 3. 42 características (features) utilizadas para el FSO

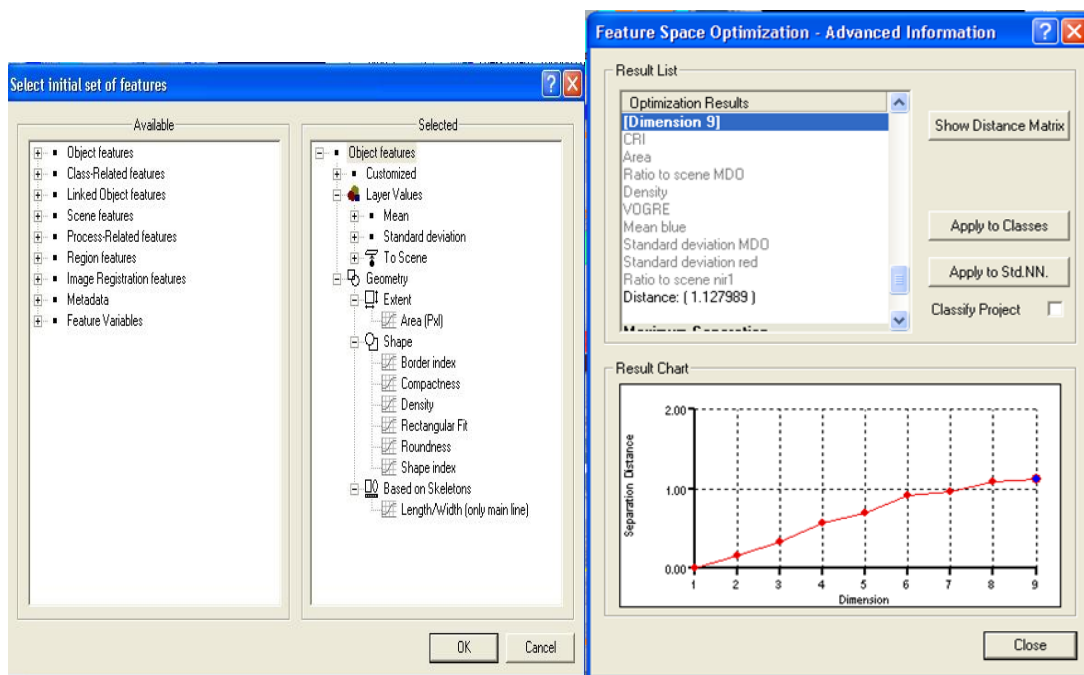
Se introducen las variables de inicio en eCognition y a continuación se le introduce la dimensión, el número máximo de características óptimas que queremos conseguir en nuestro caso 9 (Figura 34) y eCognition averigua las mejores características de las 42, clasificándolas de en orden de mayor a menor distancia mínima media más grande entre las muestras, siendo las muestras el (*Ground Truth*) que generaremos a continuación.

DETECCIÓN REMOTA DE INVERNADEROS A PARTIR DE ESTÉREO PARES PAN Y MS DEL SATÉLITE WORLDVIEW-2 APLICANDO TÉCNICAS DE CLASIFICACIÓN BASADA EN OBJETOS



a)

b)



c)

d)

Figura 34. a) Índices de vegetación y valores medios espectrales de las 8 bandas. b) Índices de desviación estándar de las 8 bandas y ratios de escena. c) Índices de geometría d) Características seleccionadas por el FSO.

3.3.5 Clasificación basada en reglas de integración del conocimiento.

Para la segmentación “Óptima” y la segmentación “Multi-rresolución” se han utilizado las mismas reglas de decisión fundamentadas en umbrales relativos a diferentes bandas espectrales, parámetros de forma, tamaño e índices concretos.

En las gráficas que a continuación se presentan, aparecen las 8 bandas de *WV-2*, (1) *Coastal*, (2) *Blue*, (3) *Green*, (4) *Yellow*, (5) *Red*, (6) *Red Edge*, (7) *NIR-1* y (8) *NIR-2*, y el valor medio de su nivel digital (*Digital Number, DN*), es el valor numérico asociado a cada píxel de una imagen. Cuando un sensor registra una imagen, este valor es proporcional a la cantidad de energía electromagnética que detecta.

a. Clasificación de vegetación.

Las clases de frutales y vegetación han sido clasificadas en una sola clase por la imposibilidad de separarlas. Para la clasificación de la vegetación se ha utilizado el Índice de Vegetación de Diferencia Normalizada (*NDVI*), que es un índice usado para estimar la cantidad, calidad y desarrollo de la vegetación. En nuestro caso es utilizado para separar las clases de vegetación del resto, ya que las áreas con un índice *NDVI* mayor 0,225 se consideran vegetación, con la restricción de que las áreas mayores de 7000 píxeles y una desviación estándar del *nDSM* mayor de 1, sean invernaderos de malla cultivada, porque aparecen invernaderos de malla cultivada con umbrales de *NDVI* igual a los de la clase vegetación, puesto que la malla permite que el espectro electromagnético que la vegetación del interior emite o refleja pase. En la figura 35 podemos observar que la clase vegetación presenta unos valores elevados de *DN* en el *NIR-1* y *NIR-2*, frente al resto de bandas.

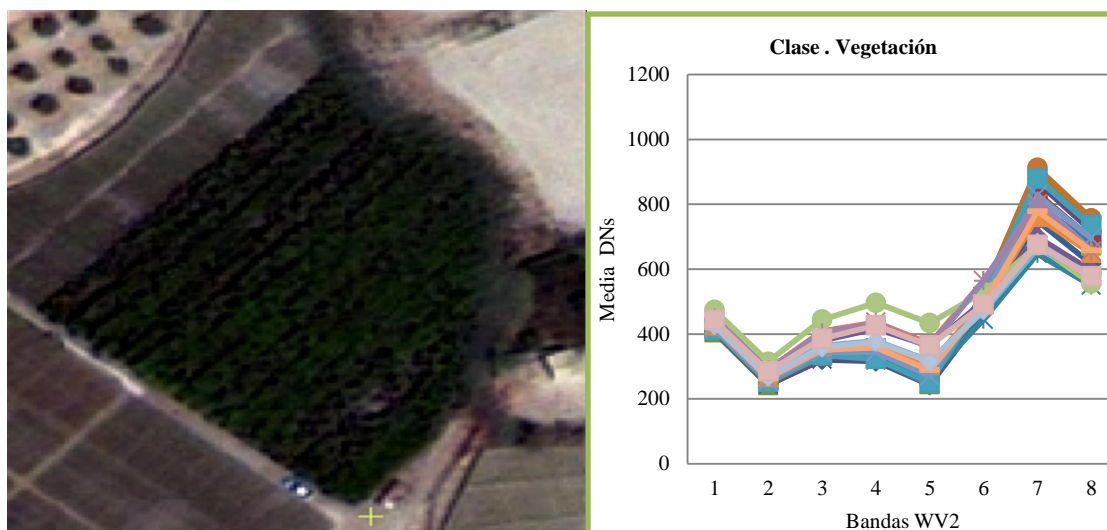


Figura 35: Imagen clase vegetación y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2.

b. Clasificación invernaderos blanqueados

La clasificación continúa respetando las áreas segmentadas anteriormente. Se clasifican los invernaderos blanqueados cultivados, por medio de los umbrales del *nDSM*, las áreas que contengan una media del *nDSM* entre 2,5 y 5m serán invernaderos blanqueados cultivados, dejando fuera la áreas que tengan un brillo (*brightness*) menor de 570, ya que los invernaderos blanqueados dan valores muy altos de brillo. También se ha dejado fuera los invernaderos que tengan la desviación estándar del *nDSM* mayor de 1,025 ya que los objetos correspondientes a invernaderos blanqueados no presentan mucha variación de altitud dentro de un mismo invernadero, además se han dejado fuera las áreas inferiores a 3,500 pixel, y así se consigue que no clasifique algunos edificios como invernadero blanqueados. Clasificando como invernaderos blanqueados no cultivados los que tengan un valor de *NDVI* menor de 0,12 en la clase de invernaderos blanqueados cultivados, ya que la vegetación de los invernaderos blanqueados no cultivados refleja o emiten muy poca radiación electromagnética correspondiente al *NDVI*. La clase de invernaderos blanqueados presenta valores elevados de *DN* en todas sus bandas en comparación con el resto de clases.

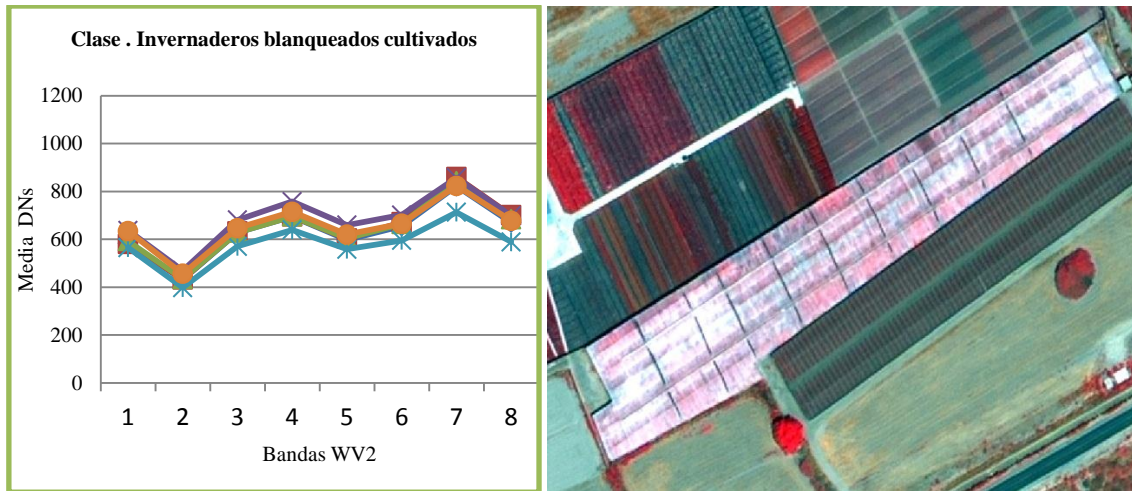


Figura 36: Imagen invernaderos blanqueados cultivados y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2.

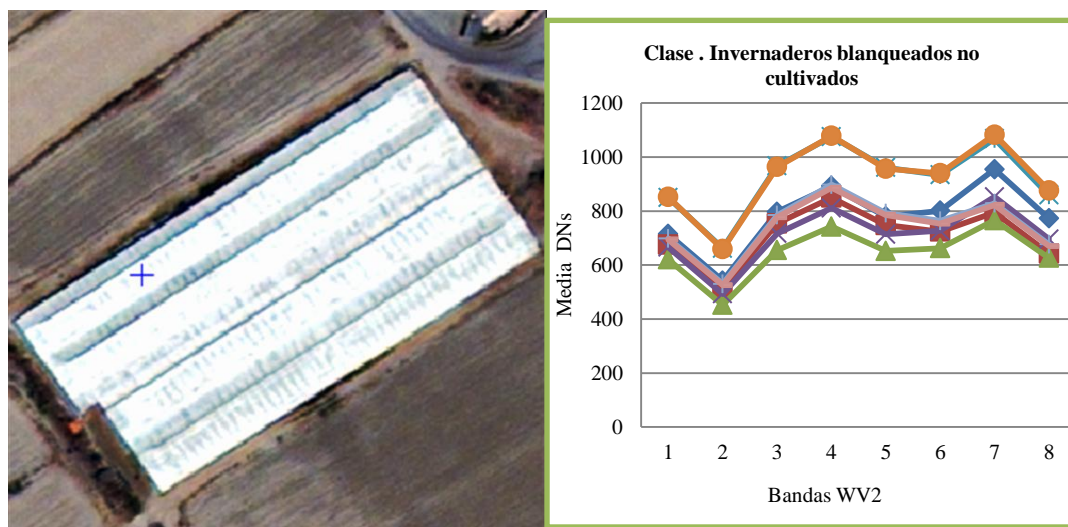


Figura 37: Imagen invernaderos blanqueados cultivados y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2.

c. Clasificación de los invernaderos tipo malla.

Se continua clasificando los invernaderos tipo malla respetando las áreas clasificadas anteriormente, los invernaderos tipo malla cultivada habían sido clasificados en parte en la clasificación de la vegetación. Se clasifican como invernaderos de tipo malla no cultivada, las áreas que tengan una media del $nDSM$ mayor de 0,67 y menor de 3m, dejando fuera las áreas con un brillo mayor de 475, y la relación ancho largo sea mayor 8, con un área menor de 4400. Tendríamos clasificados todos los invernaderos tipo malla no cultivada, los invernaderos de tipo malla cultivada se clasifican en su totalidad con los valores de la clasificación de vegetación y respetando los valores para malla no cultivada que contengan un $NDVI$ mayor de 0,13 sean malla cultivada. La media del $nDSM$ tan baja para separar los invernaderos tipo malla se produce porque presenta variaciones muy grandes dentro de un mismo invernadero, dando valores de 0 y su verdadera altitud.

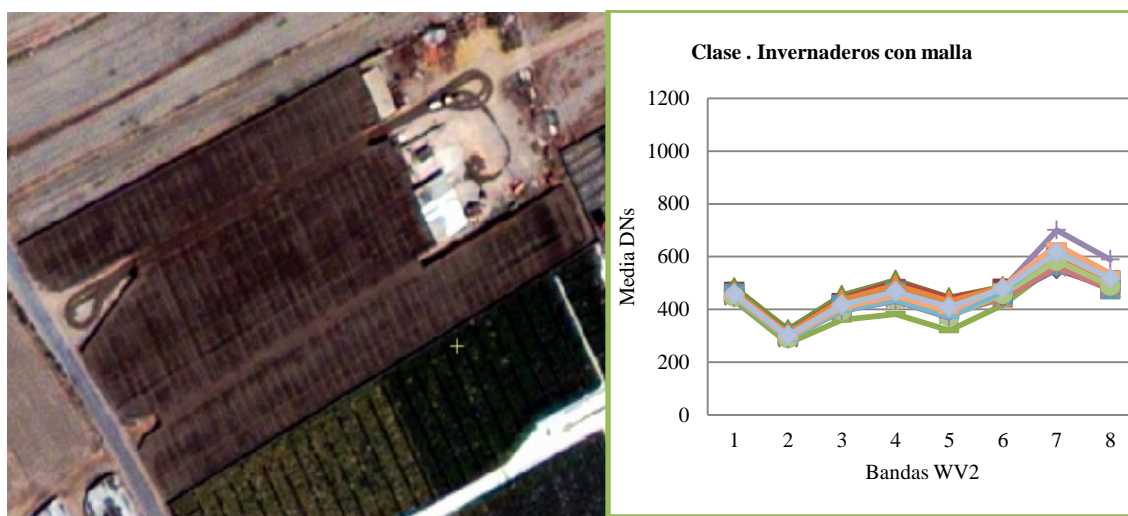


Figura 38: Imagen invernaderos con malla y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2

d. Clasificación edificios

La clasificación de los edificios se realizada respetando las áreas clasificadas anteriormente. Se clasifican como edificios aquellos que contengan una media del $nDSM$ mayor de 2m y un $NDVI$ menor o igual a 0,14, puesto que los edificios tienen un

índice de vegetación normalizada muy bajo. Dejando sin clasificar aquellas parcelas que contengan un brillo menor de 568, un área mayor de 4000 pixel y media del $nDSM$ menor 3, con una relación ancho largo mayor de 36. De esta forma quedarían clasificados los edificios que engloban, naves agrícolas, viviendas en la zona urbana y viviendas en la zona de invernaderos. La clase edificios presenta valores de DN muy bajos de la banda *blue* con respecto al resto de bandas.

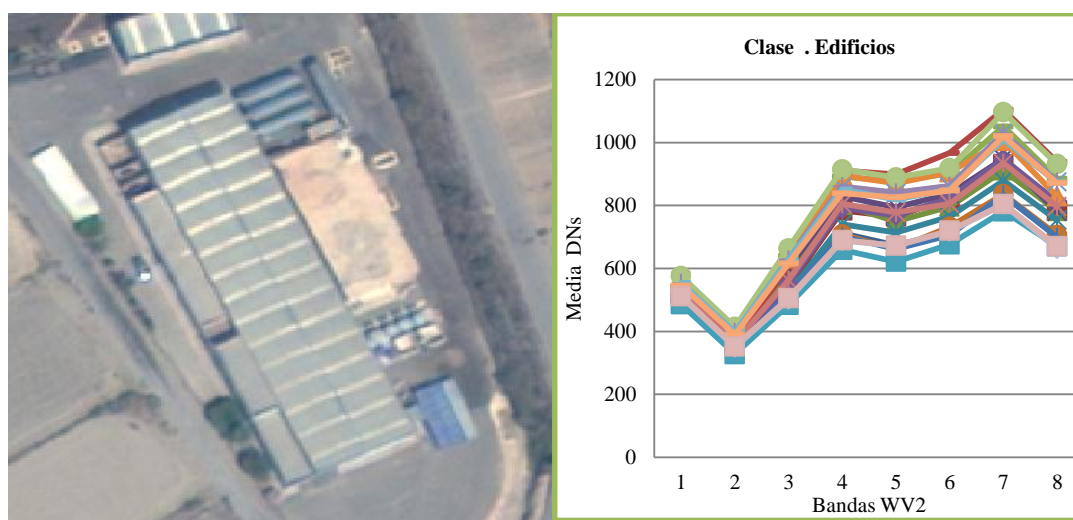


Figura 39: Imagen edificios y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2

e. Clasificación suelo desnudo

Para la clasificación de suelo desnudo se sigue respetando las áreas clasificadas anteriormente, y se clasifican como suelo desnudo aquellas que contengan una media del $nDSM$ menor de 1,7 y un valor de $NDVI$ menor de 0,16, con la restricción de que las áreas clasificadas como suelo desnudo que contengan un valor en la relación ancho largo mayor de 20 y un $NDBI$ menor 0,251 sean clasificados como carreteras.

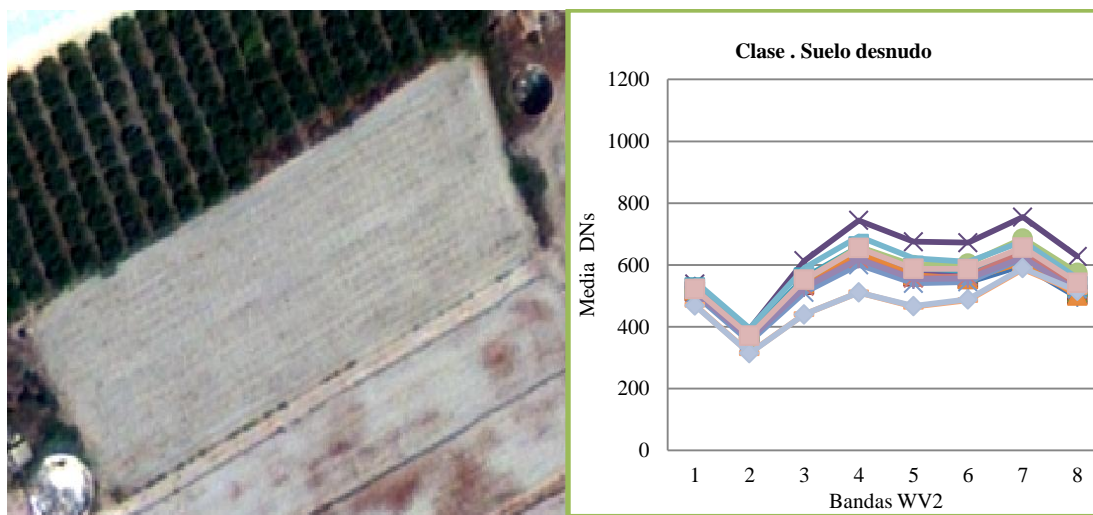


Figura 40: Imagen suelo desnudo y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2

f. Clasificación carreteras

Las áreas clasificadas como carreteras comparten igual valor medio del $nDSM$ y valores medios aproximados de $NDVI$ por eso con la clasificación de carreteras dentro de la clasificación de suelo desnudo, son suficiente mediante el índice $NDBI$.

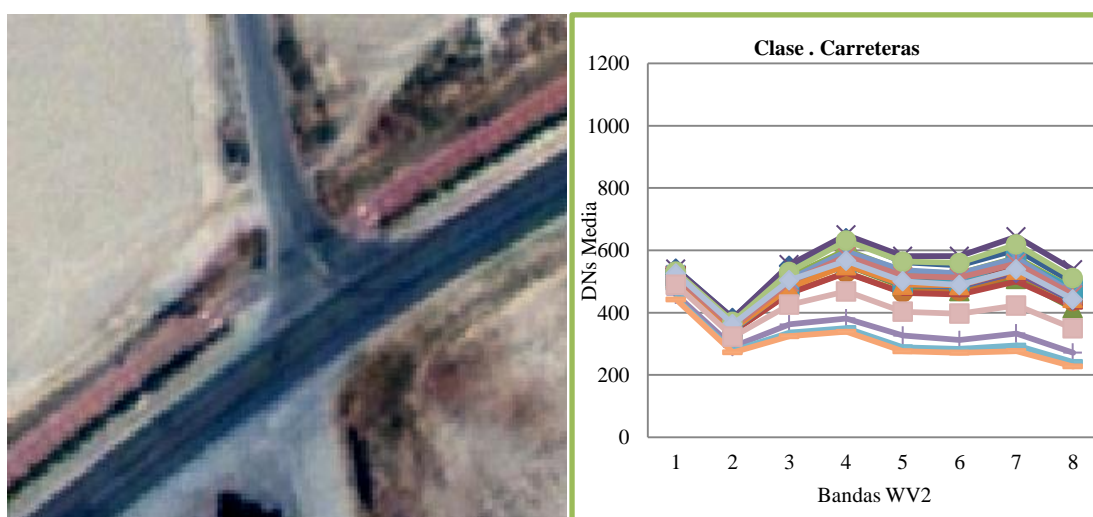


Figura 41: Imagen carreteras y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2

g. Clasificación de invernaderos no blanqueados

La clasificación de invernaderos no blanqueados se realiza por medio de los umbrales del *nDSM* y la desviación estándar del *NIR-1*. Los invernaderos no blanqueados sin cultivar tienen un valor del *nDSM* medio mayor de 2,2m y un valor de la desviación estándar del *NIR-1* menor de 65, excluyendo de esta clasificación todas las áreas clasificadas anteriormente, y las que posean un índice de forma mayor de 1,9, el valor del *NDBI* menor que 0, siendo clasificados los invernaderos cultivados sin blanquear aquellas áreas que cumplan los mismas restricciones que para los no cultivados y posean un valor medio del *NDVI* mayor de 0,11. La clase invernaderos sin blanquear no es muy representativa, puesto que teníamos poco invernaderos de muestra.




Figura 42: Imagen invernaderos cultivados y no cultivados y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2.

h. Clasificación otros invernaderos

Son clasificados como otros invernaderos los que se encuentran en construcción o destruidos, y se parte de la clasificación de edificios quitando aquellos polígonos con un área mayor de 5000 pixel y una desviación estándar del $nDSM$ mayor de 1. De las áreas que han sido clasificadas se dejan sin clasificar aquellas áreas con un $nDSM$ mayor de 1,31 los que posean una desviación estándar del $NIR-1$ menor de 80, puesto que tiene valores bajos de DN .

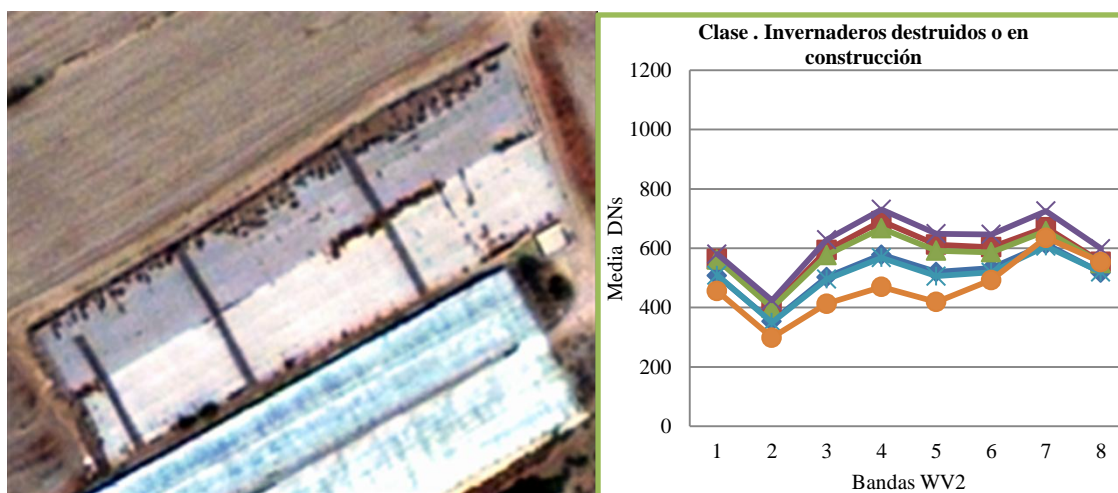


Figura 43: Imagen invernaderos destruidos o en construcción y valores medios del espectro electromagnético de las 8 bandas de una serie de muestras Coastal Blue, Blue, Green, Yellow, Red Red-Edge, NIR1 y NIR2

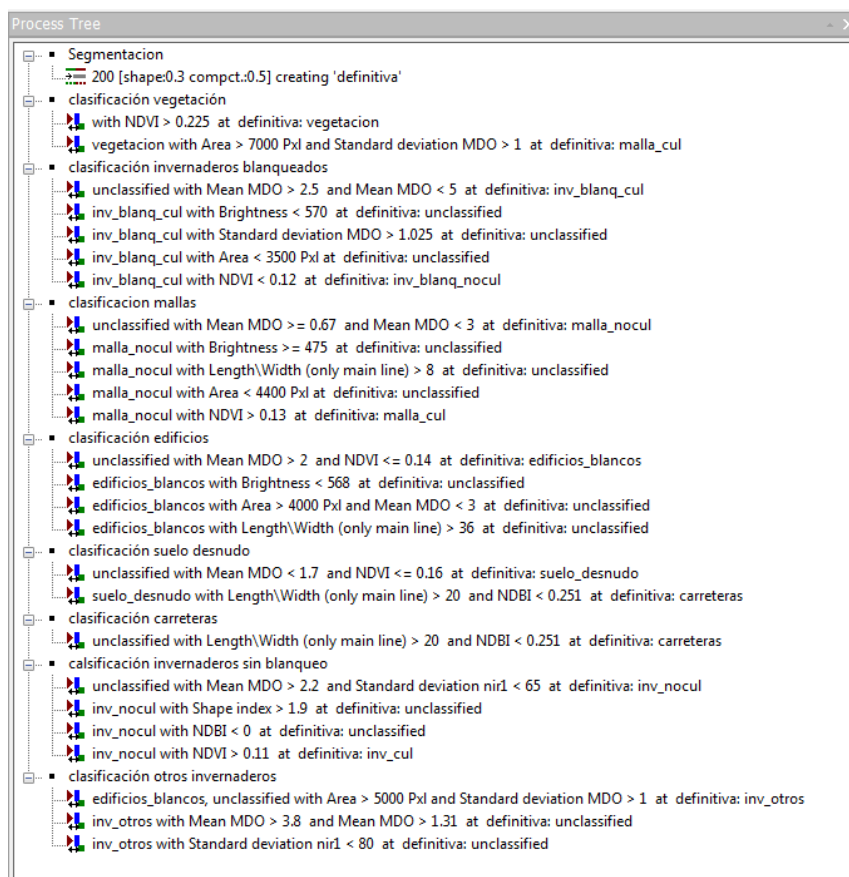


Figura 44: Proceso de clasificación por umbrales.

3.3.5.1 Estimación de la precisión de la clasificación.

Estimación de la precisión de la clasificación consiste en obtener el porcentaje de acierto para cada área u objeto de la imagen, entre su verdadera clasificación (clasificación manual inicial) y la propuesta por el clasificador.

Los índices de precisión de la clasificación usados en este trabajo estuvieron basados en la matriz de error (Congalton,1991). Una matriz de error es una herramienta especialmente efectiva en la evaluación de la precisión, ya que proporciona un punto de partida para una serie de técnicas estadísticas para examinar aún más la precisión en la clasificación (Congalton y Green, 2009). Se realizaron cuatro ensayos de clasificación, dos de ellos sobre la segmentación Óptima, un primer ensayo de clasificación mediante umbrales en eCognition, y un segunda clasificación con el software *Nearest Neighbor* también en eCognition, y los dos ensayos de clasificación restantes se realizaron sobre

la segmentación Multi-rresolución, mediante umbrales y con *Nearest Neighbor*. Para obtener mejores resultados se agruparon algunas clases especialmente difíciles de clasificar por sus semejanzas en cuanto a características, 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 (Figura 45).

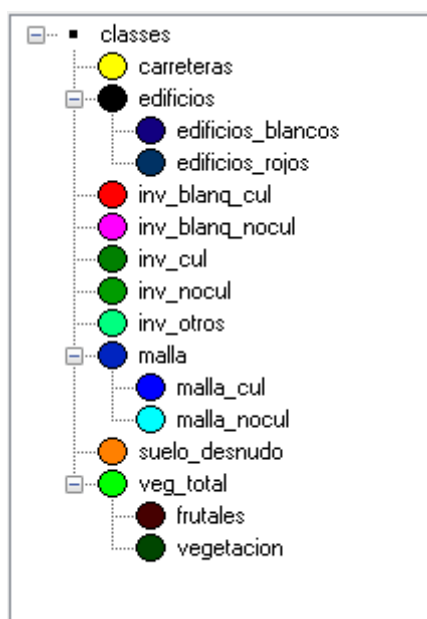


Figura 45: Clases originales para la clasificación y agrupamiento realizado

En esta matriz, los datos de la clasificación propuesta por el clasificador (representado por las columnas de la matriz) son comparados con los datos clasificados de referencia (representados por las filas de la matriz). La diagonal principal de la matriz indica el grado de acuerdo entre ambos grupos de datos. La precisión global (expresada en porcentaje, *overall accuracy*) para una imagen clasificada es calculada dividiendo el número total de áreas correctamente clasificados (suma de la diagonal principal) por el número total de áreas en la matriz de confusión (Story y Congalton, 1986). Un valor 100 para la precisión global indica un acuerdo perfecto entre los resultados de la clasificación y los datos de referencia. La precisión para cada clase fue también determinada a partir de la matriz de confusión, dividiendo el número de áreas

correctamente clasificados por el número total de áreas, indicados en la columna de los datos de referencia. Al mismo tiempo, los errores de omisión y comisión, pueden ser también determinados a partir de la matriz de confusión (Richards y Jia, 1999). La expresión de los errores de omisión y comisión en términos porcentuales suele denominarse riesgo del productor y riesgo del usuario. El primero de ellos consiste en la probabilidad de error en la que incurre el analista como consecuencia de la no inclusión de algunas de las áreas en la clase correspondiente (omisión). Por el contrario, el riesgo del usuario se refiere al que asume este cuando supone cierta la naturaleza de una de las áreas basada en la clasificación, cuando en realidad puede pertenecer a una clase diferente (comisión). Los complementarios a 100 de ambos riesgos serán la fiabilidad del productor (*producer accuracy*) y la fiabilidad del usuario (*user accuracy*). A través de esta matriz .Para complementar la determinación de la precisión, el índice Kappa (KIA) fue utilizado, el cual mide el grado de ajuste exclusivamente para la predicción de la clasificación y utiliza para el análisis los resultados de la matriz de confusión (Jensen, 1996).

En la matriz de error que se muestra como ejemplo en la Tabla 11, podemos ver a partir de la matriz que el sistema no tendría problemas en clasificar ovejas, pero tendría problemas en distinguir entre perros y gatos. La fiabilidad del productor y del usuario en este caso es del 100% puesto que clásica correctamente las ovejas. En el caso de los gatos la fiabilidad del productor es del 100%, ya que clasifica correctamente todos los gatos, pero la fiabilidad del usuario es del 50% porque clasifica perros como gatos, apareciendo en el total el doble de gatos que hay en realidad. En el caso de los perros la fiabilidad del productor es del 75% ya que clasifica perros como gatos y la del usuario es del 75% porque no están clasificados correctamente el total de perros.

Clases	Perros	Gatos	Ovejas	Total Asignado
Perros	15	0	0	15
Gatos	5	5	0	10
Ovejas	0	0	18	18
Total Real	20	5	18	
Fiabilidad Productor	75%	100%	100%	
Fiabilidad Usuario	75%	50%	100%	

Tabla 4: Ejemplo matriz de error

CAPÍTULO 4

RESULTADOS Y DISCUSIÓN

4.- RESULTADOS Y DISCUSIÓN

4.1.- RESULTADOS GLOBALES

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 segmentación Multi-rresolución en la que se generaron 743 (*OIs*) y la segmentación Óptima que genero 2137 objetos de interés, para a continuación ser clasificadas las dos segmentaciones, en eCognition con el clasificador *Nearest Neighbor* (vecino más cercano) y por medio de umbrales. En primer lugar los resultados de precisión (UA, PA, KIA por clase y OA) obtenidos a partir de las dos segmentaciones y los dos métodos de clasificación ensayados, muestra que se obtienen mejores resultados (tabla 5) con una segmentación Óptima con clasificación NN en la cual se respetan los invernaderos iniciales, tiene una precisión global (*overall accuracy*, *OA*) del 92.36%, casi 2 puntos mejor que la reportada por Tarantino y Figorito (2012), trabajando en unas condiciones similares, aunque sin utilizar datos de elevaciones (*nDSM*). Presenta en algunas de sus clases un 100% de acierto en cuanto *UA*, *UP* y *KIA*. La segmentación óptima presenta mejores resultados en la clasificación por umbrales que las dos clasificaciones en la segmentación Multi-rresolución aunque el porcentaje de acierto es menor que con una segmentación óptima clasificada por *NN* es bastante aceptable con un valor de *OA* 87%. En el caso de la segmentaciones Multi-rresolución la existencia de *IOs* de pequeño tamaño que formaban parte de un mismo invernadero causados por una segmentación excesiva (*oversegmentation*), provocaron una pérdida de precisión en la clasificación final, la segmentación Multi-rresolución con clasificación con el software *NN* da mejores resultados que por medio de umbrales, al igual que en la clasificación óptima, aunque más bajos que cualquier tipo de clasificación en la segmentación Óptima dando un valor de *OA* 84,4% de precisión, por debajo de la esperada, en cuanto a los datos obtenidos en la segmentación Multi-rresolución clasificada por umbrales da una precisión global que no podría ser aceptable para ningún trabajo dando una precisión de 66,4%. Los datos de la clasificación con *NN* son algo insuficiente puesto que se disponía de pocos áreas de clasificación de algunas de las clases y por consiguiente pocas áreas de entrenamiento.

DETECCIÓN REMOTA DE INVERNADEROS A PARTIR DE ESTÉREO PARES PAN Y MS DEL SATÉLITE WORLDVIEW-2 APLICANDO TÉCNICAS DE CLASIFICACIÓN BASADA EN OBJETOS

SEGMENTACIÓN MULTIRRESOLUCIÓN CLASIFICADA CON NN															
User Class	Sample	inv_blang_cul	inv_blang_nocul	inv_cul	inv_blang_nocul	inv_cul	inv_nocul	inv_nocul	inv_otros	suelo_desnudo	carreteras	veg_total	edificios	mall	Sum
inv_blang_cul	12	0	0	0	0	0	0	0	0	1	0	0	1	0	20
inv_blang_nocul	2	27	0	0	0	0	0	0	0	0	0	0	1	0	31
inv_cul	0	0	3	0	0	0	0	0	0	0	0	1	0	2	6
inv_nocul	0	0	0	1	0	0	0	0	0	0	1	0	0	0	2
inv_otros	1	0	0	0	0	12	0	0	0	5	1	2	1	0	22
suelo_desnudo	0	0	0	0	0	0	0	0	2	91	0	0	0	3	96
carreteras	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
veg_total	0	0	0	0	0	0	0	0	0	0	0	29	0	1	30
edificios	0	0	0	0	0	0	0	0	0	0	0	0	13	0	13
mall	0	0	0	0	0	0	0	1	1	1	2	2	0	28	34
unclassified	0	0	0	0	0	0	0	0	0	1	1	1	0	0	2
Sum	15	33	3	1	16	98	5	16	35	82,86	81,25	82,86	81,25	82,35	81,25
Precisión %															
Producer	80	81,82	100	100	75	92,86	0	82,86	81,25	82,86	81,25	82,86	81,25	82,35	81,25
User	60	87,09	50	50	54,54	94,79	undefined	96,67	100	96,67	100	96,67	100	82,35	96,67
KIA Per Class	78,31	79,31	100	100	72,65	88,57	0	80,58	80,25	80,58	80,25	80,58	80,25	0,79650238474	80,25
Precisión Total %															
Overall Accuracy	84,38														
KIA	80,31														

SEGMENTACIÓN MULTIRRESOLUCIÓN CLASIFICADA POR UMBRALES															
User Class	Sample	inv_blang_cul	inv_blang_nocul	inv_cul	inv_blang_nocul	inv_cul	inv_nocul	inv_nocul	inv_otros	suelo_desnudo	carreteras	veg_total	edificios	mall	Sum
inv_blang_cul	5	0	0	0	0	0	0	0	0	0	0	0	0	0	5
inv_blang_nocul	3	13	0	0	0	0	0	0	2	0	0	0	0	0	18
inv_cul	0	0	2	0	0	0	0	0	0	0	0	0	0	0	2
inv_nocul	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
inv_otros	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
suelo_desnudo	0	0	0	0	0	0	0	0	3	95	0	2	1	8	109
carreteras	0	3	0	0	0	0	0	0	0	5	0	0	0	2	10
veg_total	0	0	0	0	0	0	0	0	0	0	0	27	0	5	32
edificios	0	14	0	0	7	1	0	0	14	0	0	0	14	0	36
mall	0	0	0	0	0	0	0	0	0	0	0	2	0	9	11
unclassified	7	3	1	1	4	2	1	4	1	10	1	4	1	10	33
Sum	15	33	3	1	16	98	5	35	16	82,86	81,25	82,86	81,25	82,35	81,25
Precisión %															
Producer	33,34	39,39	66,67	100	66,67	100	100	77,14	87,5	77,14	87,5	77,14	87,5	26,47	77,14
User	100	72,22	100	100	87,16	50	84,38	81,82	85,45	81,82	85,45	81,82	85,45	23,17	81,82
KIA Per Class	32,01	34,81	66,4	66,4	0	100	73,88	73,88	85,45	73,88	85,45	73,88	85,45	23,17	73,88
Precisión Total %															
Overall Accuracy	66,41														
KIA	57,71														

SEGMENTACIÓN ÓPTIMA CLASIFICADA CON NN												
User Class \ Sample	inv_blang_cul	inv_blang_nocul	inv_cul	inv_nocul	inv_otros	suelo_desnudo	carreteras	veg_total	edificios	mall	Sum	
inv_blang_cul	6	0	0	0	0	0	0	0	0	0	6	
inv_blang_nocul	0	9	0	0	0	0	0	0	2	0	11	
inv_cul	0	0	3	0	0	0	0	0	0	0	3	
inv_nocul	0	0	0	1	0	0	0	0	0	0	1	
inv_otros	0	0	0	0	6	0	0	0	1	0	7	
suelo_desnudo	0	0	0	0	0	167	0	1	0	0	168	
carreteras	0	0	0	0	0	4	21	4	0	0	29	
veg_total	0	0	0	0	0	0	0	109	0	0	109	
edificios	0	0	0	0	0	0	0	1	62	0	63	
mall	0	0	0	0	0	3	0	18	0	27	48	
Sin clasificar	0	0	0	0	0	0	0	0	0	0	0	
Total	6	9	3	1	6	174	21	133	65	27		
Precisión %	100	100	100	100	100	95,98	100	81,95	95,38	100		
Producer	100	81,82	100	100	85,71	99,4	72,41	100	98,41	56,25		
User	100	100	100	100	100	93,54	100	76,1	94,62	100		
KIA Per Class	100	100	100	100	100	93,54	100	76,1	94,62	100		
Precisión Total %	92,36											
Overall Accuracy	89,78											
KIA												

SEGMENTACIÓN ÓPTIMA CLASIFICADA POR UMBRALES												
User Class \ Sample	inv_blang_cul	inv_blang_nocul	inv_cul	inv_nocul	inv_otros	suelo_desnudo	carreteras	veg_total	edificios	mall	Sum	
inv_blang_cul	6	0	0	0	0	0	0	0	0	0	6	
inv_blang_nocul	0	9	0	0	1	0	0	0	0	0	10	
inv_cul	0	0	3	0	0	0	0	0	0	0	3	
inv_nocul	0	0	0	1	0	0	0	0	2	0	3	
inv_otros	0	0	0	0	3	0	0	0	0	0	3	
suelo_desnudo	0	0	0	0	1	165	2	5	4	0	177	
carreteras	0	0	0	0	0	0	17	0	0	0	17	
veg_total	0	0	0	0	0	2	0	103	0	0	105	
edificios	0	0	0	0	0	1	0	0	53	0	54	
mall	0	0	0	0	0	0	0	0	0	27	27	
Sin clasificar	0	0	0	0	1	6	2	25	6	0	40	
Total	6	9	3	1	6	174	21	133	65	27		
Precisión %	100	100	100	100	100	94,83	80,95	77,44	81,54	100		
Producer	100	90	100	100	100	93,22	100	98,09	98,15	100		
User	100	100	100	100	49,66	91,41	80,19	70,48	78,99	100		
KIA Per Class	100	100	100	100	49,66	91,41	80,19	70,48	78,99	100		
Precisión Total %	86,97											
Overall Accuracy	82,62											
KIA												

Tabla 5: Matriz de error segmentación Multi-rresolución clasificada con NN. Matriz de error segmentación Multi-rresolución clasificada por medio de reglas de interacción del conocimiento Matriz de error segmentación Óptima clasificada con NN. Matriz de error segmentación Óptima clasificada por medio de reglas de interacción del conocimiento.

4.1.1 Clasificación vegetación.

En la segmentación Multi-rresolución clasificada con *NN*, nos aporta 35 áreas verdaderas del tipo vegetación, de estas 35 áreas solo 29 han sido clasificadas correctamente. De las 6 áreas restantes, 2 áreas han sido clasificadas como invernaderos tipo malla, ya que hay invernaderos de malla cultivada con umbrales de *NDVI* igual a los de vegetación, y la desviación estándar del *nDSM* presenta grandes variaciones en este tipo de invernaderos puesto que toma puntos en el suelo dentro del invernadero. También han sido clasificadas 2 áreas como otros invernaderos ya que son los invernaderos en construcción y destruidos en los cuales hay presente una gran cantidad de vegetación. Otra área ha sido clasificada como invernaderos cultivados por las circunstancias de vegetación en el interior, y por último un área no ha podido ser clasificada. La clasificación total nos da 30 áreas clasificadas puesto que ha introducido un área de tipo malla en vegetación.

En la clasificación por umbrales de la segmentación Multi-rresolución se obtienen peores resultados puesto que de las 35 áreas verdaderas solo 27 han sido clasificadas correctamente, de los 8 restantes 2 han sido clasificadas como suelo desnudo debido, a que tienen alguna vegetación herbácea que da valores altos de *NDVI*, 2 áreas han sido clasificadas como malla por la circunstancias anteriormente descritas, pero lo que cabe destacar es que cuatro de las áreas no han podido ser clasificadas en ninguna clase. Dando la clasificación total 32 áreas de tipo vegetación por la inclusión de 5 áreas de tipo malla en esta clase.

En la segmentación Óptima con clasificación por *NN* se toman como referencia 133 áreas verdaderas, de las cuales solo 109 han sido clasificadas correctamente, de las 24 áreas mal clasificadas, 18 han sido clasificadas como tipo malla, 4 como carreteras, 1 como suelo desnudo y una última como edificios, en este caso como no hay intrusión de otras áreas en la clase vegetación nos da un valor de del 100% de *UA* (ver Tabla 6). En la segmentación Óptima clasificada por umbrales de las 133 áreas verdaderas solo han podido ser clasificadas 103 quedando 25 áreas sin clasificar, y las cinco restantes clasificadas como suelo desnudo.

Para la clasificación de vegetación los mayores problemas se dan sobre todo por que clasifica la vegetación como suelo desnudo y invernaderos de tipo malla.

Vegetación Total	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con NN	82,86%	96,67%	80,58%
Segmentación Multi-rresolución Clasificación Umbrales	77,14%	84,38%	73,88%
Segmentación Óptima Clasificación con NN	81,95%	100%	76,10%
Segmentación Óptima Clasificación por Umbrales	77,44%	98,10%	70,48%

Tabla 6: Precisiones obtenidas sobre la clase vegetación

4.1.2 Clasificación invernaderos blanqueados cultivados

En la segmentación Multi-rresolución clasificada con *NN*, hay 15 áreas verdaderas debido a la segmentación de algunos de los 6 invernaderos cultivados. De las 15 áreas han sido clasificadas correctamente 12 de ellas, de las tres áreas restantes 2 han sido clasificadas como invernaderos blanqueados no cultivados, y 1 como otros invernaderos estos errores han sido debidos a los valores del brillo. En la segmentación Multi-rresolución clasificada por umbrales se da una mala clasificación puesto que solo 5 de los 15 invernaderos blanqueados cultivados han sido clasificados correctamente, 7 de los restantes no ha sido posible clasificarlos y los otros tres han sido clasificados como invernaderos blanqueados no cultivados. Este método no incluye ninguna área de otro tipo en la clase invernaderos blanqueados por lo que da un 100% de *UA*, y los valores de *PA* y *KIA* tan bajos, se deben a los errores del analista.

La segmentación Óptima clasificada con *NN* nos da 100% en los valores *UA*, *PA* y *KIA* la que nos muestra que todas las áreas han sido clasificadas correctamente, y no ha sido clasificada ningún área de otro tipo como invernaderos blanqueados cultivados, al igual que la clasificación con *NN* la clasificación por umbrales arroja iguales resultados.

La mejor clasificación de invernaderos blanqueados cultivados se da a través de una segmentación Óptima, presentando valores claramente mejores que con segmentación Multi-rresolución.

Inv. Blanqueados Cultivados	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	80%	60%	78,31%
Segmentación Multi-rresolución Clasificación Umbrales	33,33%	100%	32%
Segmentación Óptima Clasificación con <i>NN</i>	100%	100%	100%
Segmentación Óptima Clasificación por Umbrales	100%	100%	100%

Tabla 7: Precisiones obtenidas sobre invernaderos blanqueados cultivados

4.1.3 Clasificación invernaderos blanqueados sin cultivar

La segmentación Multi-rresolución clasificada con *NN*, los 9 invernaderos los divide en 33 áreas verdaderas de invernaderos blanqueados sin cultivar, 27 de estas áreas han sido clasificadas correctamente y las 6 áreas restantes han sido clasificadas como invernaderos blanqueados cultivados. Hay que destacar que el blanqueado no permite la diferenciación entre una clase y otra del *NDVI* puesto que no se permite la emisión o reflejo de las bandas pertenecientes al *NDVI* por parte de la vegetación del interior. La segmentación Multi-rresolución clasificada por umbrales de las 33 áreas verdaderas solo 13 son clasificadas correctamente, de las restantes 14 son clasificadas como edificios, 3 como carreteras y otras 3 no han sido posible clasificarlas esto es debido a los valores del *nDSM* de los edificios presentan valores iguales, al igual que algunas áreas del tipo carreteras.

La segmentación Óptima con clasificación *NN*, de los nueve invernaderos reales clasifica los nueve correctamente de ahí el 100% de *PA*, pero incluye en esta clase dos edificios que hacen disminuir el *UA* (tabla 8). La segmentación Óptima con clasificación por umbrales clasifica de igual modo todos los invernaderos correctamente aunque en este caso asigna un invernadero de la clase otros invernaderos a esta.

En la segmentación óptima clasifica correctamente todos los invernaderos de su clase, lo cual no se da en la segmentación Multi-rresolución.

Inv. Blanqueados Sin Cultivar	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	81,82%	87,10%	79,31%
Segmentación Multi-rresolución Clasificación Umbrales	39,39%	72,22%	34,81%
Segmentación Óptima Clasificación con <i>NN</i>	100%	81,82%	100%
Segmentación Óptima Clasificación por Umbrales	100%	90%	100,00%

Tabla 8: Precisiones obtenidas sobre invernaderos sin cultivar

4.1.4 Clasificación invernaderos tipo malla.

La segmentación Multi-rresolución nos divide los 27 invernaderos tipo malla en 34 áreas. La clasificación con *NN* clasifica correctamente 28 áreas, de los 6 restantes que no clasifica correctamente, 3 son clasificados como suelo desnudo, 2 como invernaderos cultivados y 1 de la clase vegetación. La clasificación por umbrales solo es capaz de clasificar correctamente 9 de los 34 invernaderos, 10 no los clasifica, clasifica 8 como suelo desnudo, 2 como carreteras y 5 como vegetación, comentado anteriormente en la clasificación de vegetación.

La segmentación Óptima con clasificación con *NN* clasifica correctamente los 27 invernaderos tipo malla, aunque clasifica en esta clase 18 áreas pertenecientes a vegetación y 3 a carreteras lo que da el valor tan bajo de *UA*. Por el contrario la clasificación por umbrales en la segmentación Óptima clasifica correctamente los 27 invernaderos y no incluye ninguna área de otra clase en esta.

Invernaderos con Malla	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	82,35%	82,35%	79,65%
Segmentación Multi-rresolución Clasificación Umbrales	26,47%	81,82%	23,17%
Segmentación Óptima Clasificación con <i>NN</i>	100%	56,25%	100%
Segmentación Óptima Clasificación por Umbrales	100%	100%	100%

Tabla 9: Precisiones obtenidas sobre mallas

4.1.5 Clasificación edificios

La clasificación de edificios con segmentación Multi-rresolución clasificada con *NN*, muestra de las 16 áreas consideradas como edificios clasifica correctamente 13 de ellas, clasificando las áreas restantes, una como invernadero blanqueado cultivado, otra como invernadero blanqueado sin cultivar y por último clasifica otra área como otros invernaderos, sin que se incluyan otras clases en esta lo que da un *UA* del 100%. En la clasificación por umbrales de la segmentación Multi-rresolución clasifican correctamente 14 de los 16 edificios, uno no lo clasifica y otro lo clasifica como suelo desnudo en esta clase hay inclusión de otras clases no clasificada correctamente, mencionadas anteriormente.

La segmentación Óptima con clasificación *NN* contabiliza 65 edificios verdaderos de los cuales clasifica correctamente 62, y clasifica 2 áreas como invernaderos blanqueados no cultivado y uno como invernadero sin cultivar en esta clasificación también hay inclusión de un área clasificada como vegetación. La clasificación por umbrales clasifica correctamente 53 de las áreas segmentadas, 6 de las 65 totales no las clasifica, asigna dos áreas a invernaderos no cultivados y 4 a suelo desnudo, y se clasifica un área de suelo desnudo como edificios.

Edificios	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	81,25%	100%	80,25%
Segmentación Multi-rresolución Clasificación Umbrales	87,50%	38,89%	85,45%
Segmentación Óptima Clasificación con <i>NN</i>	95,38%	98,41%	94,62%
Segmentación Óptima Clasificación por Umbrales	81,54%	98,15%	78,99%

Tabla 10: Precisiones obtenidas sobre edificios

4.1.6 Clasificación suelo desnudo

En la clasificación *NN* de suelo desnudo a partir de la segmentación Multi-rresolución se generaron 98 áreas verdaderas de las cuales 91 han sido clasificadas correctamente, 5 han sido clasificadas como otros invernaderos, 1 como invernaderos blanqueados y 1 como invernaderos tipo malla. En la clasificación por umbrales 95 áreas han sido clasificadas correctamente de las 98, 2 no se han podido clasificar y 1 ha sido clasificada como edificios.

En la segmentación Óptima con clasificación *NN* se generaron 174 objetos verdaderos de los cuales 167 fueron clasificados correctamente, 4 fueron clasificados como carreteras y 3 como tipo malla. En la segmentación Óptima clasificada por umbrales de las 174 áreas verdaderas, 167 han sido clasificadas correctamente, 6 no han sido clasificadas, 2 han sido clasificadas como vegetación total y 1 como edificios.

La clasificación errónea de la clase suelo desnudo presenta errores, ya que algunas áreas tienen elevaciones altas en el *nDSM*.

Suelo Desnudo	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	92,86%	94,79%	88,57%
Segmentación Multi-rresolución Clasificación Umbrales	96,94%	87,16%	94,67%
Segmentación Óptima Clasificación con <i>NN</i>	95,98%	99,40%	93,54%
Segmentación Óptima Clasificación por Umbrales	94,83%	93,22%	91,41%

Tabla 11: Precisiones obtenidas sobre suelo desnudo

4.1.7 Clasificación carreteras

En la clasificación de carreteras a partir segmentación Multi-rresolución clasificada con *NN*, no se ha podido clasificar ninguna de las 5 áreas verdaderas, 2 han sido clasificadas en la clase correspondiente a tipo malla, 1 no ha sido clasificada, y las otras 2 una como invernadero como invernadero no cultivado y otros invernaderos, por esos motivos los valores de *UA*, *PA* y *KIA* son 0% (Tabla 12). En cuanto a la segmentación Multi-rresolución clasificada por umbrales los valores varían bastante, ya que han sido clasificadas las 5 áreas correctamente pero se da intrusión en esta clase de 3 áreas correspondientes a invernaderos blanqueados no cultivado y 2 invernaderos tipo malla.

En la segmentación Óptima clasificada con *NN* la clase carreteras tiene 21 áreas verdaderas, las cuales clasifica correctamente de ahí el valor de 100% de *PA* y *UA* pero se clasifican erróneamente en esta clase, 4 áreas de suelo desnudo 4 correspondientes a vegetación. En la clasificación por umbrales de las 21 áreas correspondiente se han clasificado correctamente 17, de las áreas restantes no han podido ser clasificadas 2, y otras 2 han sido clasificadas como suelo desnudo, al no haber en este caso ningún área clasificada en esta clase erróneamente se da un 100% *UA*.

Carreteras	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	0%	Indefinido	0%
Segmentación Multi-rresolución Clasificación Umbrales	100%	50%	100%
Segmentación Óptima Clasificación con <i>NN</i>	100%	72,41%	100%
Segmentación Óptima Clasificación por Umbrales	80,95%	100%	80,20%

Tabla 12: Precisiones obtenidas sobre carreteras

4.1.8 Clasificación invernaderos no blanqueados cultivados

La segmentación Multi-rresolución clasificada con *NN* clasifica correctamente las tres áreas clasificadas, aunque se clasifican en esta clase 3 áreas más, 1 de vegetación y 2 de tipo malla. En la clasificación por umbrales no se clasifica ninguna área en esta clase, aunque de las 3 verdaderas una no se ha podido clasificar.

La segmentación Óptima clasificada con *NN* y por umbrales ofrece valores del 100% en *UA*, *PA* y *KIA* (Tabla 13), al estar clasificadas correctamente todas las áreas y no haber sido clasificada ningún área en esta clase.

Los valores obtenidos en esta clase son poco orientativos debido al bajo número de áreas a clasificar.

Inv. Cultivados	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	100%	50,00%	100,00%
Segmentación Multi-rresolución Clasificación Umbrales	66,67%	100,00%	66,40%
Segmentación Óptima Clasificación con <i>NN</i>	100%	100,00%	100%
Segmentación Óptima Clasificación por Umbrales	100%	100%	100,00%

Tabla 13: Precisiones obtenidas sobre invernaderos cultivados

4.1.9 Clasificación invernaderos no blanqueados sin cultivar

Invernaderos blanqueados sin cultivar solo encontramos uno en la zona de estudio, en la segmentación Multi-rresolución la área ha sido clasificada correctamente, pero otra área perteneciente a la clase carreteras ha sido clasificada. En la clasificación por umbrales no se ha podido clasificar y ningún área correspondiente a otra clase se ha clasificado con invernaderos no cultivados.

La segmentación Óptima con clasificación *NN* presenta un 100% de *UA*, *PA* y *KIA* lo que indica que ha sido clasificada correctamente y ningún área perteneciente a otra clase ha sido clasificada en esta. En la clasificación por umbrales de la segmentación Óptima se ha clasificado correctamente el área, aunque 2 áreas correspondientes a edificios se han clasificado en esta clase.

Inv. Sin Cultivar	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	100%	50%	100%
Segmentación Multi-rresolución Clasificación Umbrales	0%	Indefinido	0%
Segmentación Óptima Clasificación con <i>NN</i>	100%	100%	100%
Segmentación Óptima Clasificación por Umbrales	100%	33,33%	100,00%

Tabla 14: Precisiones obtenidas sobre invernaderos sin cultivar

4.1.10 Clasificación otros invernaderos.

La clasificación de los invernaderos en construcción o destruidos, han sido difíciles de clasificar, ya que se encuentran en diferentes estados de construcción y los destruidos también existe mucha variación por el estado del deterioro unos más que otros y presentan grandes variaciones en cuanto a la vegetación silvestre de su interior.

La clasificación con *NN* en la segmentación Multi-rresolución contempla 16 áreas verdaderas de las cuales solo 12 han sido clasificadas correctamente, 1 área ha sido

clasificada como invernadero blanqueado cultivado, 2 como suelo desnudo y 1 como invernadero tipo malla, se han clasificado como otros invernaderos, áreas de las clases suelo desnudo, edificios, carreteras y vegetación. En la segmentación Multi-rresolución clasificada por umbrales ningún área de las 16 es clasificada correctamente, y no se ha clasificado ningún área perteneciente a otra clase en esta.

En la clasificación con *NN* de la segmentación Óptima clasifica correctamente las 6 áreas aunque introduce un área correspondiente a edificios. La segmentación Óptima clasificada por umbrales solo clasifica tres invernaderos correctamente, clasifica un área como invernadero blanqueado no cultivado, un área como suelo desnudo y una no la clasifica.

Otros Inv.	PA	UA	KIA
Segmentación Multi-rresolución Clasificación con <i>NN</i>	75%	54,55%	72,65%
Segmentación Multi-rresolución Clasificación Umbrales	0%	Indefinido	0%
Segmentación Óptima Clasificación con <i>NN</i>	100%	85,71%	100%
Segmentación Óptima Clasificación por Umbrales	50%	100%	49,66%

Tabla 15: Precisiones obtenidas sobre otros invernaderos

4.1.11 Resultado final

El resultado final de los dos métodos de clasificación, la clasificación basada en reglas de interacción del conocimiento y *NN*, a partir de la segmentación Multi-rresolución y la segmentación Óptima se puede observar en la Figura 46 y 47, comparándose con los mapas de referencia sobre las dos segmentaciones.

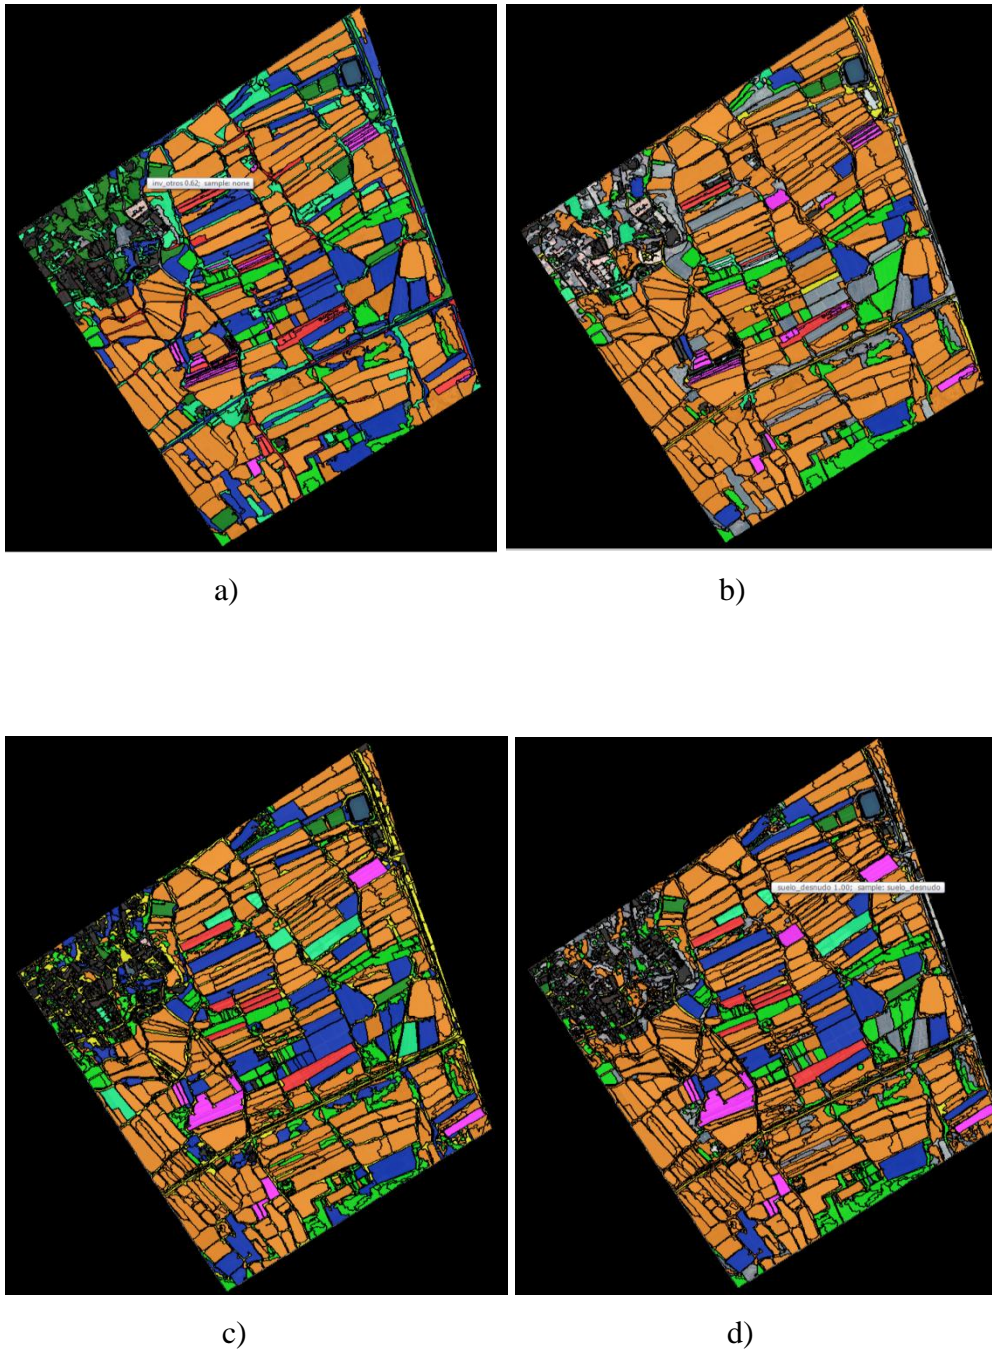



Figura 46: a) Segmentación Multi-rresolución clasificada con NN. b) Segmentación Multi-rresolución clasificada por medio de reglas de interacción del conocimiento c) Segmentación Óptima clasificada con NN. d) Segmentación Óptima clasificada por medio de reglas de interacción del conocimiento.



a)

b)

Figura 47: a) Mapa de referencia sobre la segmentación Multi-rresolución b) Mapa de referencia sobre la segmentación Óptima.

CAPÍTULO 5

CONCLUSIONES

5.- 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, o a las que por cualquier motivo, no tengamos acceso.

De los cuatros ensayos de clasificación, realizados los mejores resultados de clasificación se obtienen a partir de una segmentación Óptima clasificada por medio del algoritmo *NN* de eCognition, utilizando previamente la herramienta de optimización del espacio de características (*Features Space Optimization, FSO*). La segmentación Óptima clasificada por umbrales ofrece también buenos resultados, aunque las precisiones caen de forma espectacular sobre la segmentación Multi-rresolución clasificada por umbrales. Esto parece indicar del método de umbralización, no es muy estable, ni siquiera dentro de la misma área de trabajo. Sin embargo, la segmentación Multi-rresolución clasificada con *NN* no ofrece unos resultados tan distante de los generados en la clasificación Óptima, como ocurre en el caso de la segmentación clasificada por umbrales.

Resulta también interesante la diferenciación alcanzada en la clasificación, llegando a detectar invernaderos blanqueados cultivados y sin cultivar, invernaderos de tipo malla anti insectos, invernaderos sin blanqueo, cultivados y sin cultivar. .

Para la clasificación de invernaderos mediante imágenes de *VHR* con *NN* las mejores características son los índices de vegetación (*CRI* y *Vogre*), el ratio de escena del *nDSM* y del *NIR-1*, la desviación estándar de la banda red y del *nDSM*, el área y la media de la banda azul. Sin embargo, en la clasificación por umbrales las características más influyentes son el *NDVI* y las elevaciones del *nDSM*.

Esta metodología de trabajo podrá ser de gran utilidad para estudiar las superficies destinadas a invernaderos de Marruecos. Además podremos saber la cantidad de invernaderos que se encuentran en producción y así estar preparados para las posibles inundaciones del mercado comunitario a partir de productos marroquíes.

Las debilidades de este trabajo son en primer lugar que el *Ground truth*, se realizó a posteriori y no se ha podido comprobar en campo. En segundo lugar la generación del *nDSM*, se podría mejorar en los procesos de *matching* por medio de *semiglobal matching* (Hitmiller, 2008) y los procesos de filtrado. En tercer lugar mejorar la segmentación Multi-resolución para que se parezca lo máximo posible a la Óptima, sin que se dividan invernaderos.

CAPÍTULO 6

FUTUROS TRABAJOS

6.- FUTUROS TRABAJOS

- Detección remota de invernaderos a partir de estéreo pares pan y ms del satélite *worldview-2* aplicando técnicas de clasificación basada en objetos en una zona con mayor número de invernaderos y mayor variedad de clases de invernaderos.
- Estudio para determinar los mejores parámetros de escala, forma y compacidad en la segmentación con eCognition.
- Estudio comparativo con los mismos métodos, en la misma zona de clasificación para obtener la evolución de la superficie de invernaderos.
- Estudio comparativo mediante la misma clasificación realizada en este proyecto a otras zonas agrícolas, para observar la variación de la utilización de la superficie del suelo.
- Estudio para obtener *nDSM* de mayor precisión a partir de imágenes de satélite mediante el empleo de otros algoritmos de *matching* automático y del empleo de filtros más objetivos para pasar de manera más óptima del *DSM* a *DEM*.

CAPÍTULO 7

BIBLIOGRAFÍA

7.- BIBLIOGRAFÍA

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.

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.

AGUILAR, M. A., SALDAÑA, M. M., & AGUILAR, F. J. in press. *Generation and Quality Assessment of Stereo-Extracted DSM from GeoEye-1 and WorldView-2 Imagery*. IEEE Transactions on Geoscience and Remote Sensing. <http://dx.doi.org/10.1109/TGRS.2013.2249521>

Tesis Doctoral de MARÍA DEL MAR SALDAÑA DÍAZ, *Generación de datos georreferenciados de muy alta resolución a partir de imágenes de los satélites GeoEye-1 y WorldView-2*, directores: Dr. Manuel Ángel Aguilar Torres y Dr. Fernando José Aguilar Torres

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

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, 2002.

OUMAR, Z., & ONISIMO, M. 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.

PÉREZ, J., LÓPEZ, J. C., & FERNÁNDEZ, M. D. 2002. *La Agricultura del sureste: situación actual y tendencias de las estructuras de producción en la horticultura Almeriense*. La Agricultura Mediterránea en el Siglo XXI. Instituto de Estudios Socioeconómicos de Cajamar, 262-282.

TARANTINO, E. & FIGORITO, B. 2012. *Mapping Rural Areas with Widespread Plastic Covered Vineyards Using True Color Aerial Data*. Remote Sensing, 4, 1913-1928.

TORRENS, M. 2006. *El sector de Invernaderos en Marruecos*. Instituto Español de Comercio Exterior (ICEX). Nota Sectorial, 15 pp.

SHAMSODDINI, A., TRINDER J. C., & TURNER, R. (2013): *Pine plantation structure mapping using WorldView-2 multispectral image*, International Journal of Remote Sensing, 34:11, 3986-4007

MAHMOUDI, F.T., SAMADZADEGAN, F., & REINARTZ. P., (2013): *Object oriented image analysis based on multi-agent recognition system*. Computers & Geosciences 54, 219–230

AGÜERA, F., & LIU, J.G., (2009) *Automatic greenhouse delineation from QuickBird and Ikonos satellite images*. Computers and Electronics in Agriculture (2009)

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

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, 45–56

Geomatica 2013 tutorial. Geomatica OrthoEngine Pleiades 1A data – DEM extraction and DSM to DTM conversion.

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, 2860-2880.