



**UNIVERSIDAD DE ALMERÍA**

**ESCUELA SUPERIOR DE INGENIERÍA**

**TITULACIÓN DE INGENIERÍA TÉCNICA AGRÍCOLA  
ESPECIALIDAD MECANIZACIÓN Y CONSTRUCCIONES  
RURALES**

***OPTIMIZACIÓN DE LA CLASIFICACIÓN SUPERVISADA BASADA  
EN OBJETOS APLICADA A AMBIENTES RURALES A PARTIR DE  
ORTOIMÁGENES DE GEOEYE-1.***

**ALUMNO:**

**RUBÉN VICENTE FERRÓN**

**DIRECTORES:**

**D. MANUEL ÁNGEL AGUILAR TORRES  
D. FERNANDO JOSÉ AGUILAR TORRES**

**ALMERÍA, DICIEMBRE DE 2011**

## INDICE:

<b>0.- RESUMEN</b> .....	<b>8-9</b>
<b>1.- INTRODUCCIÓN</b> .....	<b>10-22</b>
1.1.- FUENTES DE INFORMACIÓN GEOREFERENCIADA.....	13-18
1.1.1 Imágenes de satélite.....	13-15
1.1.2 Modelos Digitales de Elevaciones.....	15-18
1.1.3 Clasificación de imágenes digitales.....	18
1.2.- EXTRACCIÓN DE INFORMACIÓN A PARTIR DE LOS DATOS.....	18-22
1.2.1. Técnicas de clasificación.....	18-19
1.2.2. Proceso de segmentación en la clasificación.....	19-21
1.2.3. Proceso de clasificación supervisada usando Nearest Neighbor.....	21-22
<b>2.- INTERÉS Y OBJETIVOS</b> .....	<b>23-24</b>
2.1.- INTERÉS.....	24
2.2.- OBJETIVOS.....	24
<b>3.- MATERIALES Y MÉTODOS</b> .....	<b>25-48</b>
3.1.- DESCRIPCIÓN DE LA ZONA DE TRABAJO.....	26-27
3.2.- MATERIALES EMPLEADOS.....	27-30
3.2.1. Modelo Digital de Elevaciones. ....	27-28
3.2.2. Imagen pancromática y multiespectral (RGB y Nir) del satélite GeoEye-1.....	28-30
3.2.3. Generación de ortoimágenes de GeoEye-1.....	30
3.3.- METODOLOGÍA.....	31-48
3.3.1.- SEGMENTACIÓN CON ECOGNITION® .....	31-34
3.3.2.- CLASIFICACIÓN MANUAL.....	34-44
3.3.2.1. Estimación de la precisión en la clasificación.....	43-44
3.3.3. – CARACTERÍSTICAS O <i>FEATURES</i> EMPLEADAS. ....	45-46

3.3.4. ANÁLISIS ESTADÍSTICO.....	47-48
<b>4.- RESULTADOS Y DISCUSIÓN.....</b>	<b>49-66</b>
4.1.- PRECISIÓN GLOBAL ( <i>OVERALL ACCURACY</i> ).....	50-51
4.2.- CLASE EDIFICIOS.....	51-53
4.3.- CLASE VEGETACIÓN.....	54-55
4.4.- CLASE SOMBRAS.....	55-57
4.5.- CLASE CALLES.....	58-59
4.6.- CLASE CARRETERAS.....	59-60
4.7.- CLASE SUELO DESNUDO.....	60-63
4.8.-OVERALL ACCURACY EN EL BOSQUE.....	64-65
4.9.-CLASES EN EL BOSQUE.....	65-66
<b>5.- CONCLUSIONES GENERALES.....</b>	<b>67-68</b>
<b>6.- FUTUROS TRABAJOS.....</b>	<b>69-70</b>
<b>7.-REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>71-76</b>

## ÍNDICE DE FIGURAS

Figura 1. Comparación entre las longitudes de onda de las bandas almacenadas por los satélites QuickBird y WorldView-2, tanto en pancromático como en multiespectral.....	15
Figura 2. Representación del terreno mediante Modelos Digitales de Elevaciones (MDEs).....	16
Figura 3. Representación de un Modelo Digital del Terreno y un Modelo Digital de Superficies. La diferencia entre los dos nos permitiría obtener un Modelo Digital de alturas de Objetos (MDO).....	17
Figura 4. Dispositivos característicos de un vuelo LiDAR.....	17
Figura 5. Función de pertenencia creada por el clasificador de Nearest Neighbor.....	22
Figura 6. 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.....	22
Figura 7. Localización de la zona de estudio.....	26
Figura 8. Emplazamiento del estudio.....	27
Figura 9. Imágenes MDS, MDE, MDO dentro de la zona del núcleo de Villaricos.....	28
Figura 10. Imágenes MDS, MDE, MDO dentro de la zona agrícola El Bosque.....	28
Figura 11. Satélite GeoEye-1.....	28
Figura 12. Recorte final de imagen GeoEye-1 adquirido de una imagen de archivo.....	30
Figura 13. Ejemplos de segmentación jerarquizada. a) escala 70 y b) escala 20, ambas en el núcleo de Villaricos. c) escala 100 y d) escala 20, en el caso de El Boque.....	31
Figura 14. Segmentación jerarquizada a escalas 20 y finalmente 70. Generados 2723 objetos en Villaricos.....	32
Figura 15. Segmentación jerarquizada a escalas 20 y finalmente 100. Generados 696 objetos en El Bosque.....	32
Figura 16. Importación de datos.....	33
Figura 17. Asignación de valores sin datos.....	34
Figura 18. A la izquierda, los objetos seleccionados para estudiar la precisión obtenida. A la derecha los objetos seleccionados para el entrenamiento del clasificador.....	36
Figura 19. En la imagen se muestra una zona indeterminada que abarca coches, carreteras y edificios.....	36

Figura 20. Leyenda de las clases y sub-clases utilizadas en la clasificación.....	39
Figura 21. Áreas empleadas para el entrenamiento del clasificador Nearest Neighbor ( <i>samples</i> ). En este caso se empleó un 10% de objetos para <i>samples</i> en el Núcleo de Villaricos.....	39
Figura 22. Clasificación obtenida al utilizar MDO+SAVI y habiendo empleado un 10% de <i>samples</i> para el entrenamiento del clasificador Nearest Neighbor en el Núcleo de Villaricos....	40
Figura 23. Leyenda de las clases y sub-clases utilizadas en la clasificación en El Bosque.....	41
Figura 24. <i>Samples</i> empleadas para entrenamiento clasificador Nearest Neighbor en El Bosque .....	42
Figura 25. Clasificación obtenida al utilizar MDO+SAVI en El Bosque.....	42
Figura 26. Resultado de la matriz de confusión utilizando MDO+SAVI como características y la repetición 4 (10%) para el entrenamiento del clasificador.....	44
Figura 27. Disposición de los factores a analizar mediante el método de la separación de medias.....	47
Figura 28. Resultado de la clasificación donde los objetos de color rojos representan los edificios con un acierto cercano al 95% en Villaricos.....	53
Figura 29. Representación grafica de las clases edificios, sombras y vegetación ( <i>Producer accuracy</i> ) para cada conjunto de capas características en Villaricos.....	57
Figura 30. Representación grafica de las clases edificios, sombras y vegetación ( <i>User accuracy</i> ) para cada conjunto de capas características en Villaricos.....	57
Figura 31. Representación grafica de las clases calles, carreteras, suelo desnudo ( <i>Producer accuracy</i> ) para cada conjunto de capas características en Villaricos.....	62
Figura 32. Representación grafica de las clases calles, carreteras, suelo desnudo ( <i>User accuracy</i> ) para cada conjunto de capas características en Villaricos.....	63
Figura 33. Clasificación obtenida con un conjunto de características formadas por MDO+SAVI obteniendo una clasificación aproximada al 88% en El Bosque.....	64

## ÍNDICE DE TABLAS

Tabla 1. Satélites de muy alta resolución existentes en la actualidad y lanzamientos previstos en los próximos años.....	14
Tabla 2. Tabla de características del satélite GeoEye-1.....	29
Tabla 3. Características de la imagen PAN y MS de GeoEye-1 adquirida para el trabajo.....	29
Tabla 4. Disposición de los objetos después del proceso de segmentación en Villaricos.....	35
Tabla 5. Características de los cuatro conjuntos de muestras de objetos extraídas para entrenamiento del clasificador en El Bosque.....	37
Tabla 6. Disposición de los objetos después del proceso de segmentación en El Bosque.....	41
Tabla 7. Forma del archivo .CSV en Villaricos.....	44
Tabla 8. Características de los objetos usadas en este análisis.....	46
Tabla 9. ANOVA para los resultados de <i>overall accuracy</i> .....	50
Tabla 10. Separación de medias de la variable <i>samples</i> para la <i>overall accuracy</i> a un nivel de confianza del 95%.....	50
Tabla 11. Separación de medias de la variable <i>features</i> para la <i>overall accuracy</i> a un nivel de confianza del 95%.....	51
Tabla 12. ANOVA para la clase “edificios” ( <i>User accuracy</i> ).....	52
Tabla 13. Separación de medias de la variable <i>samples</i> para la clase “edificios” a un nivel de confianza del 95%. .....	52
Tabla 14. Separación de medias en la variable <i>features</i> para la clase “edificios” a un nivel de confianza del 95%. .....	52
Tabla 15. ANOVA para la clase “vegetación” ( <i>producer accuracy</i> ).....	54
Tabla 16. Separación de medias de la variable <i>samples</i> para la clase “vegetación” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%. .....	54
Tabla 17. Separación de medias de la variable <i>features</i> para la clase “vegetación” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%.....	55
Tabla 18. ANOVA para la clase “sombras” ( <i>Producer accuracy</i> ).....	55
Tabla 19. Separación de medias de la variable <i>samples</i> para la clase “sombras” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%.....	56
Tabla 20. Separación de medias en la variable <i>features</i> para la clase “sombras” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%.....	56

Tabla 21. ANOVA para la clase “calles” ( <i>Producer accuracy</i> ).....	58
Tabla 22. Separación de medias de la variable <i>samples</i> para la clase “calles” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%. .....	58
Tabla 23. Separación de medias de la variable <i>features</i> para la clase “calles” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%. .....	59
Tabla 24. ANOVA para la clase “carreteras” ( <i>Producer accuracy</i> ).....	59
Tabla 25. Separación de medias de la variable <i>samples</i> para la clase “carreteras” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%.....	60
Tabla 26. Separación de medias de la variable <i>features</i> para la clase “carreteras” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%.....	60
Tabla 27. ANOVA para la clase “suelo desnudo” ( <i>Producer accuracy</i> ).....	61
Tabla 28. Separación de medias en la variable <i>samples</i> para la clase” suelo desnudo” ( <i>Producer accuracy</i> ) un nivel de confianza del 95%.....	61
Tabla 29. Separación de medias en la variable <i>features</i> para la clase” suelo desnudo” ( <i>Producer accuracy</i> ) a un nivel de confianza del 95%.....	62
Tabla 30. Precisión global (Overall Accuracy) utilizando un 10% de muestras para cada conjunto de características en El Bosque.....	65
Tabla 31. <i>Producer Accuracy</i> de las clases para cada una de los conjuntos de <i>features</i> en El Bosque.....	65
Tabla 32. <i>User Accuracy</i> de las clases para cada uno de los conjuntos de <i>features</i> en El Bosque.....	66

# CAPÍTULO 0

## RESUMEN



## **0.- RESUMEN**

La última generación de satélites comerciales de muy alta resolución (*very high resolution*; VHR) abre nuevas posibilidades para las aplicaciones cartográficas y de detección remota. De hecho, una de las aplicaciones más comunes de las imágenes de sensores remotos es la extracción de información de la Superficie-Uso del suelo mediante técnicas de clasificación. Cuando se usan imágenes de satélite de muy alta resolución (VHR), utilizar una clasificación basada en objetos puede mejorar la precisión en la clasificación en comparación con una clasificación basada en píxeles.

El objetivo de este proyecto es realizar una evaluación de la precisión obtenida en el proceso de clasificación supervisada basada en objetos, tanto en entornos urbanos como rurales, a partir de ortoimágenes fusionadas (*pansharpened*), y pancromáticas del satélite GeoEye-1. La influencia de los distintos conjuntos de características o *features* de objetos sobre la precisión obtenida finalmente en la clasificación es también estudiada.

Para la fase de clasificación basada en objetos se usará el software comercial eCognition v. 8., mientras que el clasificador con el que hemos realizado el monográfico ha sido el Nearest Neighbor. En la zona urbana (núcleo urbano de Villaricos, Almería) se ensayaron 7 conjuntos de características de objetos, incluyendo *features* relativas a textura, geometría y valores de características de las principales capas de información. Para la zona agrícola situada en el paraje El Bosque, Palomares (Almería), 4 conjuntos de características fueron estudiados en la zona agrícola.

Estos objetos fueron segmentados con eCognition® utilizando la segmentación multirresolución, que es una técnica de fusión-región de abajo hacia arriba a partir de objetos formados por píxeles. Se obtuvieron 2723 objetos, de los que se pudieron clasificar de manera manual 1894. Aproximadamente la mitad de estos últimos objetos (945) se extrajeron para, de entre ellos, seleccionar los distintos sets de muestras de entrenamiento del clasificador. Se ensayaron cuatro porcentajes de muestras de entrenamiento (5%, 10%, 15% y 20%) con cuatro repeticiones cada uno, por lo que 16 sets de muestras de entrenamiento fueron seleccionados. La otra mitad de los objetos clasificados manualmente (949) fueron usados para validar la precisión obtenida en clasificación.

Finalmente se llevo a cabo un test estadístico (ANOVA) sacando las siguientes conclusiones: Se obtuvo una precisión global del 79.4 % en zonas urbanas y del 88 % en zonas agrícolas ambas utilizando las capas compuestas por la banda pancromática, las bandas roja, azul, verde e infrarroja de la ortoimagen *pansharpened*, el brillo calculado para el rojo, azul, verde e infrarrojo, la diferencia máxima, media del índice de vegetación ajustada al suelo (SAVI) y el modelo digital de objetos (MDO). Para la clasificación de los edificios e invernaderos, la variable MDO mostró ser la capa de características más influyente, produciendo precisiones superiores al 95% en ambos casos.

# **CAPÍTULO 1**

## **INTRODUCCIÓN**

## **1.- INTRODUCCIÓN**

Una de las aplicaciones más comunes de imágenes procedentes de sensores remotos es la extracción de información de la superficie-uso del suelo. Esta información será útil para que los gobiernos municipales puedan optimizar la planificación y gestión del territorio, tanto en ambientes urbanos como rurales y/o agrícolas. Un ejemplo podría ser el cambio del uso del suelo o la planificación de migración de las aguas pluviales) (Shackelford y Davis, 2003). Durante la última década, la teledetección por satélite ha avanzado a pasos agigantados, aumentando la resolución espacial de sus productos de manera muy importante, hasta llegar a 0.5 m de resolución en imágenes de GeoEye-1 o WorldView-2.

Se ha demostrado que las imágenes de satélites comerciales de muy alta resolución espacial (e.g., Ikonos, QuickBird, GeoEye-1, WorldView-1 o WorldView-2) son una alternativa rentable a la fotografía aérea para la generación de ortofotomapas digitales (Davis y Wang, 2003). En este sentido, con la llegada en la última década de los satélites con sensores de alta resolución espacial, se plantean nuevos retos para la clasificación automática de la superficie-uso del suelo en áreas de ambiente rural.

La tradicional clasificación basada en píxeles ha quedado muy limitada a la clasificación de las imágenes obtenidas con satélites con un tamaño de píxel o GSD (*Ground Sample Distance*) grande como LandSat. La información superficie-uso del suelo extraída mediante la clasificación multispectral basada en píxeles muestra tener más complejidad, debido al aumento de la variación interna en la unidad de la cubierta vegetal (Carleer y Wolff, 2006; Kux y Pinho, 2006). Con el aumento de resolución espacial de los nuevos satélites, las clases de superficie-uso del suelo tienden a ser representadas por unidades espaciales de características heterogéneas de espectro reflectante, y su separabilidad estadística se reduce cuando se utilizan criterios tradicionales de clasificación basados en píxeles. En consecuencia, la precisión de clasificación se reduce y por lo general los resultados muestran un efecto de sal y pimienta, debido a la existencia de píxeles individuales clasificados de forma diferente a sus vecinos. Estudios previos han demostrado que la precisión de la clasificación superficie-uso del suelo puede disminuir cuando aumenta la resolución espacial de la imagen (Townshend y Justicia, 1981; Latty *et al.*, 1985; Martin *et al.*, 1988; Gong y Howarth, 1990; Treitz y Howarth, 2000).

La exactitud de la clasificación es particularmente problemática en los entornos urbanos que normalmente consisten en mosaicos de pequeñas objetos compuestos de materiales con diferentes propiedades físicas (Mathieu *et al.*, 2007). Para superar este problema se puede utilizar clasificación basada en objetos de interés (IO, *Interest Object*). Para ello es necesario una segmentación previa de la imagen que nos proporcione regiones que aglutinan píxeles con características homogéneas (Carleer y Wolff, 2006). Por tanto, en la clasificación por objetos se utiliza una región o IO en lugar de un píxel como unidad para la clasificación.

Las razones por las que la estrategia de clasificación basada en IO puede, potencialmente, mejorar la precisión en la clasificación comparadas con la clasificación basada en píxeles puede ser:

- (1) La partición de una imagen en OI es similar al concepto que tienen los humanos de organizar el paisaje para comprenderlo (Hay y Castilla, 2006),
- (2) Además de las características espectrales, nos permiten el uso de las características de textura y de contexto (las relaciones con otros objetos) y dar forma a algunas características geométricas como por ejemplo, forma, tamaño y geomorfología (Hay y Castilla, 2006; Yu *et al.*, 2006).
- (3) Los IO que se extraen de una determinada escena pueden estar asociados a diferentes niveles de abstracción (es decir, a diferentes escalas) y estos niveles se puede representar en un sistema de análisis (Kux y Pinho, 2006). Muchos investigadores anteriores han demostrado las ventajas de la clasificación basada en objetos (Ton *et al.*, 1991; Johnsson, 1994; Hill, 1999; Herold *et al.*, 2003; Carleer y Wolff, 2006; Kong *et al.*, 2006; Kux y Pinho, 2006; Marchesi *et al.*, 2006; Yu *et al.*, 2006; Mathieu *et al.*, 2007).

Los cambios en el territorio afectan sobremanera a zonas del litoral. Concretamente, el litoral andaluz ha experimentando un espectacular y explosivo proceso de transformación en las últimas décadas (Requejo, 2001), donde los procesos de urbanización tienen una alta cuota de responsabilidad (Ojeda y Villar, 2006). Los conceptos de crecimiento e intensificación aluden al proceso de urbanización, es decir, a la evolución que registra el suelo rústico al transformarse en suelo urbano (Zoido *et al.*, 2000). En este sentido, el Informe anual de 2004 de la Consejería de Medio Ambiente de la Junta de Andalucía (Consejería de Medio Ambiente, 2005) ya recoge, en el capítulo sobre el litoral, algunos indicadores sobre el crecimiento urbano total de 2002 respecto a 1998. En la actualidad, la longitud de costa urbanizada en Almería es de 75 km, cuando en 1957 apenas superaba los 11 km, es decir un 33% de su longitud total y un 52% de la ocupada por playas (Viciano, 2007). Como resultado de ello se ha consolidado un continuo urbano congestionado y de alta densificación, como son los casos de Roquetas de Mar, 71% de su costa construida; Vera, 100%; Mojácar, 56%.

La preocupación de la Comunidad Autónoma Andaluza por el problema del futuro de nuestras costas queda recogida en el Plan Andaluz de Medio Ambiente 2004-2010, donde se dedica un área estratégica de actuación (Área 6 concretamente) a la Gestión Ambiental Integrada del Litoral. Por otra parte, el Plan Cartográfico de Andalucía 2008-2011 establece unas líneas prioritarias en el ámbito de la captura y compilación de datos georreferenciados, entre las que se encuentra la expansión de la Altimetría Láser Aerotransportada, la mejora de las técnicas de análisis y extracción automatizadas a partir de imágenes digitales, la integración de datos multifuente, mejora de las capacidades de la fotogrametría digital, etc.

Por tanto la dedicación de esfuerzos encaminados a la clasificación automática y supervisada basada en objetos de usos del suelo a partir de imágenes de satélites de muy alta resolución en zonas muy cambiantes, está más que justificada.

## **1.1.- FUENTES DE INFORMACIÓN GEOREFERENCIADA.**

### **1.1.1 Imágenes de satélite**

La aplicación de la fotogrametría digital a las imágenes de satélite en la década de los 90 supuso una verdadera revolución en la generación de información espacial, tanto topográfica como temática, para su integración en Sistemas de Información Geográfica (SIG). Sin embargo, no fue hasta 1999 cuando aparecieron los satélites comerciales de muy alta resolución (*very high resolution*, VHR). Actualmente existen orbitando sobre la tierra y recogiendo imágenes de su superficie nueve satélites comerciales VHR. Estos satélites se caracterizan por tener una gran resolución tanto geométrica, con un tamaño de píxel en la banda pancromática de 1 m e incluso inferior, como radiométrica (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.

Ikonos, perteneciente en un principio a la compañía Space Image (USA), fue el primero de este nuevo tipo de satélites comerciales VHR. Fue lanzado en 1999 y capta imágenes terrestres tanto pancromáticas, con 0.82 m (remuestreadas a 1 m) de tamaño de píxel, como multispectrales, con un tamaño de píxel de 3.28 m (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 de 0.61 m y 2.44 m en pancromático y multispectral (R, G, B e NIR) respectivamente, lo que le otorgó en su momento el honor de ser el satélite comercial que presentaba la mayor resolución espacial.

Desde el lanzamiento de los satélites 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, 2002; Kay *et al.*, 2003; Chmiel *et al.*, 2004; Pecci *et al.*, 2004; Aguilar *et al.*, 2007a; Aguilar *et al.*, 2006b). De hecho, Ikonos y QuickBird ofrecen la posibilidad de generación rápida y precisa de ortoimágenes, capaces de competir con las generadas a partir de vuelos aéreos convencionales, como por ejemplo, la ortofoto en blanco y negro de la Junta de Andalucía de 2002 (Aguilar *et al.*, 2008a). Hay que tener en cuenta que la Consejería de Vivienda y Ordenación del Territorio de la Junta de Andalucía y el Centro Nacional de Información Geográfica (CNIG) están colaborando en la generación de nuevas ortoimágenes de la Comunidad Andaluza en el marco del Plan Nacional de Ortofotografía Aérea (PNOA). Estas ortofotografías aéreas, que se elaboran de forma sistemática en toda España, y también en Andalucía desde 1999, son imágenes aéreas corregidas con una precisión que oscila entre 1 metro y los 50 centímetros.

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

Satélite	País	Lanzamiento	Res. PAN (m)	Res. MS (m)	Tamaño Escena (km)
<i>IKONOS-2</i>	<i>US</i>	<b>09/24/99</b>	<b>1.0</b>	<b>4</b>	<b>11</b>
<i>QuickBird-2</i>	<i>US</i>	<b>10/18/01</b>	<b>0.61</b>	<b>2.44</b>	<b>16</b>
<i>EROS B1</i>	<i>Israel</i>	<b>04/25/06</b>	<b>0.7</b>		<b>7</b>
<i>Resurs DK-1</i>	<i>Rusia</i>	<b>06/15/06</b>	<b>1.0</b>	<b>3</b>	<b>28</b>
<i>KOMPSAT-2</i>	<i>Corea</i>	<b>07/28/06</b>	<b>1.0</b>	<b>4</b>	<b>15</b>
<i>IRS Cartosat 2</i>	<i>India</i>	<b>01/10/07</b>	<b>0.8</b>		<b>10</b>
<i>WorldView -1</i>	<i>US</i>	<b>09/18/07</b>	<b>0.5</b>		<b>16</b>
<i>GeoEye-1</i>	<i>US</i>	<b>06/09/08</b>	<b>0.41*</b>	<b>1.65*</b>	<b>15</b>
<i>WorldView -2</i>	<i>US</i>	<b>08/10/09</b>	<b>0.46*</b>	<b>1.84*</b>	<b>16</b>
<i>EROS C</i>	<i>Israel</i>	Previsto en 2010	0.7	2.8	11
<i>Pleiades-1</i>	<i>France</i>	Previsto en 2010	0.7	2.8	20
<i>Pleiades-2</i>	France	Previsto en 2011	0.7	2.8	20
<i>KOMSAT-3</i>	Corea	Previsto en 2012	0.7	3.2	?

\*La distribución y uso de imágenes con una resolución mejor de 0.5 m en pancromático y de 2.0 m en multiespectral estará sujeta a la aprobación por el Gobierno de los Estados Unidos.

Además, este tipo de imágenes de satélite han sido utilizadas para numerosas aplicaciones en: (i) la detección de edificios (Fraser *et al.*, 2002a; Weber y Ranchin, 2003; Lee *et al.*, 2003; Mesev, 2005; Kim *et al.*, 2006; Mayunga *et al.*, 2007; Gamba *et al.*, 2007), (ii) carreteras (Yan y Zhao, 2003; Jin y Davis, 2005), (iii) vegetación (Nichol y Lee, 2005; Castillejo-González *et al.*, 2009; Martínez-Casasnovas *et al.*, 2009), (iv) detección de invernaderos (Agüera *et al.*, 2006; Agüera *et al.*, 2008), e incluso (v) localización de daños ocasionados por desastres naturales (Al-Khudhairy *et al.*, 2005).

Más recientemente y financiado al 50% por la empresa GeoEye y el Departamento de Defensa de los Estados Unidos, en el año 2008 fue lanzado el satélite GeoEye-1 (GeoEye, Inc.), que actualmente es el satélite comercial con mayor resolución geométrica, tanto en pancromático como en multiespectral. GeoEye-1 ofrece la posibilidad de tomar imágenes con un tamaño de píxel de 0.41 m en pancromático y 1.65 m en multiespectral, estando compuesta esta última imagen por 4 bandas (R, G, B e NIR). Los primeros resultados 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 octubre de 2009 hay que remarcar otro hito en la corta historia de los satélites VHR, el lanzamiento del satélite WorldView-2 de DigitalGlobe. Este nuevo satélite presenta una gran resolución geométrica en pancromático (0.46 m) y multispectral (1.84 m), aunque ligeramente inferior a la obtenida por GeoEye-1. Su principal novedad es que tiene la capacidad de almacenar 8 bandas en la imagen multispectral (Fig. 1): Coastal Blue (400-450 nm), Blue (450-510 nm), Green (510-580 nm), Yellow (585-625 nm), Red (630-690 nm), Red-Edge (705-745 nm), NIR1 (770-895 nm) y NIR2 (860-1040 nm). Su alta resolución espacial permite la detección de detalles pequeños, y su alta resolución espectral lo capacita para obtener información detallada sobre la calidad de superficies asfaltadas, profundidad del mar, o incluso sobre el estado de salud de un cultivo. Las imágenes de este nuevo satélite *VHR* se han empezado a comercializar a partir del 4 de enero de 2010, por lo que aún no hay bibliografía sobre aplicaciones reales de imágenes de este satélite. Sin embargo, según un estudio piloto realizado por DigitalGlobe (2009), se pueden obtener mejoras sustanciales en la precisión de la clasificación usando las 8 bandas de WorldView, frente a las imágenes multispectrales tradicionales RGB-NIR de QuickBird, Ikonos o GeoEye-1. Estas mejoras se cuantifican en una mejora global de entre un 10 y un 30% en la clasificación de carreteras, vegetación o elementos acuáticos (arrecifes, barreras de arena).




Figura 1. Comparación entre las longitudes de onda de las bandas almacenadas por los satélites QuickBird y WorldView-2, tanto en pancromático como en multispectral.

Los satélites VHR también ofrecen la posibilidad de generación de Modelos Digitales de Elevaciones (MDEs) a partir de estéreo-pares de imágenes, pudiéndose obtener errores medios cuadráticos 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, la calidad de puntos de control (Ridley *et al.*, 1997; Toutin 2004a; Toutin 2006; Aguilar *et al.*, 2007b). Estos errores han sido mucho menores, en torno a 0.5 veces el tamaño de píxel, cuando el MDE fue generado a partir de un estéreo-par de GeoEye-1 (Fraser y Ravanbakhsh, 2009).

### **1.1.2 Modelos Digitales de Elevaciones**

Otra fuente de información de alto valor para la extracción de elementos en una determinada zona son los MDEs y Modelos Digitales de Superficies (MDSs) obtenidos

a partir de escáneres láser aerotransportados (ALS- LiDAR; *Airborne Laser Scanner - Light Detection and Ranging*). Un MDE no es otra cosa que una representación digital del terreno que sustituye, en cierto modo, a los planos analógicos basados en curvas de nivel (Fig. 2).

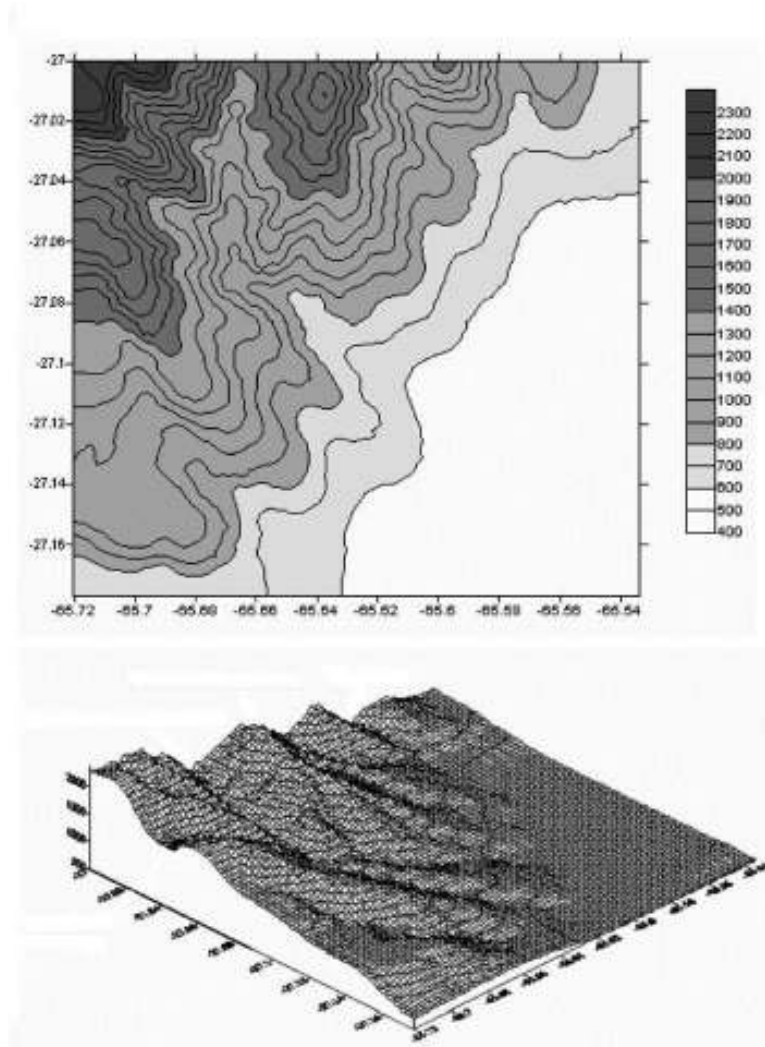


Figura 2. Representación del terreno mediante Modelos Digitales de Elevaciones (MDEs).

En la Figura 3 puede observarse la diferencia entre un MDE del terreno y un MDS. En este último se tiene en cuenta el denominado microrelieve (vegetación, edificios, etc.) que se asienta sobre el terreno desnudo. De esta forma, la diferencia entre un MDS y el MDE del suelo desnudo correspondiente nos proporcionaría lo que se denomina un Modelo Digital de alturas de Objetos (MDO).

Un sistema LiDAR es un sensor activo aerotransportado que emite pulsos de luz infrarroja con una frecuencia muy elevada (en algunos modelos más de 150 kHz). Mediante unos relojes de elevada precisión, se determina el tiempo que tarda cada pulso en volver al emisor y por tanto la distancia al objeto reflector.






Figura 3. Representación de un Modelo Digital del Terreno y un Modelo Digital de Superficies. La diferencia entre los dos nos permitiría obtener un Modelo Digital de alturas de Objetos (MDO).




Figura 4. Dispositivos característicos de un vuelo LiDAR.

Los parámetros de orientación externa del sensor en cada momento se obtienen mediante el postproceso de los datos aportados por dos subsistemas complementarios representados en la Figura 4: (i) GPS diferencial cinemático de precisión en torno a 10 cm., que consta de un GPS montado en el avión y una o varias estaciones de referencia en tierra para transmitir correcciones diferenciales (posición  $X, Y, Z$  del sensor respecto al sistema de referencia WGS 84), y (ii) Sistema IMU (*Inertial Measurement Unit*) para la obtención de los ángulos de orientación  $\omega, \varphi, \kappa$ .

La integración de ambos conjuntos de datos, junto con el ángulo de salida y la distancia recorrida por cada pulso láser, permiten reconstruir la línea imaginaria que ha descrito cada rayo en el espacio. De esta forma podemos obtener una nube muy densa de puntos georreferenciados que, dependiendo de la altura de vuelo, la velocidad del avión, el

ángulo de escaneo del sensor y la frecuencia de repetición de los pulsos, pueden estar separados por distancias entre 0.25 m y 2 m. Es decir, se pueden obtener MDEs con una elevadísima resolución espacial (hasta 10 puntos/m<sup>2</sup>) y en un corto periodo de tiempo.

En general, los MDE conforman una información que puede resultar básica para la clasificación de imágenes basada en objetos. Esta información puede ser crucial debido a que muchas características de la clasificación pueden estar relacionadas con la altura relativa, como por ejemplo los edificios, árboles, invernaderos. Incluso, si la información es suficientemente densa, podrían usarse valores derivados, como la desviación estándar de alturas que sería indicativo de la variabilidad para separar, por ejemplo, objetos planos de rugosos. De esta forma, los modelos digitales de alturas conforman una información que complementa a la información radiométrica que puede ser insuficiente cuando el número de bandas es bajo, pudiendo resultar información básica o necesaria para según qué clases se pretendan separar.

### **1.1.3 Clasificación de imágenes digitales**

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. 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. Se imponen por tanto 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 de forma supervisada usos de suelo en zonas rurales a partir de ortoimágenes de GeoEye-1 usando información radiométrica contenida en la propia imagen de satélite, como información altimétrica, procedente de tecnología LiDAR.

## **1.2.- EXTRACCIÓN DE INFORMACIÓN A PARTIR DE LOS DATOS**

### **1.2.1. Técnicas de clasificación.**

La mayoría de las técnicas usadas para la extracción de información son clasificaciones basadas en parámetros estadísticos deducidos de zonas de la imagen estudiada. La clasificación puede ser supervisada, no supervisada, o mixta. Pudiéndose utilizar estos tres tipos de clasificaciones tanto para clasificación por píxeles como para clasificación por objetos.

En la clasificación supervisada, el analista define en la escena una serie de parcelas, llamadas áreas de entrenamiento, de las cuales conoce su pertenencia a cada una de las clases establecidas en la leyenda. A partir de los parámetros estadísticos que definen la población de muestras de cada clase, los píxeles de toda la escena son incluidos en una clase u otra. Por lo tanto, la selección de estos campos de entrenamiento es una tarea delicada pues de esto dependerá el resultado de la clasificación.

En la clasificación no supervisada, el analista busca la agrupación automática de los datos de la imagen en una serie de grupos homogéneos que respondan a similitudes espectrales de las cubiertas. Es decir, sin aplicar ningún entrenamiento previo, los píxeles de la imagen son agrupados entre sí según sus similitudes. El proceso final, por tanto, será el de reconocer cada clase creada por el sistema como una clase real en el terreno. Este tipo de clasificación tiene la ventaja de que la participación del usuario es mínima, por lo que los errores de identificación de las muestras serán evitados.

La clasificación mixta, es la combinación de ambas clasificaciones. Existen dos formas distintas de combinar ambos métodos. En el primer caso puede realizarse un entrenamiento no supervisado para obtener una clasificación inicial propuesta por el sistema que será evaluada por el analista. Se agruparan clusters de igual significación temática, y se separarán en nuevos agrupamientos los que mezclen dos clases informacionales, siendo por tanto este último paso supervisado. Otra forma distinta es sintetizar los resultados obtenidos de cada uno de ellos por separado. Existirán categorías que aparezcan como clase de ambos lo que demostrará que la clase propuesta por el operador tiene un significado espectral y otras categorías señaladas como clases que no encontraran afinidad por lo que su tratamiento habrá de particularizarse en el ámbito del proyecto (Pinilla, 1995).

En este trabajo usaremos una clasificación supervisada basada en objetos. Por tanto, el primer paso es realizar la segmentación de la imagen, obteniendo así los IO de partida que tendremos que clasificar automáticamente.

### **1.2.2 Proceso de segmentación en la clasificación.**

La segmentación subdivide una imagen en IO homogéneos. La segmentación es una de las tareas más difíciles de la clasificación basada en objetos y puede determinar el éxito o fracaso del análisis final.

Existen varias técnicas para la segmentación (González y Woods, 1992). Entre ellas podemos citar (i) la detección de discontinuidades, (ii) enlazado de bordes y detección de límites, (iii) umbralización, y (iv) segmentación orientada a regiones.

Los algoritmos de segmentación se utilizan para subdividir imágenes completas para obtener objetos directamente a partir de la información contenida en los píxeles individualmente (a nivel de píxel), o bien los objetos pueden ser obtenidos mediante la información contenida en otra segmentación realizada previamente mediante la agregación-desagregación de objetos (a nivel de objetos) lo que permite crear una red de objetos y subobjetos superponibles entre sí, y que guardan una jerarquía espacial (súper-objetos, sub-objetos).

El software utilizado en este trabajo para realizar la segmentación y clasificación ha sido eCognition<sup>®</sup> v.8. Este software ofrece varios enfoques diferentes para la segmentación, que van desde algoritmos muy simples, tales como tablero de ajedrez (*chessboard*) o la segmentación de *quadtree*, a otros basados en métodos altamente

sofisticados tales como la segmentación multirresolución y la segmentación del filtro de contraste. En este trabajo hemos trabajado la segmentación multirresolución.

#### *1.2.2.1. La segmentación multirresolución.*

El algoritmo de segmentación multirresolución local minimiza la heterogeneidad media de los objetos de la imagen para una resolución o escala dada. Se puede ejecutar en un nivel de IO creado previamente, o a nivel de píxel. La segmentación multirresolución es un procedimiento de optimización que, para un número determinado de objetos de imagen, minimiza la heterogeneidad media y maximiza su homogeneidad respectiva.

El procedimiento de segmentación se inicia considerando cada píxel como un objeto inicial uniéndose iterativamente los píxeles dos a dos, siempre que no se supere un umbral de homogeneidad de forma local. Este criterio de homogeneidad se define como una combinación de los parámetros homogeneidad espectral y forma, que pueden influir en este cálculo mediante la modificación del parámetro de escala. Los valores más altos para el parámetro de escala causan objetos de imagen más grandes, mientras que valores más pequeños para el parámetro de escala provocan objetos más pequeños.

Para realizar la segmentación multirresolución con eCognition<sup>®</sup> debemos introducir los siguientes parámetros y capas de información:

*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 asignará a la información de los píxeles que la capa durante el proceso de segmentación, en el supuesto de que la segmentación utilizara información de los píxeles. 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 parámetro de escala:* 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 escala posible en los que todavía se distinguían las diferentes regiones de la imagen que deban ser clasificadas.

*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 (color = 1 -

forma). En efecto, al disminuir el valor asignado al campo de forma, se define a qué 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 sólo un contraste espectral relativamente débil.

### **1.2.3 Proceso de clasificación supervisada usando Nearest Neighbor.**

Nearest Neighbor 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 (vecino más cercano) 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:

- (i) Enseñar al sistema dándole objetos certeros como muestras.
- (ii) 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 5 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.

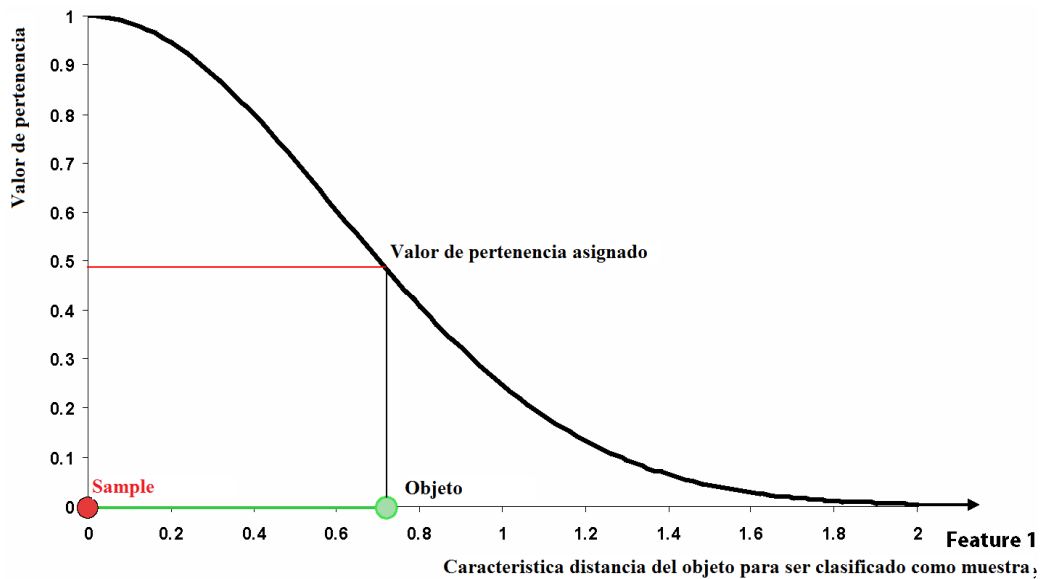


Figura 5. Función de pertenencia creada por el clasificador de Nearest Neighbor

Para que un objeto sea clasificado se utiliza la muestra para evaluar su función 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 *samples* de esa clase. Cuando la función de pertenencia se describe como 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 6:

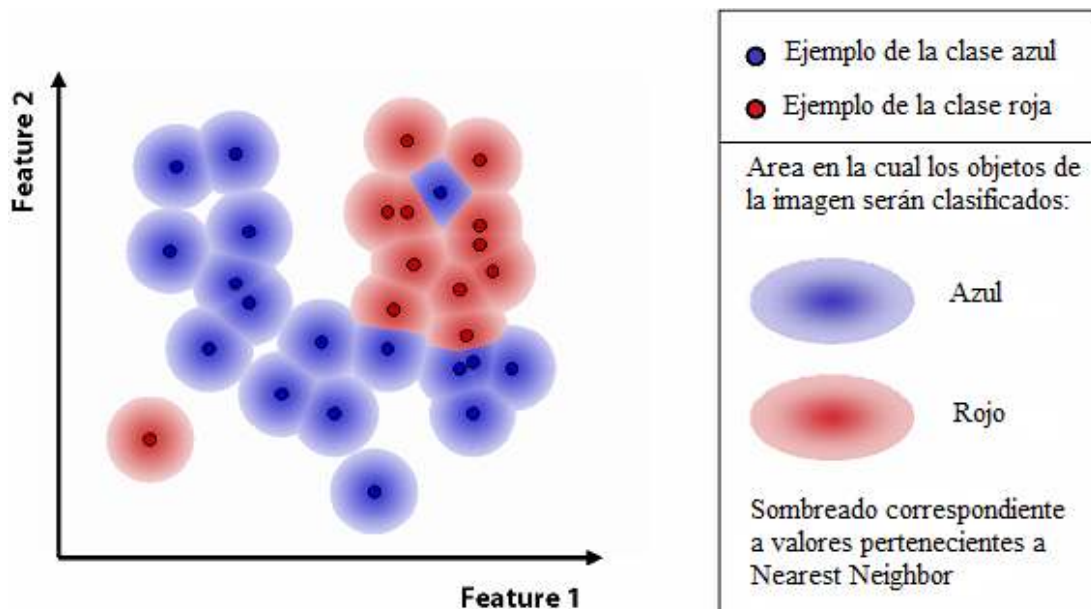


Figura 6. Función de pertenencia muestra las clases asignadas en dos dimensiones. Las muestras se representan con pequeños círculos. Los valores de pertenencia de las correspondientes clases roja y azul están sombreadas del mismo color, por lo que en áreas con objetos clasificados rojos, el valor de pertenencia azul es ignorado y viceversa.

# CAPÍTULO 2

## INTERÉS Y OBJETIVOS

## **2.- INTERÉS Y OBJETIVOS**

### **2.1.- INTERÉS**

Después de todo lo expuesto, 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, ya sean en ambientes urbanos, rurales o agrícolas. Dicha extracción de información o clasificación de usos del suelo, 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 ello 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 (Ruther *et al.*, 2002). Según lo expuesto, se hace necesario desarrollar una metodología que automatice lo máximo posible la extracción de la información espacial a partir de imágenes de satélite de alta resolución, y en nuestro caso concreto, procedentes de GeoEye-1. Es por ello que en este trabajo vamos a estudiar el funcionamiento de técnicas de clasificación supervisada basada en objetos a partir de ortoimágenes de GeoEye-1. Estas técnicas ensayadas y validada, por un lado en una zona urbana correspondiente al casco urbano de Villaricos (Almería), y por otro, en la zona agrícola conocida como El Bosque en el término municipal de Palomares (Almería).

### **2.2.- OBJETIVOS**

El objetivo fundamental del proyecto es estudiar el nivel de precisión y calidad alcanzables, en condiciones operacionales, en la clasificación supervisada de zonas rurales muy cambiantes del levante almeriense, usando un software de clasificación basada en objetos (eCognition<sup>®</sup>) y ortoimágenes pancromática, multiespectral y fusionada, de uno de los satélites comerciales VHR más novedoso e inexplorado; GeoEye-1.

Concretamente se pretende estudiar, como influyen en el resultado de precisión final en la clasificación, factores como:

- (i) El porcentaje de muestras seleccionadas para el entrenamiento del clasificador empleado (Nearest Neighbor en nuestro caso).
- (ii) Las características (*features*) de los objetos seleccionados para la clasificación supervisada que más influyen en la clasificación. En otras palabras, determinar el conjunto de *features* óptimo que van a ser tenidos en cuenta en la clasificación.



# **CAPÍTULO 3**

**MATERIALES**

**Y**

**MÉTODOS**

### **3.- MATERIALES Y MÉTODOS**

#### **3.1.- DESCRIPCION DE LA ZONA DE TRABAJO**

El estudio comparativo se realiza en la zona comprendida entre las poblaciones de Garrucha y Villaricos (pedanía perteneciente al termino municipal de Cuevas del Almanzora), en el levante de la provincia de Almería (Fig. 7) con una superficie total aproximada de 841 ha. La franja costera explorada tiene una profundidad de 700-800 m aproximadamente. La zona incluye la desembocadura de los ríos Almanzora y Antas, entre las que se encuentran urbanizaciones de gran importancia que han experimentado un gran desarrollo durante los últimos años como consecuencia de la expansión inmobiliaria como resultado del desarrollo del sector turístico de la zona.




Figura 7. Localización de la zona de estudio.

Dicho estudio se desarrollo en dos zonas diferenciadas como se muestra en la (Fig. 8). La zona 1 en el núcleo urbano de Villaricos, con una extensión de 16.7 ha, y la zona 2, más agrícola, situada en el término municipal de Palomares, conocida como El Bosque, y con una superficie de 30.9 ha.



Figura 8. Emplazamiento del estudio.

### **3.2.- MATERIALES EMPLEADOS**

#### **3.2.1 Modelo Digital de Elevaciones.**

A partir del vuelo fotogramétrico combinado con sensor LiDAR realizado el 28 de agosto de 2009 en el marco del Proyecto de Excelencia RNM-3575 se obtiene el Modelo Digital de Superficie (MDS) y el Modelo Digital de Elevaciones (MDE). La altura de vuelo fue de 1000 m y el escáner láser aerotransportado fue un Leica ALS60 con 35° de ángulo de visión (FOV). La densidad media de puntos obtenidos fue de 1.61 puntos/m<sup>2</sup> y para obtener una mayor precisión en el cálculo de trayectorias se utilizó una estación GPS de referencia en tierra ubicado sobre el vértice “Alboluncas” de la Red Regente Nacional. La precisión vertical del MDE LiDAR, evaluada a partir de 62 puntos de comprobación medidos sobre el terreno mediante técnicas de GPS diferencial, fue de 0.089 m. Ortoimágenes de 15 cm GSD fueron también generadas a partir de una cámara digital DMC de Intergraph tomadas junto a los datos LiDAR en este vuelo combinado.

Todos los procesos para filtrar la nube de puntos obtenidos en formato ALS se llevaron a cabo a través del software TerraMatch<sup>®</sup> y TerraScan<sup>®</sup> del paquete TerraSolid<sup>®</sup>, generando el MDE referenciado al datum ETRS89, UTM 30N. En las Figuras 9 y 10, las podemos observar la representación del MDS, MDE y MDO (diferencia entre un MDS y el MDE del suelo desnudo) correspondientes a las zonas de Villaricos y El Bosque respectivamente. En la Figura 9, los edificios de Villaricos son resaltados en el MDO, mientras que en la Figura 10, son los invernaderos que existen en la zona los que aparecen en color blanco en el MDO.

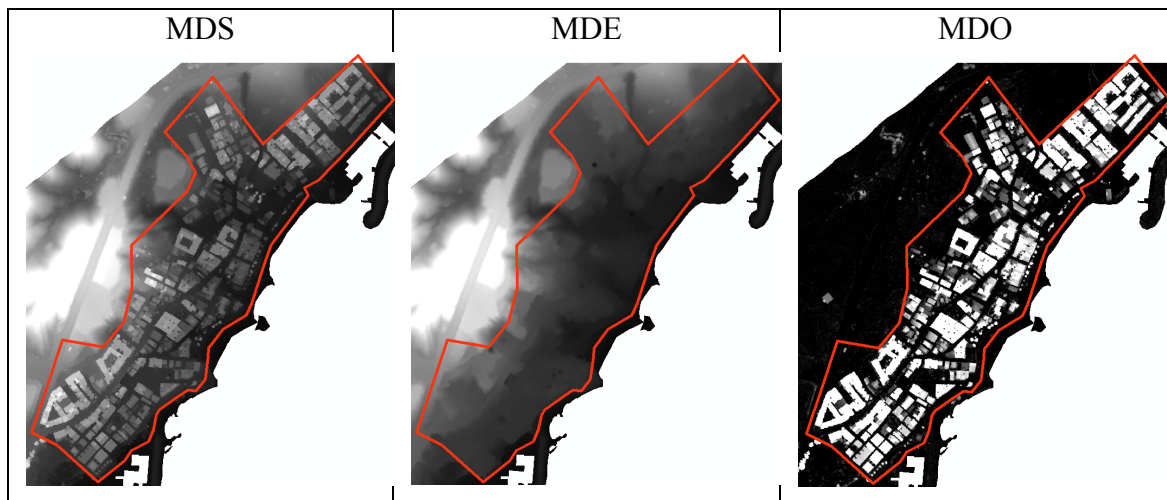


Figura 9. Imágenes MDS, MDE, MDO dentro de la zona del núcleo de Villaricos.




Figura 10. Imágenes MDS, MDE, MDO dentro de la zona agrícola El Bosque.

### **3.2.2 Imagen pancromática y multispectral (RGB y Nir) del satélite GeoEye-1.**

El satélite GeoEye-1 (Fig.11) fue lanzado el 6 de Septiembre de 2008 y está equipado con la tecnología más avanzada en sensores remotos de teledetección para uso comercial.



Figura 11. Satélite GeoEye-1.

Es capaz de capturar imágenes de 0.41m de resolución para imágenes PAN y de 1.65 m de resolución para imágenes MS. Sin embargo, por imposición del Gobierno de los Estados Unidos, estas imágenes deben ser remuestreadas a 0.5 m en las imágenes PAN y a 2 m en las imágenes MS. Las imágenes MS de este satélite tienen cuatro bandas: azul, verde, rojo e infrarrojo cercano, cuya longitud de onda se especifica en la Tabla 2

Tabla 2. Tabla de características del satélite GeoEye-1.

<b>CARACTERÍSTICAS</b>	<b>GeoEye-1</b>
Resolución final (PAN)	50 cm
Resolución real en el nadir (PAN)	41 cm
Resolución 60 ° elevación (PAN)	50 cm
Resolución final (MS)	2 m
Resolución real en el nadir (PAN)	1.65 cm
Banda Azul	450-510 nm
Banda Verde	510-580 nm
Banda Roja	655-690 nm
Infrarrojo Cercano	780-920 nm
Ciclo de vida previsto	7 años
Tiempo de revisita	3 días
Altura orbital	681 km

En Enero de 2011, y en el marco del Proyecto de Investigación del Plan Nacional con referencia CTM2010–16573, se adquirió una imagen de archivo de GeoEye-1 (PAN + MS). La imagen fue capturada el 29 de Septiembre de 2010. La imagen obtenida fue remuestreada a 0.5 m y 2 m en PAN y MS respectivamente y ocupa aproximadamente 49 km<sup>2</sup>, incluyendo la totalidad de la zona de estudio (Fig. 12). En la Tabla 3 podemos observar las características de la imagen que hemos usado en este trabajo.

Tabla 3. Características de la imagen PAN y MS de GeoEye-1 adquirida para el trabajo.

Producto:	GeoEye-1 Geo
Fecha de adquisición:	29/09/10
Cobertura de nubes (%):	0
Fuente de la imagen:	2010092911015041603031603264_004
Azimut del Sol:	159.29 grados
Ángulo de elevación solar:	48.39 grados
Ángulo de elevación del sensor:	69.41 grados
Azimut del Sensor:	221.92 grados
Tamaño de píxel:	0.5 m PAN and 2 m MS



Figura 12. Recorte final de imagen GeoEye-1 adquirido de una imagen de archivo.

### **3.2.3 Generación de la ortoimágenes de GeoEye-1.**

A partir de la imagen Geo pancromática de GeoEye-1, se generó una de las ortoimágenes empleadas en este trabajo, con 0.5 m de GSD. Usando el algoritmo PANSHARP de PCI-Geomática se generó una imagen fusionando las imágenes originales pancromática y multiespectral. Esta imagen fusionada tiene 0.5 m de GSD y las 4 bandas (R,G,B e Ir) que le aporta la imagen multiespectral. Las funciones racionales de grado cero y computadas con 7 puntos de control medidos en campo con GPS diferencial fueron el modelo de sensor empleado en la fase de orientación, tanto en el caso de la imagen pancromática, como para la imagen fusionada. El DEM usado para la fase de ortorrectificación final fue el derivado de datos LiDAR, descrito anteriormente. En este sentido, el equipo del proyecto del Plan Nacional de Investigación, en el cual se enmarca este trabajo, ya han presentado varios trabajos donde se detalla este proceso (Aguilar *et al.*, 2011; Aguilar *et al.*, in press; Saldaña, 2011).

La precisión planimétrica en las ortoimágenes pancromática y fusionada de GeoEye-1, medida como error cuadrático medio (*Root Mean Square Error*,  $RMSE_{2d}$ ), y calculada en 48 puntos de comprobación independientes medidos con GPS diferencial, fue de 0.46 m.



### 3.3.- METODOLOGÍA

#### 3.3.1.- SEGMENTACIÓN CON ECOGNITION®

Debido a la exigencia computacional necesaria para abordar este trabajo y al elevado número de repeticiones y ensayos que se han llevado a cabo, se decidió restringir el área de estudio a dos zonas. El núcleo urbano de Villaricos, con una extensión de 16.7 ha, y la zona agrícola situada en el término municipal de Palomares, conocida como El Bosque, y con una superficie de 30.9 ha (Fig. 8). Se realizó una segmentación previa con multiresolución usando el software de segmentación y clasificación basado en objetos denominado eCognition®. Para la segmentación de ambas zonas sólo se emplearon la ortoimagen fusionada con 4 bandas (R, G, B, NIR). En la zona urbana de Villaricos se realizó una doble segmentación jerarquizada con escalas de 20. Los objetos resultantes fueron fusionados empleando finalmente una escala 70 (Fig.13). Por otro lado, en la zona agrícola El Bosque se eligieron escalas jerarquizadas de 20 y 100 respectivamente. En ambos casos, el factor de forma (*shape*) se fijó en 0.3 mientras que la compacidad (*compactness*) se mantuvo en 0.5. De esta forma se generaron los objetos pertenecientes a las dos zonas de estudio, que posteriormente se pretendían clasificar automáticamente.

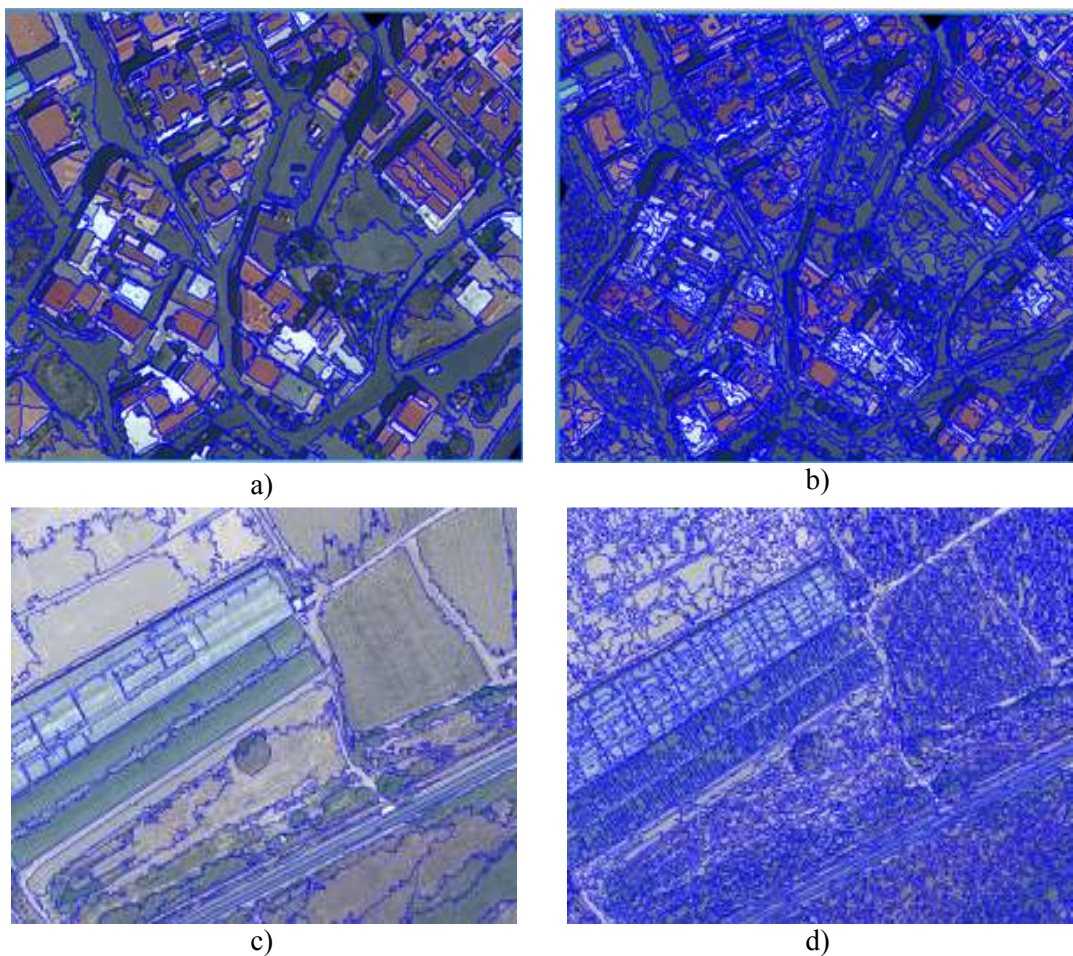


Figura 13. Ejemplos de segmentación jerarquizada. a) escala 70 y b) escala 20, ambas en el núcleo de Villaricos. c) escala 100 y d) escala 20, en el caso de El Boque.

Estos objetos fueron segmentados con eCognition® utilizando la segmentación multirresolución, que es una técnica de fusión-región de abajo hacia arriba a partir de objetos formados por píxeles, un total de 2723 objetos en la zona del núcleo de Villaricos (Fig.14) y 696 objetos en la zona El Bosque (Fig.15).




Figura 14. Segmentación jerarquizada a escalas 20 y finalmente 70. Generados 2723 objetos en Villaricos.




Figura 15. Segmentación jerarquizada a escalas 20 y finalmente 100. Generados 696 objetos en El Bosque.



### Importación de los datos empleados

Para la segmentación se importaron las ortoimágenes pancromática y fusionada con 4 bandas. Además se importaron el MDO (Modelo Digital de Objetos o Modelo Digital de Superficie normalizado) y el SAVI (Indicé de Vegetación ajustada al suelo) enfocada básicamente a la detección de superficies con vegetación.

$$SAVI = \frac{1.5 \times (NIR - Red)}{(NIR + Red + 0.5)}$$

Hay que tener en cuenta que las capas de información (Pancromática, MDO y SAVI) sólo se emplearon en clasificación. En la Figura 16 vemos como, tras la incorporación de la información, las capas anteriormente comentadas aparecen incorporadas en el nuevo proyecto.




Figura16. Importación de datos.

En el software empleado se pueden definir inicialmente las áreas en las que no existen datos (Fig. 17), que serán, en nuestro caso, aquellas de color negro con un valor de 0 en cada uno de los canales radiométricos (Rojo, Verde, Azul e Infrarrojo), que corresponden a las zonas que quedan fuera del interés del proyecto, o a las áreas que no han sido recogidas por el sensor. Este primer paso resulta importante para no tener en cuenta estas áreas ni en la segmentación, ni en la clasificación posterior, consiguiendo aumentar la eficiencia considerablemente.



Figura 17. Asignación de valores sin datos

### 3.3.2.- CLASIFICACIÓN MANUAL

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, 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*.

Existen dos formas de realizar la fase de entrenamiento, de cada una de las cuales deriva un método de clasificación. Si el conocimiento de las características de las clases está basado en la experiencia del analista, el procedimiento de clasificación se denomina supervisado. Si por el contrario, la tarea de clasificación se realiza automatizadamente, el sistema informático buscará agrupamientos naturales de los vectores de características en función de las similitudes que encuentre entre las celdillas de la imagen, los cuales podrán coincidir o no con las clases buscadas. Este segundo método se denomina no supervisado.

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 areas*), de las cuales se conoce su pertenencia a una clase concreta de las establecidas en el trabajo.

#### La clasificación manual realizada en la zona 1, Villaricos:

En la zona del núcleo de Villaricos, una vez realizada la segmentación en eCognition<sup>®</sup>, los 2723 objetos detectados se exportaron a formato .shp de ArcGis v. 9.3. Dentro de la plataforma de este Sistema de Información Geográfica, se procedió a clasificar manualmente cada uno de estos segmentos, agrupándolos en cada una de las 10 clases

seleccionadas para la zona de Villaricos. Estas clases fueron, en el caso de la zona urbana de Villaricos: edificios rojos, edificios blancos, edificios grises, otros edificios, carreteras asfaltadas, calles, vegetación, piscinas, suelo desnudo y sombras. Hay que reseñar aquí que, finalmente, todas las clases referidas a tipos de edificios serían finalmente fusionadas en una única clase, como se explicará más adelante. De los 2723 objetos segmentados en Villaricos, 1894 pudieron ser clasificados claramente por un operador en cada una de las 10 clases seleccionadas. Para ello, las capas de información comentadas anteriormente (ortoimágenes pancromática y multiespectral de GeoEye-1, SAVI, MDO) y la ortoimagen de 15 cm GSD producida en el vuelo combinado LiDAR fueron usadas para la clasificación manual. Como se muestra en la Figura 18, aproximadamente la mitad de los objetos (949) se seleccionaron para estudiar la precisión obtenida, mientras que el resto (945) se reservaron para extraer las diferentes repeticiones de objetos para el entrenamiento del clasificador.

Tabla 4. Disposición de los objetos después del proceso de segmentación en Villaricos.

<b>Clase</b>	<b>Nº Objetos</b>	<b>Objetos entrenamiento</b>	<b>Objetos precisión</b>
Edificios rojos	298	149	149
Edificios blancos	558	279	279
Edificios grises	68	34	34
Otros edificios	55	27	28
Sombras	477	238	239
Vegetación	194	97	97
Suelo desnudo	93	46	47
Carreteras	72	36	36
Calles	71	35	36
Piscinas	8	4	4
Indeterminadas	829		
<b>Total</b>	<b>2723</b>		
<b>Útiles</b>	<b>1894</b>	<b>945</b>	<b>949</b>

En la Tabla 4 se muestra la forma correcta de clasificar los objetos en cada una de las diez clases consideradas. Para cada clase, aproximadamente un 50% de objetos seleccionados para extraer repeticiones de objetos para el entrenamiento y el otro 50% seleccionadas para validar la precisión.

La selección de los campos de entrenamiento es una tarea delicada que requiere todo el rigor posible, porque de ella dependerá el resultado de la clasificación. Es necesario que el campo de entrenamiento en la imagen represente solamente a la clase que se pretende caracterizar y no se muestre contaminación por otras. En otras palabras, no son deseables los objetos mixtos que contengan información de más de una capa. Solamente así se podrá dotar al clasificador de un vector de medidas y una matriz de covarianzas exactamente representativa de la clase.



Figura 18. A la izquierda, los objetos seleccionados para estudiar la precisión obtenida. A la derecha los objetos seleccionados para el entrenamiento del clasificador.

De los 2723 objetos supervisados el observador no pudo clasificar claramente dentro de la leyenda de clases establecidas 829 objetos, los cuales fueron clasificados dentro de una clase denominada indeterminada. Como muestra la Figura 19, los objetos clasificados como indeterminados son objetos no útiles ya que en la segmentación la región generada abarcó varias zonas de distintas clases y no pudo ser clasificada dentro de una de las clases de la leyenda.



Figura 19. En la imagen se muestra una zona indeterminada que abarca coches, carreteras y edificios

En esta fase del entrenamiento del clasificador si se utiliza una sola área o campo de entrenamiento por clase, se corre el riesgo de particularizar excesivamente las características de la misma, y tras la clasificación quedaran zonas ocupadas por la misma cubierta sin atribuir a su correspondiente clase. Por ello cuando hay variabilidad dentro de las clases es necesario tomar más de un campo de entrenamiento. Es preferible aunque más costosos, elegir un mayor número de campos de entrenamiento de un tamaño inferior y distribuirlos de acuerdo a las características de variabilidad de la escena, que no un solo campo de entrenamiento de gran tamaño. Muchos estudios han mostrado que la precisión en clasificación varía en función del tamaño de muestras de entrenamiento empleadas (e.g., Foody y Mathur, 2006). En general, cuanto mayor es número y extensión del área de entrenamiento, mejores resultados podemos esperar en clasificación. Sin embargo, las tareas de entrenamiento suponen un coste importante que hay que intentar reducir en lo posible.

De los 945 objetos seleccionados para el entrenamiento del clasificador Nearest Neighbor de eCognition® en el caso del núcleo de Villaricos, se ensayaron 4 tamaños de muestras compuestas de 4 repeticiones cada una. La disposición final fue la siguiente: (i) Porcentaje de muestras igual al 5%: Repeticiones 5, 6, 7 y 8, (ii) Porcentaje de muestras igual al 10%: Repeticiones 1, 2, 3 y 4, (iii) Porcentaje de muestras igual al 15%: Repeticiones 9, 10, 11,12, (iv) Porcentaje de muestras igual al 20%: Repeticiones 13, 14, 15, 16. En la Tabla 5 se muestra la cantidad de objetos extraídos para cada uno de los conjuntos de muestras junto con su área media y desviación estándar.

Tabla 5. Características de los cuatro conjuntos de muestras de objetos extraídas para entrenamiento del clasificador en El Bosque.

Clases	NºObjetos para samples				Área de los objetos (m <sup>2</sup> )	
	5%	10%	15%	20%	Media	D.Estandar
Edificios rojos	15	30	45	60	74	1.72
Edificios blancos	28	56	84	112	30	2.58
Edificios grises	4	7	11	14	77	3.37
Otros edificios	3	6	9	11	55	1.55
Sombras	24	48	72	96	45	1.60
Vegetación	10	20	30	39	89	1.64
Suelo desnudo	5	10	14	19	166	2.74
Carreteras	4	8	11	15	218	5.24
Calles	4	8	11	15	103	2.99
Piscinas	1	1	2	2	43	9.36
Total	98	194	289	383		

La elección de las áreas de interés (*samples*) que iban a formar cada uno de los 16 sets empleados en este trabajo se realizó desde el software ArcGis<sup>®</sup>, trabajando con el archivo vectorial nativo de este Sistema de Información Geográfica (SIG), i.e., ficheros shapefile con extensión .shp.

Los 16 sets de áreas de entrenamiento se seleccionaron atendiendo a su distribución espacial (se intentó que las *samples* de cada clase estuviesen bien distribuidas sobre la zona de interés) y a la superficie total abarcada. Por ejemplo, los 298 objetos catalogados como edificios rojos tenían un área media de 74.5 m<sup>2</sup> presentando una desviación estándar de 51.6, por tanto, se intentó que cada una de las 16 repeticiones seleccionadas tuviese una superficie media de alrededor de 74 m<sup>2</sup>.

Una vez seleccionados en ArcGis los 16 conjuntos de objetos que componían las áreas de entrenamiento, debíamos preparar su exportación a ficheros GEOTIFF para poder usarlos directamente como *samples* en entorno eCognition. El proceso sería el siguiente: (i) cada archivo .shp que contiene cada una de los 16 sets de áreas de entrenamiento, es convertido en un archivo de imagen mediante la operación de rasterización que convierte la información espacial del modelo vectorial al modelo ráster mediante la función *polygon to raster* de ArcGis.

A continuación con ERDAS IMAGINE 9.1<sup>®</sup> se realiza la exportación de .IMG a .GEOTIFF, ya que constituye el formato más adecuado para su uso en el clasificador Nearest Neighbor del software eCognition<sup>®</sup>.

A la hora de realizar la clasificación utilizamos el criterio más sencillo para asignar una celdilla a una categoría que consiste en incluirlo en la más cercana. La distancia se mide entre el extremo del vector características de la celdilla en cuestión y la media del agrupamiento. Por ello, el procedimiento se conoce comúnmente con la denominación de mínima distancia o vecino más próximo Nearest Neighbor. Esta clasificación se realizará mediante el software eCognition<sup>®</sup> con el clasificador integrado Nearest Neighbor.

Para clasificar los objetos usando el clasificador Nearest Neighbor, después de haber efectuado la segmentación, habría que seguir los siguientes pasos: (i) Cargar o crear las clases, (ii) Definir el espacio de características, (iii) Definir los objetos de la muestra, (iv) Clasificar, revisar los resultados y optimizar su clasificación.

En la Figura 20 se muestra como se disponen las clases y subclases, cada una de ellas identificada con un color diferente, utilizadas para la clasificación en el núcleo de Villaricos.





Figura 20. Leyenda de las clases y sub-clases utilizadas en la clasificación en el núcleo de Villaricos.

Para la clasificación con Nearest Neighbor, se necesitan muestras de los objetos que se consideren representativas de una determinada clase. De esta manera, se entrena el algoritmo Nearest Neighbor en la clasificación para diferenciar las clases. Cuantas más muestras selecciones, más consistente será la clasificación. Los sets de samples se cargan en eCognition como una *TTA mask*, (archivo GEOTIFF) que contiene la muestra de los objetos previamente seleccionados manualmente en entorno ArcGis.

Como dijimos previamente, en nuestro caso se utilizaron 4 conjuntos de muestras (5%, 10%, 15%, 20%) con 4 repeticiones cada una, es decir, un total de 16 repeticiones fueron utilizadas individualmente para entrenar el clasificador Nearest Neighbor. En la Figura 21 se muestra la disposición de las muestras en la repetición 2 (10% de samples) para el entrenamiento del clasificador.




Figura 21. Samples empleadas para entrenamiento clasificador N. Neighbour. En este caso se empleó un 10% de objetos para samples en el Núcleo de Villaricos.

Una vez efectuada la importación del set de entrenamiento, se pasa a la fase de clasificación automática. Se probaron siete conjuntos de características en la clasificación de Villaricos: (i) 7 Características básicas, compuestas por la banda pancromática, el rojo, las bandas azul, verde e infrarrojo de la ortoimagen pansharpened, el brillo calculado para el rojo, azul, verde e infrarrojo, y la diferencia máxima, (ii) 7 Características básicas además de SAVI, (iii) 7 Características básicas más MDO, (iv) 7 Características básicas más MDO y SAVI, (v) 7 Características básicas y más SAVI y el Índice de Diferencia Normalizada Azul (BNDVI), (vi) 7 Características básicas más una componente de textura, concretamente el CONTRASTE calculado a partir de contra banda pancromática tras calcular la matriz de coocurrencia de Haralick para todas las direcciones y, finalmente, (vii) 45 funciones, incluyendo además de los anteriores, otras características de textura, posición y forma.

En la Figura 22, que se muestra a continuación, se ilustra la clasificación obtenida al utilizar el conjunto de las 7 características básicas más MDO y SAVI, habiendo empleado un 10% de muestras para entrenar el clasificador Nearest Neighbor.




Figura 22. Clasificación obtenida al utilizar las 7 features básicas más MDO y SAVI y habiendo empleado un 10% de samples para el entrenamiento del clasificador Nearest Neighbor en el Núcleo de Villaricos.

#### La clasificación manual realizada en la zona 2, El Bosque:

Un ensayo similar al expuesto, se realizó en una zona de condiciones más rurales con el objeto de ver cómo funcionaba en estos ambientes el clasificador de eCognition®



Nearest Neighbor. Para ello seleccionamos en el denominado como paraje El Bosque, una zona para practicar lo expuesto anteriormente.

En la zona de El Bosque, y una vez realizada la segmentación en eCognition<sup>®</sup>, los 696 objetos detectados en este proceso se exportaron a formato .shp de ArcGis v. 9.3. Dentro de la plataforma de este Sistema de Información Geográfica, se procedió a clasificar manualmente cada uno de estos segmentos, agrupándolos en cada una de las 4 clases seleccionadas para la zona El Bosque. Las clases seleccionadas en este caso, como se muestran en la Figura 23 fueron 7: Carreteras, invernaderos plástico, invernaderos malla, cultivos sin vegetación, cultivos aire libre, vegetación y caminos. Finalmente se agruparon en 4 clases principales, como se ilustra en la Figura 23.



Figura 23. Leyenda de las clases y sub-clases utilizadas en la clasificación en El Bosque.

De los 696 objetos segmentados en El Bosque, 510 objetos pudieron ser clasificados claramente por un operador en cada una de las 7 clases seleccionadas. Como se muestra en la Tabla 4, un total de 456 de los objetos se seleccionaron para estudiar la precisión obtenida, mientras que 54 objetos se dejaron para extraer un 10% de objetos para el entrenamiento del clasificador.

Tabla 6. Disposición de los objetos después del proceso de segmentación en El Bosque.

<b>Id</b>	<b>Clase</b>	<b>Nº Objetos</b>	<b>10% Samples</b>	<b>Accuracy</b>
1	Carreteras	5	1	4
2	Invernaderos plástico	68	7	61
3	Invernaderos malla	24	3	21
4	Cultivos sin vegetación	174	18	156
5	Cultivos aire libre	120	12	108
6	Vegetación	96	10	86
7	Caminos	23	3	20
8	Indeterminado	186		
	Total	696	54	456
	útiles	510		

Todo el proceso fue análogo al empleado en el caso del núcleo urbano de Villaricos, explicado en el caso anterior, aunque en el caso de El Bosque, solamente se extrajo un set de áreas de entrenamiento. Dicho set incluyó un 10% de objetos perteneciente a cada una de las 7 clases seleccionadas (Tabla 6).

En la Figura 24 se muestra el set de samples seleccionadas, representando el 10% de objetos para muestras destinadas al entrenamiento del clasificador Nearest Neighbor, ya que fue el porcentaje de objetos para muestras que demostró obtener los mejores resultados en la precisión estudiada en la zona del núcleo de Villaricos.



Figura 24. Samples empleadas para entrenamiento clasificador N. Neighbour en El Bosque.

Para la etapa de clasificación en El Bosque, se probaron 4 conjuntos de características: (i) 7 Características básicas, compuestas por la banda pancromática, las bandas roja, azul, verde e infrarroja de la ortoimagen pansharpened, el brillo de la calculada para el rojo, azul, verde e infrarrojo, y la diferencia máxima, (ii) 7 Características básicas además de SAVI, (iii) 7 Características básicas más MDO, (iv) 7 Características básicas más MDO y SAVI.




Figura 25. Clasificación obtenida al utilizar las 7 features básicas más MDO y SAVI en El Bosque.

En la Figura 25 se muestra la clasificación obtenida al utilizar las 7 features básicas más MDO y SAVI en el clasificador Nearest Neighbor, habiendo empleado un 10% de objetos para su entrenamiento.

### **3.3.1.1 Estimación de la precisión de la clasificación.**

El siguiente paso en la verificación de la clasificación consiste en obtener para cada celdilla o píxel de la imagen, su verdadera clasificación (clasificación manual inicial) y compararla con la propuesta por el clasificador.

La comparación entre los resultados de la clasificación y los de la verificación se realiza mediante la confección de una matriz cuadrada en la que las columnas recogen las clases propuestas por el clasificador y las filas la ocupación real, y que se conoce como matriz de confusión (Pinilla, 1995). Cada elemento de la misma estará ocupado con un número que representará la cantidad de píxeles de la muestra analizada que, perteneciendo en la imagen clasificada a la categoría que marca su columna, realmente la verificación ha demostrado su pertenencia a la clase que indica su fila. La diagonal principal de dicha matriz estará ocupada por el número de celdillas correctamente clasificadas para cada categoría. Los elementos fuera de la diagonal principal indican errores de asignación ya sean errores por omisión o errores por comisión.

La matriz de confusión es una modalidad de tabla de contingencia, a partir de la cual podrá extraerse información cuantitativa acerca del proceso de verificación. La fiabilidad global de la imagen clasificada se estima como la razón existente entre el número de celdillas correctamente clasificadas y el total de celdillas muestreadas. La fiabilidad del muestreo será establecida como el cociente entre la traza de la matriz de confusión y la suma de sus elementos.

La expresión de los errores de omisión y comisión en términos porcentuales suele denominarse riesgo del productor (*producer accuracy*) y riesgo del usuario (*user accuracy*). El primero de ellos consiste en la probabilidad de error en la que incurre el analista como consecuencia de la no inclusión de algunas celdillas en la clase correspondiente (omisión). Por el contrario, el riesgo del usuario se refiere al que asume éste cuando supone cierta la naturaleza de una celdilla 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 y la fiabilidad del usuario.

Tras la clasificación procedemos a la comparación, en cada una de las zonas, de lo clasificado mediante eCognition® y el *Ground Truth* muestral (objetos seleccionados para estudiar la precisión y correctamente clasificados de forma manual). Para ello debemos cargar la máscara que se compone del fichero que habíamos creado para validar la precisión, en formato geotiff y un archivo .csv compuesto de la forma que muestra la Tabla 7 en el caso de Villaricos.

Tabla 7. Forma del archivo .CSV en Villaricos

Id	Rojo(0-255)	Verde (0-255)	Azul(0-255)	Nombre Clases
1	255	0	0	Edificios rojos
2	156	156	156	Carreteras
3	168	112	0	Suelo desnudo
4	255	190	190	Edificios blancos
5	0	0	0	sombras
6	255	0	197	Edificios grises
7	152	230	0	Vegetación
8	0	255	197	Piscinas
9	255	255	0	Calles
10	163	0	163	Otros edificios

A continuación tras cargar la máscara, calculamos en el evaluador de exactitud mediante la función Accuracy Assessment de eCognition® y escogemos la opción Error basado en la máscara (*Error Matrix based on a TTA Mask*) y comprobamos los resultados. El valor de precisión global o *overall accuracy* es el acierto global que obtenes tras la clasificación automática, cuando se compara con el conjunto de objetos destinados a validar la precisión.

Como vemos en la Figura 26, en el apartado de acierto (*accuracy*) tenemos un acierto de productor y usuario por cada clase que tenemos.

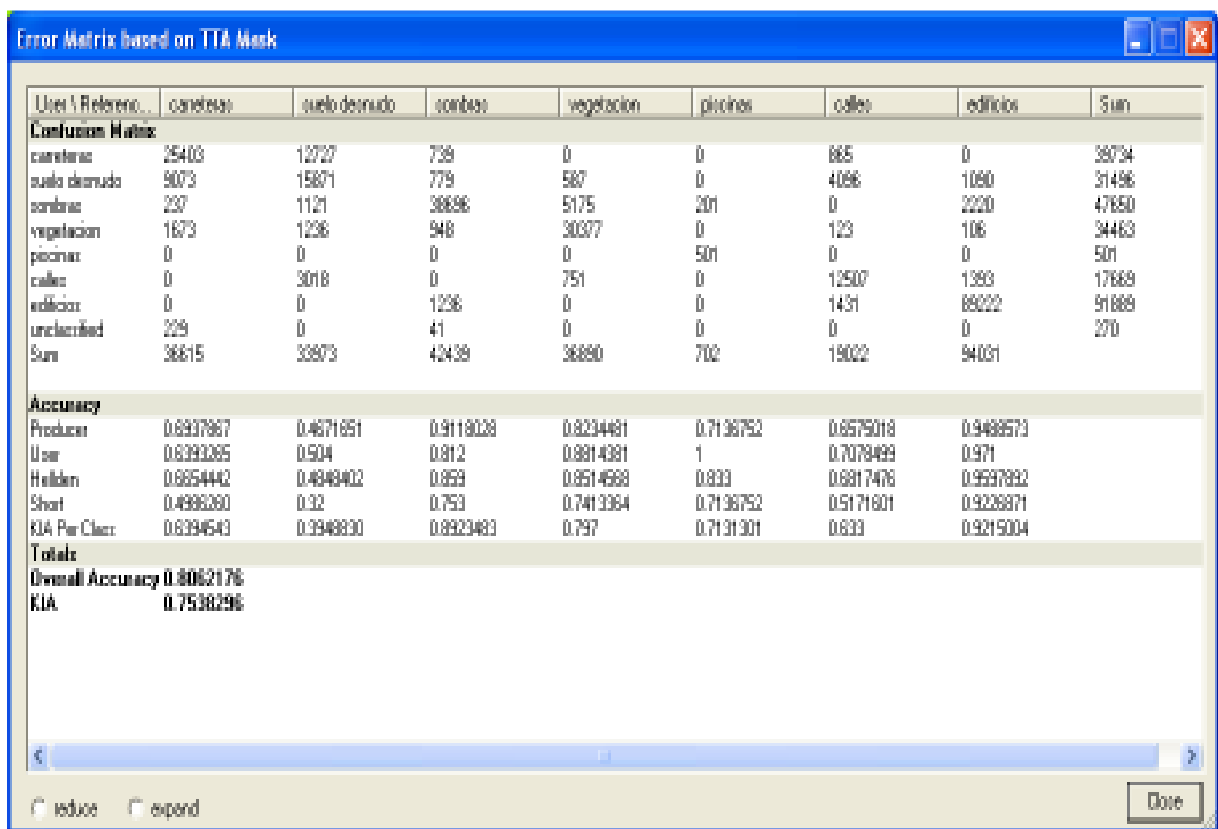


Figura 26. Resultado de la matriz de confusión utilizando las 7 features básicas más MDO y SAVI como características y la repetición 4 (10%) para el entrenamiento del clasificador en el caso de Villaricos.

### **3.3.3- CARACTERÍSTICAS O *FEATURES* EMPLEADAS**

En los últimos años, el valor de la adición de diversas características a la clasificación de imágenes de satélite se ha demostrado claramente como un método para mejorar los resultados (e.g., Pu *et al.*, 2011; Carleer y Wolff, 2006). Por ejemplo, la textura es el término utilizado para caracterizar el tono o nivel de gris-variaciones en una imagen. El análisis de la textura ha jugado una vez más papel importante en el procesamiento digital de imágenes y la interpretación, principalmente motivado por el hecho de que puede proporcionar información adicional sobre las propiedades de la imagen.

Una de las finalidades de nuestro proyecto es comprobar si mediante el uso de distintas características (*features*) pertenecientes al grupo de textura, forma, posición o valores medios de las capas de información principales, obtenemos una mayor precisión a la hora de la clasificación.

Además de las siete características básicas (*features*) cargadas directamente en eCognition (Fig. 16), se usaron otros 42 factores de características más para realizar la clasificación de objetos mediante Nearest Neighbor. Fueron generadas un total 49 características (26 características espectrales, 19 características de textura y 4 características de forma/geometría) para el análisis de esta clasificación de objetos (Tabla 8). La consideración y determinación de esas características fueron seleccionadas en base a estudios previos realizados por diversos autores (Haralick *et al.*, 1973; Carleer y Wolff, 2006; Kong *et al.*, 2006; Yu *et al.*, 2006; Pu *et al.*, 2011).

Para nuestro estudio se dispusieron de la siguiente forma en conjuntos de características:

En la Zona de Villaricos se formaron siete grupos de características o *features*.

- (i) 7 Características básicas: Compuestas por la banda pancromática, las bandas roja, azul, verde e infrarroja de la ortoimagen pansharpened, el brillo calculado para el rojo, azul, verde e infrarrojo, y la diferencia máxima.
- (ii) 7 Características básicas además del SAVI.
- (iii) 7 Características básicas más MDO.
- (iv) 7 Características básicas más MDO y SAVI.
- (v) 7 Características básicas y más SAVI y el Índice de Diferencia Normalizada Azul (BNDVI).
- (vi) 7 Características básicas más el CONTRASTE calculado en la banda Pancromática a partir de la matriz de Haralick, para todas las direcciones.
- (vii) 45 features, se utilizaron todas las features de la Tabla 8 menos BNDVI y MDO.

En la Zona de El Bosque se formaron cuatro grupos de características.

- (i) 7 Características básicas: Compuestas por la banda pancromática, las bandas roja, azul, verde e infrarroja de la ortoimagen pansharpened, el brillo calculado para el rojo, azul, verde e infrarrojo, y la diferencia máxima.
- (ii) 7 Características básicas además del SAVI.
- (iii) 7 Características básicas más MDO.

(iv) 7 Características básicas más MDO y SAVI.

Tabla 8. Características de los objetos usadas en este análisis. (Para más información, Definiens eCognition, 2009)

<b>Features</b>	<b>Descripción</b>
BNDVI	Variante del NDVI que utiliza la información del canal azul en lugar del rojo.
Banda1	Media en la imagen pansharpened GEOEYE-1 de la banda 1(azul).
Banda2	Media en la imagen pansharpened GEOEYE-1 de la banda 2(verde).
Banda3	Media en la imagen pansharpened GEOEYE-1 de la banda 3(roja).
Banda4	Media en la imagen pansharpened GEOEYE-1 de la banda 4(NIR).
Max.dif	Media en la imagen pansharpened GEOEYE-1 de la máxima diferencia.
Billo	Media en la imagen pansharpened GEOEYE 1 del brillo.
PAN	Media en la imagen pansharpened GEOEYE-1 de la banda pancromática.
SAVI	Media del índice de vegetación ajustada al suelo: $1.5 (banda4 - banda3) / (banda4 + banda3 + 0.5)$ .
MDO	Media del Modelo digital de superficie o modelo digital de objetos.
SDB1	Derivación estándar de la Banda1.
SDB2	Derivación estándar de la Banda2.
SDB3	Derivación estándar de la Banda3.
SDB4	Derivación estándar de la Banda4.
SDPA	Derivación estándar de la banda pancromática.
SDVI	Derivación estándar del SAVI.
Radio1	Radio de escena en banda 1.
Radio2	Radio de escena en banda 2.
Radio3	Radio de escena en banda 3.
Radio4	Radio de escena en banda 4.
SAVI	Radio de escena en SAVI.
PAN	Radio de escena en Pancromática.
HUE	Color asignado para conversión de los valores RGB en HSI.
Saturación	Saturación asignada para conversión de los valores RGB en HSI.
Intensidad	Intensidad (brillo) asignada para conversión de los valores RGB en HSI.
GLCMH	GLCM Homogeneidad en banda4.
GLCMCON	GLCM contraste en banda4.
GLCMD	GLCM diferencia en banda4.
GLCME	GLCM entropía en banda4.
GLCMSD	GLCM desviación estándar en banda4.
GLCMCOR	GLCM correlación en banda4.
GLDVA	GLDV segundo momento angular en banda4.
GLDVE	GLDV entropía en banda4.
GLDVC	GLDV contraste en banda4.
Compacto	Compactación, el producto del ancho y largo de los correspondientes objetos dividido con su número de pixeles internos.
CompactoP	Compactación, la relación del área de un polígono con el área de un círculo con el mismo perímetro.
Formal	Forma índice, el largo del borde de un IO dividido cuatro veces la raíz cuadrada de su área, es decir, la suavidad.
NumeroP	Número de bordes, numero de bordes que forman el polígono.

Nota: Todas las características (GLCM, GLDV) fueron estudiadas para todas las direcciones según las bandas NIR y PAN.



### 3.3.4- ANÁLISIS ESTADÍSTICO

Se ensayaron distintos porcentajes de objetos para entrenamiento del clasificador, así como diversos conjuntos de *features* para generar la clasificación en zonas urbanas y agrícolas. Se realizaron cuatro repeticiones de cada proyecto para poder llevar a cabo un análisis de la varianza (ANOVA) que nos servirá para elegir el procedimiento más adecuado.

El análisis de varianza (ANOVA) de un factor sirve para comparar varios grupos en una variable cuantitativa. El ANOVA de un factor permite obtener información sobre el resultado de esa comparación. Es decir, permite concluir si los factores sometidos a distintos programas difieren la medida de rendimiento utilizada. En nuestro caso los factores estudiados fueron el conjunto de *features* utilizado en clasificación y el porcentaje de muestras empleado (5%, 10%, 15% y 20%). La variable dependiente o estudiada será la precisión obtenida en la clasificación automática y controlada en el conjunto de objetos correctamente clasificados y destinados a la evaluación de la precisión de la clasificación. Esta variable dependiente será, en un primer momento, la overall accuracy, y después iremos ensayando la influencia de los factores sobre las precisiones *user* y *producer* particularizadas para cada una de las clases principales (7 en el caso de Villaricos y 4 en el caso de El Bosque).

Una vez tenemos todos los datos necesarios para hacer un análisis estadístico de la varianza (ANOVA) lo que hacemos es exportar estos datos al programa SPSS para Windows.

Para ello se crea una tabla como la que se muestra en la Figura 27 en la cual se disponen dos columnas, en una se colocan las samples (5%,10%,15%, 20%) para cada una de sus 4 repeticiones por cada uno de los porcentajes de las samples, en otra columna se colocan los conjuntos de características (*features*) mediante unos códigos identificativos. En otra fila horizontal se disponen las clases.

	samples	features	overall	edific_p	edific_u	veg_p	veg_u	sombra_p	sombra_u	bare_p	bare_u	carret_p	carret_u	calles_p	calles_u
2	5	9	76.19	96.74	87.76	59.27	85.50	90.03	84.76	49.06	47.48	52.37	58.41	71.05	65.81
3	5	9	75.68	93.50	91.80	89.38	82.92	87.67	90.33	19.80	33.10	55.94	47.86	72.25	64.91
4	5	9	81.35	97.08	91.36	84.49	85.78	87.96	92.76	53.05	54.61	69.89	63.68	55.75	84.97
5	10	9	83.15	96.26	95.69	91.18	88.60	87.02	91.23	63.26	54.52	59.63	76.25	77.28	66.27
6	10	9	77.76	95.22	94.27	77.40	81.69	90.64	89.32	40.52	46.48	63.25	57.57	58.14	55.15
7	10	9	76.04	94.36	94.36	65.49	92.88	88.81	77.14	58.76	46.87	43.74	52.91	73.30	72.37
8	10	9	80.62	94.89	97.10	82.34	88.14	91.18	81.21	46.72	50.39	69.38	63.93	65.75	70.78
9	15	9	82.47	96.95	94.21	84.15	85.20	90.31	89.27	58.17	54.77	58.09	70.30	80.81	75.47
10	15	9	77.77	95.87	92.62	79.70	86.34	88.65	92.21	40.90	50.23	65.82	53.68	50.23	52.12
11	15	9	79.48	95.57	95.13	83.69	90.33	92.28	81.22	44.95	43.28	54.80	60.62	72.67	78.28
12	15	9	82.36	95.43	95.29	88.18	91.23	91.26	89.16	47.89	53.15	65.88	62.94	80.35	73.81
13	20	9	79.39	96.57	96.12	88.10	91.74	90.97	83.39	35.17	41.79	54.62	56.95	78.72	65.58
14	20	9	83.93	95.20	96.30	90.67	87.61	90.64	91.41	57.81	61.72	69.89	69.16	73.92	67.68
15	20	9	80.88	95.20	94.54	94.38	94.54	92.68	89.06	53.00	47.46	47.21	58.65	73.50	69.95
16	20	9	82.96	98.01	94.48	89.72	92.60	90.84	86.65	54.11	57.17	59.24	68.40	75.47	67.60
17	5	7	70.07	83.90	81.41	38.92	78.47	91.12	92.65	44.26	44.82	79.59	49.32	44.82	56.10
18	5	7	74.32	92.31	74.09	73.07	95.25	92.37	85.55	39.32	50.34	64.60	65.49	28.90	59.90
19	5	7	64.56	87.12	78.67	55.68	91.39	91.40	79.38	15.96	18.92	39.74	32.60	44.71	59.35
20	5	7	76.77	95.18	78.88	75.72	94.34	91.78	82.38	34.04	48.67	71.24	66.01	41.47	83.31
21	10	7	74.17	90.40	81.77	76.47	81.87	85.88	90.30	48.16	42.65	60.52	68.76	36.14	49.78
22	10	7	74.83	89.16	85.05	73.92	86.23	93.70	92.36	27.27	36.64	72.75	58.74	52.77	52.04
23	10	7	74.59	88.83	86.04	66.94	92.77	91.89	89.33	48.41	42.91	57.68	52.28	62.55	68.21
24	10	7	73.84	87.21	79.36	81.11	77.62	80.48	79.48	47.73	55.00	59.52	67.74	53.06	80.65
25	15	7	73.47	87.46	78.89	72.02	91.00	92.36	81.40	32.73	45.24	63.83	58.27	56.39	63.76
26	15	7	71.80	88.05	82.79	75.19	76.81	91.01	92.69	24.42	35.96	69.26	59.13	32.43	31.47
27	15	7	74.14	87.78	80.65	83.17	87.80	87.78	86.67	32.07	41.99	68.06	59.37	45.76	57.11
28	15	7	76.66	91.60	85.07	71.78	97.70	93.04	87.22	37.36	43.33	67.36	59.17	63.94	65.53

Figura 27. Disposición de los factores a analizar mediante el método de la separación de medias.

Seleccionaremos para este caso el modelo lineal general univariante tomando como valores fijos las *samples* y las *features* ya que serán con las que hagamos una comparación con cada una de las clases de las cuales disponemos mediante el método que queremos utilizar para nuestro análisis estadístico, la separación de medias Duncan. Denominada prueba del rango múltiple de Duncan, es el método de comparación por pasos basado en la distribución del rango estudentizado.

Controla la tasa de error utilizando, para el conjunto de medias separadas  $r$  pasos, un nivel de significación  $\alpha_C = 1 - (1 - \alpha)^{r-1}$ . Cuantos más pasos existen entre dos medias, mayor es la diferencia mínima con la que vamos a considerar que esas medias difieren significativamente.

Para saber qué media difiere de qué otra debemos utilizar un tipo particular de contrastes denominados comparaciones múltiples post hoc o comparaciones a posteriori. Estas comparaciones permiten controlar la tasa de error al efectuar varios contrastes utilizando las mismas medias, es decir, permiten controlar la probabilidad de cometer errores tipo I al tomar varias decisiones (los errores tipo I se cometen cuando se decide rechazar una hipótesis nula).

Este método permite, una vez rechazada la hipótesis general del ANOVA de que todas las medias son iguales, averiguar qué medias en concreto difiere de qué otras.

Con esto se generan varias tablas en las que se podrán detectar para cada una de las clases que hemos seleccionado cuál de los factores optimizan la precisión y calidad de la clasificación.

A continuación en datos y resultados haremos un estudio de los resultados de estas tablas obtenidas



# **CAPÍTULO 4**

**RESULTADOS**

**Y**

**DISCUSIÓN**

#### **4.- RESULTADOS Y DISCUSIÓN**

##### **CASO DE VILLARICOS**

##### **4.1.- OVERAL ACURRACY**

El valor de overall accuracy es la precisión global que obtienes clasificando, teniendo como punto de partida los objetos que en la realidad hay en el terreno.

Tabla 9. ANOVA para los resultados de *overall accuracy* de la imagen de Geoeye-1.

<b>Fuente</b>	<b>Suma de cuadrados</b>	<b>Gl</b>	<b>Media cuadrática</b>	<b>F</b>	<b>Significación</b>
Modelo	665065.608(a)	28	23752.343	3162.109	.000
SAMPLES	253.734	3	84.578	11.260	.000
FEATURES	382.923	6	63.821	8.496	.000
SAMPLES *FEATURES	20.437	18	1.135	.151	1.000
Error	630.970	84	7.512		
Total	665696.579	112			

En la Tabla 9 se puede observar que, según el grado de significación, el factor Samples es el más significativo, siendo también significativo el factor Features, pero no siendo significativa la combinación de ambos factores al mismo tiempo, es decir la intersección de factores (no hay una relación directa entre ambos factores). Ya que el estudio se ha realizado a un nivel de confianza del 95%, para que un factor sea significativo,  $p$  debe estar por debajo de 0.05 ( $p < 0.05$ ), en este caso, como se observa en la Tabla 9, la significación de las Samples y Features es del 0.000. En esta tabla se han usado los 7 conjuntos de features estudiados para el caso de Villaricos, y 16 sets de áreas de entrenamiento descritas también para este caso.

Una vez que vemos que las dos variables son significativas, se procede al estudio de las mismas por separado. El objetivo de este estudio es determinar para qué porcentaje de SAMPLES la precisión será la más adecuada, y cuáles serán las mejores FEATURES para una clasificación precisa.

Siendo las Samples y Features las variables fijas, se realiza el estudio de las mismas, cuya separación de medias mediante el test de Duncan, se presenta en la Tablas 10 y 11.

Tabla 10. Separación de medias de la variable *samples* para la *overall accuracy* en la imagen a un nivel de confianza del 95%.

<b>SAMPLES (%)</b>	<b>N</b>	<b>SUBCONJUNTO</b>		
		<b>1</b>	<b>2</b>	<b>3</b>
5	28	74.6610		
10	28		77.0241	
15	28		77.6009	77.6009
20	28			78.7975
Significación		1.000	.433	.106

Como se muestra en la Tabla 8, con el 20% de muestras de entrenamiento se consiguen los mejores resultados de clasificación global (78.79%), aunque no es diferente de cuando empleamos un 15% de muestras (77.60%). Unos porcentajes inferiores al 15% si presentan diferencias significativamente peores.

Tabla 11. Separación de medias de la variable *features* para la *overall accuracy* en la imagen a un nivel de confianza del 95%.

FEATURES	N	SUBCONJUNTO			
		1	2	3	4
7 FEATURES	16	73.9493			
+CONTRASTE	16	75.8089	75.8089		
+MDO	16		76.2814		
+SAVI	16		76.8756		
SAVI+BNDVI	16		77.3272	77.3272	
45 FEATURES	16			78.9290	78.9290
+SAVI+MDO	16				79.9749
Significación		.058	.158	.102	.283

Vemos como no hay una diferencia significativa entre 7 FEATURES y CONTRAST ni de este con MDO, SAVI, SAVI+BNDVI, pero si entre estas tres últimas con 7 FEATURES. Ni diferencia significativa entre SAVI+BNDVI y 45 features pero si de esta con el resto ni si quiera con SAVI+MDO que es la más significativa de todas las features. En resumen, los mejores resultados se obtendrían usando las 7 características básicas más SAVI y MDO (79.97%) o con las 45 features (78.93%) no habiendo diferencias significativas entre ellos. Hay que tener en cuenta que el tiempo para el cómputo de las 45 features es muchísimo más elevado que para el resto de características, siendo las características de textura tras Haralick las que consumen más tiempo computacional.

#### 4.2.- CLASE EDIFICIOS

Esta clase fusiona los resultados de las cuatro clases inicialmente elegidas para este tipo de elementos (i.e., edificios rojos, blancos, grises y otros edificios). Se puede observar que el grado de significación, tanto en Features como en Samples es el mismo (0.000), por lo que para conocer cual adquiere mayor significación observamos el valor F, que es mayor en Features que en las samples, por lo que Features tendrá una mayor significación en el análisis, no siendo significativas ambas al mismo tiempo. Ya que el estudio se ha realizado a un nivel de confianza del 95%, para que un dato sea significativo,  $p$  debe estar por debajo de 0.05 ( $p < 0.05$ ). En la Tabla 12 se muestra el análisis ANOVA realizado con los factores fijos (Samples y Features) y la variable dependiente (edificios).

Tabla 12. ANOVA para la clase “edificios”(user accuracy).

Fuente	Suma cuadrados	Gl	Media cuadrática	F	Significación
Modelo	853249.517(a)	28	30473.197	3833.604	.000
SAMPLES	324.297	3	108.099	13.599	.000
FEATURES	2802.847	6	467.141	58.768	.000
SAMPLES *FEATURES	163.286	18	9.071	1.141	.329
Error	667.713	84	7.949		
Total	853917.231	112			

Tabla 13. Separación de medias de la variable *samples* para la clase “edificios” en la imagen a un nivel de confianza del 95%.

SAMPLES	N	Subconjunto	
		1	2
5	28	84.2626	
15	28		87.3662
20	28		88.3597
10	28		88.4691
Significación		1.000	.171

En la Tabla 13 que genera ANOVA mediante el método de separación de medias Duncan se muestra claramente como no hay diferenciación aparente para el subconjunto 2 en el cual se encuentran los datos pertenecientes a 10, 15, 20 % y por lo contrario encontramos el subconjunto 1 formado por datos pertenecientes a el 5 %. Por lo que un 5% de samples para cada una de las 4 repeticiones efectuadas es el que genera una mayor precisión.

Tabla 14. Separación de medias en la variable *features* para la clase “edificios” en la imagen a un nivel de confianza del 95%.

FEATURES	N	Subconjunto			
		1	2	3	4
7 FEATURES	16	81.6157			
+SAVI	16	82.1718			
SAVI+BNDVI	16	83.0885			
+CONTRASTE	16		86.0894		
45 FEATURES	16			88.3422	
+SAVI+MDO	16				94.1794
+MDO	16				94.3139
Significación		.167	1.000	1.000	.893

Al realizar la separación de medias utilizando el método de Duncan para *features* (Tabla 14), en edificios se vio que 7 *features*, SAVI, SAVI+BNDVI (subconjunto 1) no tenían diferenciación significativa entre ellos pero si el Contraste con respecto a estos, 45 F

con respecto a los del subconjunto 1 y 2 y también una diferenciación significativa, la mayor del SAVI+MDO y MDO con respecto a los demás pero no entre ellos.

Esto viene a decir que dentro de las Features utilizadas las que mejor resultado dieron al clasificar edificios, tanto precisión de usuario (*user*) como de productor (*producer*) fueron tanto SAVI+MDO como el MDO por independiente. Esto se debe básicamente en que el MDO es una capa fundamental a la hora de detectar edificaciones mediante umbrales de color, altura, forma y al sumarle el SAVI que es el que básicamente detecta la vegetación, hace que por ejemplo no confunda al clasificar alturas de árboles con alturas de edificios y los clasifique incorrectamente. Ese hecho concuerda con los datos reportados por autores como Herмосilla *et al.* (2010). En la (Fig.28) vemos como al utilizar un conjunto de características formado por MDO+SAVI logramos una muy buena clasificación de los edificios próxima al 95% de edificios clasificados automáticamente por el clasificador.




Figura 28. Resultado de la clasificación utilizando capa MDO+SAVI. a) Imagen pancharpened b) Clasificación obtenida para Villaricos al utilizar MDO+SAVI c) Detalle clasificación de edificios y leyenda de clases.

### 4.3.- CLASE VEGETACIÓN

Tabla 15. ANOVA para la clase “vegetación” (*producer accuracy*).

Fuente	Suma cuadrados	Gl	Media cuadrática	F	Significación
Modelo	706495.503	28	25231.982	242.521	.000
SAMPLES	4302.852	3	1434.284	13.786	.000
FEATURES	4191.390	6	698.565	6.714	.000
SAMPLES * FEATURES	1018.342	18	56.575	.544	.928
Error	8739.398	84	104.040		
Total	715234.901	112			

En la Tabla 15 se puede observar que según el grado de significación, el factor Samples es el más significativo siendo también significativo el factor Features, pero no siendo significativa la combinación de ambos factores al mismo tiempo, es decir la intersección de factores (no hay una relación directa entre ambos factores) Ya que el estudio se ha realizado a un nivel de confianza del 95%, para que un factor sea significativo,  $p$  debe estar por debajo de 0.05 ( $p < 0.05$ ), en este caso, como se observa en la Tabla 15 la significación de las Samples y Features es del 0.000. En esta tabla se han usado los 7 conjuntos de features estudiados para el caso de Villaricos, y 16 sets de áreas de entrenamiento descritas también para este caso.

Tabla 16. Separación de medias de la variable *samples* para la clase “vegetación” a un nivel de confianza del 95%.

SAMPLES	N	Subconjunto		
		1	2	3
5	28	69.0963		
10	28		78.7158	
15	28		81.8428	81.8428
20	28			85.8906
Significación		1.000	.255	.141

En la Tabla 16 que genera ANOVA mediante el método de separación de medias Duncan para Samples se muestra claramente como no hay diferenciación aparente dentro del subconjunto2 donde se encuentran los datos pertenecientes a 10y15% y dentro del subconjunto3 donde se encuentra los datos pertenecientes a 15y 20%) y por el contrario si en el subconjunto 1 formado por los datos pertenecientes a el 5%) pero aun así no habiendo diferenciación significativa entre 15 y 20 % será el 20 % el de samples para cada una de las 4 repeticiones el que genera mayor precisión.

Tabla 17. Separación de medias de la variable *features* para la clase “vegetación” a un nivel de confianza del 95%.

FEATURES	N	Subconjunto	
		1	2
+MDO	16	69.1722	
7 FEATURES	16	73.3342	
+CONTRAST	16	73.9652	
+SAVI+MDO	16		81.9001
+SAVI	16		83.0103
SAVI+BNDVI	16		84.6013
45 FEATURES	16		86.2214
SIGNIFICACIÓN		.215	.282

Al realizar la separación de medias utilizando el método de Duncan para *features* (Tabla 17), en vegetación vemos como las features pertenecientes al subconjunto 1 y al subconjunto 2, no muestra diferenciación de las Features pertenecientes a cada uno pero si entre ellas donde se puede ver que una vez que aparece el SAVI mejora siendo cuando se aplican las 45 clases cuando mejor funcionaria pero con el inconveniente de el tiempo que tarda ya que al ser 45 capas de características el software puede tardar mucho tiempo siendo inviable ya que la diferenciación no es significativa con las de su subconjunto. Así que aquí la mejor opción sería pensar que la mejor opción es utilizar SAVI+BNDVI que son capas fundamentales a la hora de detectar vegetación.

Esto viene a decir que dentro de las Features utilizadas las que mejor resultado dieron al clasificar vegetación, tanto precisión de usuario (*user*) como de productor (*producer*) fueron 45 *features* y SAVI+BNDVI decidiendo que la capa de características más adecuada es la de SAVI+BNDVI por el menor tiempo computacional de esta.

#### 4.4.- CLASE SOMBRAS

En la Tabla 18 se observó que según el grado de significación en la tabla ANOVA el factor más significativo fue *features* (F=3.801 Sig=0.002) siendo menos significativo el factor *samples* (F=3.476 Sig=0.020) y no siendo relativamente significativas la combinación de ambos factores al mismo tiempo, es decir la intersección de factores (no hay relación directa entre ambos factores) Ya que el estudio se ha realizado a un nivel de confianza del 95%, para que una dato sea significativo, *p* debe estar por debajo de 0.05 ( $p < 0.05$ ).

Tabla 18. ANOVA para la clase “sombras” (*Producer accuracy*)

Fuente	Suma cuadrados	gl	Media cuadrática	F	Significación
Modelo	928658.691(a)	28	33166.382	3970.153	.000
SAMPLES	87.108	3	29.036	3.476	.020
FEATURES	190.521	6	31.753	3.801	.002
SAMPLES * FEATURES	51.969	18	2.887	.346	.993
Error	701.730	84	8.354		
Total	929360.421	112			

Tanto en el caso de sombras (*Producer accuracy*) como en sombras (*User accuracy*) se vio que la característica más influyente fue el factor *features* ( $F=5.310$  Sig=0.000) siendo el factor *samples* ( $F=0.089$  Sig=0.966) poco influyentes.

Una vez que vemos que las dos variables son significativas, se procede al estudio de las mismas por separado. El objetivo de este estudio es determinar para qué porcentaje de Samples la precisión será la más adecuada, y cuáles serán las mejores Features para una clasificación precisa.

Se realizó para ello el método de separación de medias de Duncan para *samples* (Tabla 19) se vio que para el 10% de muestras había una diferenciación mínima (89.6377) con respecto al resto (5%=90.9828 15%= 91.5944 20%=91.9532) por lo que no se aprecia una gran mejora al coger un determinado porcentaje de muestras con respecto a otro. Cualquier porcentaje parece ser bueno, tanto para user como para producer, a la hora de estudiar la precisión de las sombras.

Tabla 19. Separación de medias de la variable *samples* para la clase “sombras” a un nivel de confianza del 95%

SAMPLES	N	Subconjunto	
		1	2
10	28	89.6377	
5	28	90.9828	90.9828
15	28		91.5944
20	28		91.9532
Significación		.085	.241

Al realizar el método de separación medias de Duncan para las Features (Tabla 20) en sombras se vio que la que la capa 45 *features* produce los mejores resultados ,viendo que por lo computacional se utilizaría cualquiera de las capas que no son significativamente diferentes a los datos obtenidos en 45 *features*, estas son SAVI, CONTRAST, SAVI+BNDVI cualquiera de estas mejoraría la clasificación tanto de sombras (*User accuracy*) como sombras (*Producer accuracy*) en un tiempo menor que el empleado 45 *features*.

Tabla 20. Separación de medias en la variable *features* para la clase “sombras” a un nivel de confianza del 95%.

FEATURES	N	Subconjunto		
		1	2	3
+MDO	16	88.5145		
+SAVI+MDO	16	90.2838	90.2838	
7 FEATURES	16	90.5765	90.5765	
SAVI+BNDVI	16		91.5545	91.5545
+CONTRAST	16		91.7047	91.7047
+SAVI	16		91.7352	91.7352
45 FEATURES	16			92.9250
SIGNIFICACIÓN		.059	.213	.228



A continuación en las Figuras 29 y 30 se muestra una representación grafica de las clases edificios, sombras y vegetación tanto Producer como User accuracy para los conjuntos de capas de características habíamos seleccionado en Villaricos.




Figura 29. Representación grafica de las clases edificios, sombras y vegetación (*Producer accuracy*) para cada conjunto de capas características en Villaricos.




Figura 30. Representación grafica de las clases edificios, sombras y vegetación (*User accuracy*) para cada conjunto de capas características en Villaricos.

#### 4.5.-CLASE CALLES

Se observó que según el grado de significación en calles (Tabla 21), el factor más importante fue *features* (F=15.874 Sig=0.000) siendo menos significativo el factor *samples* (F=5.004 Sig=0.003) y no siendo relativamente significativas la combinación de ambos factores al mismo tiempo (F=0.367 Sig=0.990). Ya que el estudio se ha realizado a un nivel de confianza del 95%, para que una dato sea significativo, *p* debe estar por debajo de 0.05 ( $p < 0.05$ ).

Para calles user igual que en calles producer se vio que la característica más influyente fueron las Features (F=3.283 Sig=0.006) siendo las Samples (F=0.824 Sig=0.484) poco influyentes y ambas no influyentes (F=0.337 Sig=0.994).

Tabla 21. ANOVA para la clase “calles” (*Producer accuracy*).

Fuente	Suma de cuadrados	gl	Media cuadrática	F	Significación
Modelo	362476.847(a)	28	12945.602	85.956	.000
SAMPLES	2261.127	3	753.709	5.004	.003
FEATURES	14344.091	6	2390.682	15.874	.000
SAMPLES * FEATURES	995.962	18	55.331	.367	.990
Error	12651.052	84	150.608		
Total	375127.899	112			

Una vez que vemos que las dos variables son significativas, se procede al estudio de las mismas por separado. El objetivo de este estudio es determinar para qué porcentaje de samples la precisión será el más adecuado y cuáles serán las mejores Features para una clasificación precisa.

Tabla 22. Separación de medias de la variable *samples* para la clase “calles” (*Producer accuracy*) a un nivel de confianza del 95%.

SAMPLES	N	Subconjunto	
		1	2
5	28	49.4084	
10	28	55.1598	
15	28	55.3008	
20	28		62.0948
Significación		.093	1.000

Al realizar el método de las medias de Duncan para *samples* (Tabla 22) se vio que encalles (*producer accuracy*) en el 20% de muestras había una diferenciación (62.0948) con respecto al resto (5%=49.4084 10%= 55.1598 15%=55.3008) .Con respecto a calles (*User accuracy*) no se encuentra una diferencia aparente entre los porcentajes por

lo que cualquiera parece ser bueno para la precisión (5%=64.2384 10%= 59.5308 15%=60.9916 20%=62.1686).

Tabla 23. Separación de medias de la variable *features* para la clase “calles” a un nivel de confianza del 95%.

FEATURES	N	Subconjunto		
		1	2	3
45 FEATURES	16	39.2769		
7 FEATURES	16		49.2735	
+CONTRAST	16		51.2131	
SAVI+BNDVI	16		51.8364	
+SAVI	16		52.5618	
+SAVI+MDO	16			71.6371
+MDO	16			72.6379
SIGNIFICACIÓN		1.000	.497	.818

Al realizar la separación de medias utilizando el método de Duncan para *features* (Tabla 23), en calles se vio que MDO mejora la clasificación de calles Producer y User, viendo que SAVI+MDO obtienen buenos resultados en calles (*producer accuracy*) no siendo significativamente mejor que SAVI y SAVI+BNDVI cuando de calles (*User accuracy*) hablamos.

#### 4.6.-CLASE CARRETERAS

Al analizar los resultados obtenidos mediante ANOVA aplicado a la clase carreteras (Tabla 24) obtenemos que el factor *features* tiene una relevancia significativa en el análisis no teniendo importancia significativa el factor *samples* cuando de carreteras (*producer accuracy*) hablamos. Cosa que en carreteras (*User accuracy*) no pasa siendo el factor *samples* el más significativo de los dos factores. *Samples* (F=5.252 Sig=0.002) *Features* (F=1.866 Sig=0.096).

Tabla 24. ANOVA para la clase “carreteras” (*Producer accuracy*).

Fuente	Suma cuadrados	gl	Media cuadrática	F	Significación
Modelo	477693.544(a)	28	17060.484	136.736	.000
SAMPLES	115.558	3	38.519	.309	.819
FEATURES	3816.660	6	636.110	5.098	.000
SAMPLES * FEATURES	1228.576	18	68.254	.547	.926
Error	10480.671	84	124.770		
Total	488174.215	112			

Se realizó para ello el método de separación de medias de Duncan para *samples* (Tabla 25), en carreteras se vio que no había una diferenciación entre ellas (10%=63.3016 20%= 65.0261 15%=65.4779 5%= 66.0109).

Tabla 25. Separación de medias de la variable *samples* para la clase “carreteras” a un nivel de confianza del 95%.

SAMPLES	N	Subconjunto
		1
10	28	63.3016
20	28	65.0261
15	28	65.4779
5	28	66.0109
Significación		.416

Al ver los resultados obtenidos por el método de separación de medias de Duncan para las *Features* (Tabla 26) vemos que las features que dieron mejores resultados al clasificar carreteras, tanto precisión de usuario (*user*) como de productor (*producer*) fue SAVI+BNDVI. Cosa que se prevé lógica ya que BNDVI es una capa fundamental a la hora de detectar carreteras.

Tabla 26. Separación de medias de la variable *features* para la clase “carreteras” a un nivel de confianza del 95%.

FEATURES	N	Subconjunto			
		1	2	3	4
+MDO	16	54.3283			
+SAVI+MDO	16	60.2787	60.2787		
+CONTRAST	16		63.1113	63.1113	
7 FEATURES	16		65.0314	65.0314	65.0314
45 FEATURES	16			69.3104	69.3104
+SAVI	16			70.7555	70.7555
SAVI+BNDVI	16				71.8635
SIGNIFICACIÓN		.136	.261	.080	.118

#### 4.7.- CLASE SUELO DESNUDO

Por último analizaremos lo obtenido mediante el software estadístico ANOVA (Tabla 27) aplicado a la clase suelo desnudo viendo que las *Features* ( $F=5.953$   $Sig=0.000$ ) tienen una relevancia significativa en el análisis al igual que las *Samples* ( $F=2.970$   $Sig=0.036$ ) cuando de suelo desnudo producir hablamos. Cosa que en suelo desnudo *user* pasa pero no siendo muy importante las *Samples* ( $F=0.686$   $Sig=0.563$ ) *Features* ( $F=2.944$   $Sig=0.012$ ).

Tabla 27. ANOVA para la clase “suelo desnudo” (*Producer Accuracy*).

Fuente	Suma cuadrados	gl	Media cuadrática	F	Significación
Modelo	206233.580(a)	28	7365.485	59.231	.000
SAMPLES	1107.841	3	369.280	2.970	.036
FEATURES	4441.680	6	740.280	5.953	.000
SAMPLES * FEATURES	794.953	18	44.164	.355	.992
Error	10445.609	84	124.352		
Total	216679.189	112			

Tras esto se llevo a cabo el método de separación de medias de Duncan para *samples* (Tabla 28) en suelo desnudo (*producer accuracy*) el 10% de muestras había una diferenciación (62.0948) con respecto a (5%=37.9565) y de estas dos con respecto a (15%=41.8992 20%=42.2949) siendo no significativamente diferentes estas dos últimas entre sí. Con respecto a suelo desnudo (*User accuracy*) no se encuentra una diferencia aparente entre los porcentajes por lo que cualquiera de los porcentajes de *samples* parece ser bueno para la precisión (5%=46.7746 10%= 48.6736 15%=49.7548 20%=50.1708).

Tabla 28. Separación de medias en la variable *samples* para la clase” suelo desnudo” a un nivel de confianza del 95%.

SAMPLES	N	Subconjunto	
		1	2
5	28	37.9565	
15	28	41.8992	41.8992
20	28	42.2949	42.2949
10	28		46.8333
Significación		.174	.122

Al ver los resultados obtenidos por el método de separación de medias de Duncan para *features* (Tabla 29) en suelo desnudo (*producer accuracy*) como mejora significativamente cuando usamos CONTRASTE, SAVI+MDO, 45 *features*, a la hora de operar por el tiempo sería más conveniente el uso de CONTRASTE o del SAVI+MDO. Esto sucede al analizar los datos de suelo desnudo (*User accuracy*), al observar los datos correspondientes este, se aprecia como mejorarían CONTRASTE, SAVI+BNDVI, SAVI, 45 FEATURES sin tener mejoras significativas al usar cualquiera de estos.

Tabla 29. Separación de medias en la variable *features* para la clase "suelo desnudo" a un nivel de confianza del 95%.

FEATURES	N	Subconjunto	
		1	2
+SAVI	16	34.8199	
SAVI+BNDVI	16	35.0642	
7 FEATURES	16	36.1370	
+MDO	16	43.3044	43.3044
+CONTRASTE	16		47.6525
+SAVI+MDO	16		48.4631
45 FEATURES	16		50.2807
SIGNIFICACIÓN		.051	.110

A continuación en las Figuras 31 y 32 se muestra una representación grafica de las clases calles, carreteras y suelo desnudo tanto Producer como User accuracy para los conjuntos de capas de características que habíamos seleccionada en Villaricos.




Figura 31. Representación grafica de las clases calles, carreteras, suelo desnudo (*Producer accuracy*) para cada conjunto de capas características en Villaricos.




Figura 32. Representación grafica de las clases calles, carreteras, suelo desnudo (*User accuracy*) para cada conjunto de capas características en Villaricos.

Podemos observar al analizar las graficas que componen las Figuras 29, 30, 31 y 32 como el MDO es fundamental para la detección de edificios y calles. Realmente sin MDO seguramente se confundirían edificios y calles por su información espectral siendo el MDO el que los consigue distinguir.

## CASO DE EL BOSQUE

### 4.8.-OVERALL ACCURACY EN EL BOSQUE

Como se muestra en la Tabla 30, en la precisión global (*overall accuracy*) obtenida para cada conjunto de características ensayados. Cuando usamos las 7 *features* básicas más MDO (87.5 %) o más MDO y SAVI (88%) es cuando se obtienen los resultados de clasificación más precisos a nivel global. Usando sólo las 7 *features* básicas (78.3%) o cuando a estas le añadimos el SAVI (78.5%), los resultados empeoraron casi 10 puntos porcentuales.

Como se muestra en la Fig. 33, al utilizar el conjunto de características MDO+SAVI obtenemos la mejor precisión en la clasificación (un 88%). Como veremos en las Tablas 31 y 32, el empleo del MDO provocó una mejora espectacular de la clasificación de los invernaderos, en color gris en la Fig. 33, de entre 30 y 40 puntos porcentuales respecto a la clasificación con 7 *features* básicas o con 7 *features* básicas más SAVI.

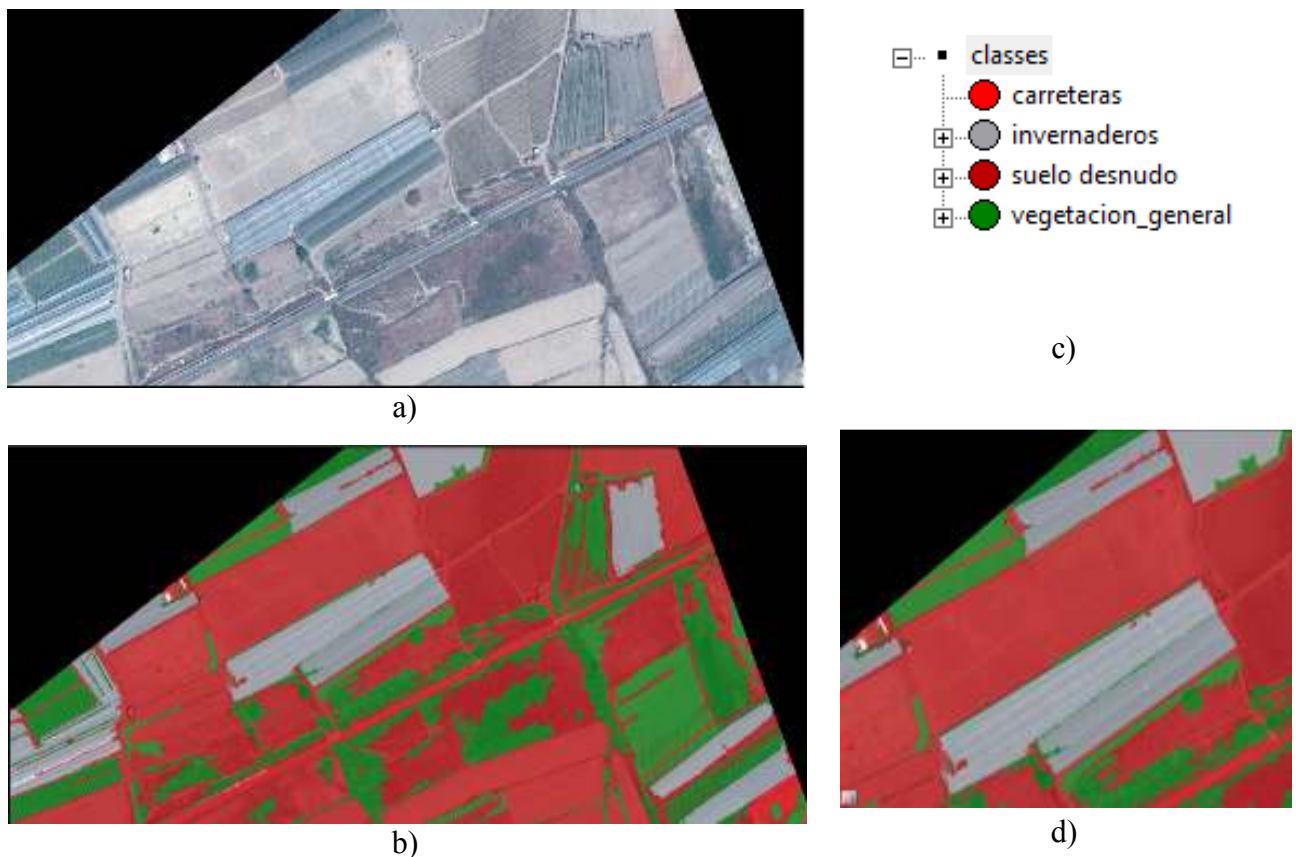


Figura 33. Resultado de la clasificación utilizando configuración MDO+SAVI. a) Imagen pancharpened, b) Clasificación obtenida para El Bosque al utilizar MDO+SAVI, c) Código de colores de las clases, y d) Detalle clasificación de edificios.



Tabla 30. Precisión global (*Overall Accuracy*) utilizando un 10% de muestras para cada conjunto de características en El Bosque.

<b>Características</b>	<b>Overall accuracy (%)</b>
7 FEATURES	78.3
SAVI	78.5
MDO	87.5
MDO + SAVI	88.0

#### **4.9.-CLASES EN EL BOSQUE**

Las precisiones obtenidas por el productor (*producer accuracy*) y el usuario (*user accuracy*) se muestran en las Tablas 31 y 32, para los distintos conjuntos de *features* empleados para la clasificación de las cuatro clases globales (carreteras, invernaderos, vegetación, suelo desnudo) seleccionadas en El Bosque.

El uso del MDO como característica de clasificación consiguió mejorar de forma extraordinaria la clasificación de invernaderos, situándola en unos niveles del 96% de acierto para la precisión por comisión (*producer accuracy*) y llegando al 99% en precisión por omisión (*user accuracy*). El MDO también se mostró efectivo para diferenciar la clase “suelo desnudo”, elevando las precisiones de clasificación en esta clase hasta el 85% (*producer accuracy*) y 96% (*user accuracy*) respectivamente.

La inclusión del MDO para la detección de edificios ha sido reportada ya por muchos autores como fundamental (Hermosilla *et al.*, 2010; Turker y San, 2010; Longbotham *et al.*, in press). Sin embargo, el hallazgo de su posible uso para detección de invernaderos en comarcas como la almeriense, abre una nueva puerta de investigación.

Tabla 31. *Producer Accuracy* de las clases para cada una de los conjuntos de features en El Bosque.

	<b>Carreteras (%)</b>	<b>Invernaderos (%)</b>	<b>Vegetación (%)</b>	<b>Suelo desnudo (%)</b>
<b>7 FEATURES</b>	91.0	60.0	85.0	81.0
<b>SAVI</b>	91.0	56.0	86.0	82.0
<b>MDO</b>	91.0	<b>96.0</b>	88.0	85.0
<b>MDO + SAVI</b>	91.0	<b>96.0</b>	89.0	85.0

Tabla 32. *User Accuracy* de las clases para cada uno de los conjuntos de features.

	<b>Carreteras (%)</b>	<b>Invernaderos (%)</b>	<b>Vegetación (%)</b>	<b>Suelo desnudo (%)</b>
<b>7 FEATURES</b>	59.0	53.0	80.0	56.0
<b>SAVI</b>	58.0	62.0	65.0	90.0
<b>MDO</b>	63.0	<b>99.0</b>	64.0	<b>96.0</b>
<b>MDO + SAVI</b>	62.0	<b>99.0</b>	64.0	<b>96.0</b>

# **CAPÍTULO 5**

## **CONCLUSIONES GENERALES**

## **5.- CONCLUSIONES GENERALES**

Las principales conclusiones a las que se ha llegado tras el desarrollo de este proyecto son, para el caso de estudio de la zona urbana de Villaricos:

- El porcentaje de muestras de entrenamiento necesarias, con el cual se obtiene una mayor precisión en la clasificación de clases realizadas mediante el clasificador de eCognition<sup>®</sup>, Nearest Neighbor, estaría representado por el 10% para cada clase.
- En el caso de la zona urbana de Villaricos, se obtuvo una precisión global (*overall accuracy*) del 74.3% con 7 características básicas, el 75.6% con la adición del contraste, un 75.9% con 7 características básicas además del MDO, un 77,2 % con 7 características básicas y SAVI, 77.4% con 7 características básicas más el SAVI y BNDVI, el 79.2 % con 45 características, y finalmente, la que mejoró la precisión en la clasificación fue, con una precisión del 79.4%, las 7 características básicas más el SAVI y MDO.
- La característica más importante para la detección de edificios en zonas urbanas fue el uso del MDO, con el cual se obtuvieron precisiones cercanas al 95%.
- En la clase vegetación, fue el SAVI la característica más significativa obteniéndose un 88.4% al utilizarla dentro del set de 45 características, y un 81.1% al utilizar las 7 características básicas más el SAVI.
- Se observó también como características como SAVI más BNDVI mejoran significativamente la detección de carreteras.
- Por último en esta zona 1 se vio como al utilizar 45 características hacían que la precisión en la clasificación mejorase en la mayoría de las clases pero siendo muy pesado para el software, viéndose condicionada por la gran inversión de tiempo de computación.

Para la segunda zona de estudio de este monográfico, la zona agrícola de El Bosque, en la que existen varios invernaderos, las conclusiones fueron las siguientes:

- En el caso de El Bosque, se obtuvo una precisión global (*overall accuracy*) del 78.3% con 7 características básicas, un 78.5% con 7 características básicas además del SAVI, un 87.5 % con 7 características básicas y MDO, y finalmente, la que mejoró la precisión en la clasificación fue, con una precisión del 88%, las 7 características básicas más el SAVI y MDO.
- En esta zona agrícola se concluyó que las features capaces de mejorar la precisión en la clasificación, dentro del porcentaje de muestras seleccionado en esta zona para el entrenamiento del clasificador (10%), fue el conjunto de características formado por MDO+SAVI los que fueron capaces de mejorar la precisión. Esto se preveía lógico ya que el MDO se encargará de detectar las alturas de los invernaderos y demás objetos con altura y el SAVI de detectar las zonas con vegetación haciendo una diferenciación entre invernaderos-terreno y entre estos y los demás componentes de la zona.

# CAPÍTULO 6

## FUTUROS TRABAJOS

## **6.- FUTUROS TRABAJOS**

- Comparación de la precisión de la clasificación de ortoimágenes satélite realizada mediante eCognition® con otros nuevos clasificadores, como por ejemplo Support Vector Machines.
- Comparación de ortoimágenes aéreas y de satélite, para determinar con cual se obtiene mejores resultados de clasificación en eCognition®.
- Estudio para determinar cuál es la escala y los parámetros de forma y compactación que permite una segmentación óptima, que finalmente mejore los resultados de clasificación en eCognition®.
- Mejora del conjunto de *features* utilizadas para la clasificación supervisada
- Estudio comparativo mediante la misma clasificación realizada en este proyecto a otras zonas urbanas o agrícolas, para observar la variación de la utilización de la superficie del suelo.
- Posibilidad de la inclusión de nuevas bandas que aportan satélites como WorldView-2 para la mejora de la segmentación y clasificación automática basada en objetos.
- La inclusión del MDO para la detección de edificios ha sido reportada ya por muchos autores como fundamental (Hermosilla *et al.*, 2010; Turker y San, 2010; Longbotham *et al.*, in press). Sin embargo, el hallazgo de su posible uso para detección de invernaderos en comarcas como la almeriense, abre una nueva puerta de investigación.

# **CAPÍTULO 7**

## **BIBLIOGRAFÍA**

## **7.- REFERENCIAS BIBLIOGRÁFICAS**

- Aguilar, M.A., Aguilar, F.J., Carvajal, F., Agüera, F., Estrada, L., 2006b. Geometric accuracy of Ikonos Geo Panchromatic Orthoimage Products. *Revue française de photogrammétrie et de télédétection*, 184: 5-10.
- Aguilar, F.J., Carvajal, F., Aguilar, M.A., Agüera, F., 2007a. Developing digital cartography in rural planning applications. *Computers and Electronics in Agriculture*, 55(2): 89-106.
- Aguilar, M.A., Aguilar, F.J., Carvajal, F., Agüera, F., 2007b. Comparison of two commercial solutions for generating DSMs from QuickBird stereo imagery. 2007 Annual Conference of the Remote Sensing & Photogrammetry Society (RSPSoc2007). September 2007, NewCastle, U.K., unpaginated CD ROM.
- Aguilar, M.A.; Aguilar, F.J.; Saldaña, M.M.; Fernández, I., (*In Press*). Geopositioning accuracy assessment of GeoEye-1 Panchromatic and Multispectral imagery.
- Aguilar, M.A.; Aguilar, F.J.; Fernández, A.; Fernández, I.; Saldaña, M.M.; García Lorca, A.M.; Negreiros, J.G.; Viciano, A.; González, E., 2011. Geometric processing of GeoEye-1 satellite imagery for coastal mapping applications. *Proceedings of the IMProVe (International Conference on Innovative Methods in Product Design)*, June 15th – 17th, 2011, Venice, Italy.
- Agüera, F., Aguilar, M.A., Aguilar, F.J., 2006. Detecting greenhouses changes from QuickBird imagery on the Mediterranean coast. *Internacional Journal of Remote Sensing*, 27(21): 4751-4767.
- Agüera, F., Aguilar, F.J., Aguilar, M.A., 2008. Using texture analysis to improve per-pixel classification of very high resolution images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(6): 635-646
- Al-Khudhairy, D.H.A., Caravaggi, I., Giada, S., 2005. Structural Damage Assessments from Ikonos Data Using Change Detection, Object-Oriented Segmentation, and Classification Techniques. *Photogrammetric Engineering and Remote Sensing*, 71(7): 825-837.
- Carleer, A.P., & E. Wolff, 2006. Region-based classification potential for land-cover classification with very high spatial resolution satellite data, In *Proceedings of 1st International Conference on Object-based Image Analysis (OBIA 2006)*, Salzburg University, Austria, July 4-5, 2006. Vol. XXXVI, ISSN 1682 1777.
- Castillejo-González, I.L., García-Castillo, R., García-Ferrer, A., Sánchez de la Orden, M., López-Granados, F., 2009. Grado de influencia de las variables espectrales y de forma en la detección de olivos mediante técnicas basadas en objetos. XIII Congreso de la Asociación Española de Teledetección, Calatayud.
- Chmiel, J., Kay, S., Spruyt, P., 2004. Orthorectification and geometric quality assessment of very high spatial resolution satellite imagery for Common Agricultural Policy purposes. *Proceeding of the XXth International Archives of the Photogrammetry*
- Consejería De Medio Ambiente, 2005. El Informe de Medio Ambiente en Andalucía 2004 de la Consejería de Medio Ambiente de la Junta de Andalucía y realizado desde



la Dirección General de Participación e Información Ambiental. Disponible en: <http://www.juntadeandalucia.es/medioambiente/> (último acceso 4 de Noviembre de 2009).

J. Croft, 2008. Prodigious Mapping Capabilities, Spatial resolution and Geo-location ability, GeoEye's next-generation Imaging Satellite. *GeoInformatics*, 4 (2008) pp 18-23.

Davis, C.H., & X. Wang, 2003. Planimetric accuracy of Ikonos 1m panchromatic orthoimage products and their utility for local government GIS basemap applications, *International Journal of Remote Sensing*, 24(22), 4267–4288.

Definiens eCognition, 2009. Definiens eCognition Developer 8 Reference Book. Definiens AG, München, Germany.

DigitalGlobe, Inc., 2009. The Benefits of the 8 Spectral Bands of WorldView-2. Disponible en: [http://worldview2.digitalglobe.com/docs/WorldView-2\\_8-Band\\_Applications\\_Whitepaper.pdf](http://worldview2.digitalglobe.com/docs/WorldView-2_8-Band_Applications_Whitepaper.pdf)

Fraser, C.S., 2002. Prospect for mapping from high-resolution satellite imagery. The 23rd Asian Conference on Remote Sensing (ACRS 2002), 25-29 November 2002, Kathmandu, Nepal, unpaginated CD ROM.

Fraser, C. S., Baltsavias, E., Gruen, A., 2002a. Processing of Ikonos imagery for submetre 3D positioning and building extration. *ISPRS Journal of Photogrammetry and Remote Sensing*, 56: 177-194.

Fraser, C.S., Ravanbakhsh, M., 2009. Georeferencing Accuracy of GeoEye-1 Imagery. *Photogrammetric Engineering and Remote Sensing*, 75(6): 634-638.

Foody, G.M. y Mathur, A., 2006. The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM. *Remote Sensing of Environment* 103 (2006) 179-189.

Gamba, P., Dell'Acqua, F., Lisini, G., Trianni, G., 2007. Improved VHR urban area mapping exploiting object boundaries. *IEEE Transactions on Geoscience and Remote Sensing*, 45(8): 2676-2682.

Gong, P. y P.J. Howarth, 1990. The use of structural information for improving spatial resolution and classification accuracy land-cover classification accuracies at the rural–urban fringe, *Photogrammetric Engineering and Remote Sensing*, 56, 67–73.

Haralick, R.M., Shanmugam, K., Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3, 610–621.

Hay, G.J. y G. Castilla, 2006. Object-based image analysis: strengths, weaknesses, opportunities and threats (SWOT), In *Proceedings of 1st International Conference on Object-based Image Analysis (OBIA 2006)*, Salzburg University, Austria, July 4-5, 2006. Vol. XXXVI, ISSN 1682-1777.

Hermosilla, T., Ruiz, L.A., Recio, J.A., 2010. Detección automática de edificios mediante imágenes de alta resolución y datos Lidar para la actualización de bases de datos cartográficas en entornos urbanos. Automatic building location using high resolution images and Lidar data for land use/land cover geospatial database updating in urban environments. *Revista de Teledetección*, 34, 89-93.

Hill, R.A., 1999. Image segmentation for humid tropical forest classification in Landsat TM data, *International Journal of Remote Sensing*, 20(5), 1039–1044.

Jin, X., Davis, C.H., 2005. An integrated system for automatic road mapping from high-resolution multi-spectral satellite imagery by information fusion. *Information Fusion*, 6: 257-273.

Johnsson, K., 1994. Segment-based land-use classification from SPOT satellite data, *Photogrammetric Engineering & Remote Sensing*, 60(1), 47–53.

Kay, S., P. Spruyt, K. Alexandrou, 2003. Geometric quality assessment of orthorectified VHR space image data. *Photogrammetric Engineering & Remote Sensing*, 69(5):484–491.

Kim, T., Lee, T. Y., Kim, K. O., 2006. Semiautomatic building line extraction from Ikonos images through monoscopic line analysis. *Photogrammetric Engineering and Remote Sensing*, 72: 541-549.

Kong, C., X. Kai, C. Wu, 2006. Classification and extraction of urban land-use information from high-resolution image based on object multi-features, *Journal of China University of Geosciences*, 17(2), 151-157.

Kux, H.J.H. & C.M.D. Pinho, 2006. Object-oriented analysis of high-resolution satellite images for intra-urban land cover classification: Case study in São José Dos Campos, São Paulo State, Brazil, In *Proceedings of 1<sup>st</sup> International Conference on Object-based Image Analysis (OBIA 2006)*, Salzburg University, Austria, July4-5, 2006. Vol. XXXVI, ISSN 1682-1777.

Latty, R.S., R. Nelson, B. Markham, D. Williams, D. Toll, & J. Irons, 1985. Performance comparison between information extraction techniques using variable spatial resolution data, *Photogrammetric Engineering and Remote Sensing*, 51, 1159–1170.

Lee, S. D., Shan, J., Bethel, J., 2003. Class-guided buildings extraction from Ikonos imagery. *Photogrammetric Engineering and Remote Sensing*, 69(2): 143-150.

Longbotham, N., Chaapel, C., Bleiler, L., Padwick, C., Emery, W.J., Pacifici, F., 2011. Very High Resolution Multiangle Urban Classification Analysis. *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, In Press.

Martin, L.R.G., P.J. Howarth, G. Holder, 1988. Multispectral classification of land use at the rural–urban fringe using SPOT data, *Canadian Journal of Remote Sensing*, 14, 72–79.

Marchesi, A., R. Colombo, & P. Valentini, 2006. Application of high spatial resolution satellite imagery for urban environment mapping, In *Proceedings of 1st International Conference on Object-based Image Analysis (OBIA 2006)*, Salzburg University, Austria, July 4-5, 2006. Vol. XXXVI, ISSN 1682-1777.

Martínez-Casasnovas, J.A., Concepción Ramos, M., Vallés, D., 2009. Análisis de la relación entre las propiedades del suelo, el índice de vigor del cultivo y el rendimiento en un viñedo de la D.O. Costers del Segre (Lleida). XIII Congreso de la Asociación Española de Teledetección, Calatayud.

- Mathieu, R., J. Aryal, & A.K. Chong, 2007. Object-based classification of ikonos imagery for mapping large-scale vegetation communities in urban areas, *Sensors*, 7, 2860-2880.
- Mayunga, S. D., Coleman, D. J., Zang, Y., 2007. A semi-automated approach for extracting buildings from QuickBird imagery applied to informal settlement mapping. *International Journal of Remote Sensing*, 28(10): 2343-2357.
- Mesev, V., 2005. Identification and characterisation of urban bulding patterns using IKONOS imagery and point-based postal data. *Computers, Environment and Urban Systems*, (29): 541-557.
- Nichol, J., Lee, C.M., 2005. Urban vegetation monitoring in Hong Kong using high resolution multispectral images. *International Journal of Remote*, 26(5): 903-918.
- Ojeda, J., Villar, A., 2006. Evolución del suelo urbano/alterado en el litoral de Andalucía. *GeoFocus*, 7: 73-99.
- Pecci, J., F. Cano, y G. Maza, 2004. Generación de una ortoimagen QuickBird del año 2003 de la Comunidad Autónoma de la Región de Murcia: metodología y resultados. XI Congreso Métodos Cuantitativos, Sistemas de Información Geográfica y Teledetección, 20-23 September 2004, Murcia, Spain, pp. 301-312.
- Pu, R., Landry, S., Yu, Q., 2011. Object-based urban detailed land cover classification with high spatial resolution IKONOS imagery. *International Journal of Remote Sensing*, Vol. 32, No. 12, 20 June 2011, 3285–3308.
- Requejo, J., 2001. La segunda residencia lanza una OPA sobre el litoral andaluz. Una grave amenaza sobre el modelo de ordenación territorial para el litoral. In III Congreso Internacional de Ordenación del Territorio. Asociación Fundicot, Madrid, España, 2001.
- Ridley, H., Atkinson, P., Aplin, P., Muller, J.P., Dowman, I., 1997. Evaluating the potential of the forthcoming commercial U.S. high-resolution satellite sensor imagery at the Ordnance Survey. *Photogrammetric Engineering and Remote Sensing*, 63(8): 997-1005.
- Ruther,H., Hagai, M.M., Mtaló, E. G., 2002, Application of snakes and dynamic programming optimization in modeling of buildings in informal settlement areas. *ISPRS journal of Photogrammetry and remote sensing*, 56, 269-282.
- Shackelford, A.K. & C.H. Davis, 2003. A combined fuzzy pixel-based and object based approach for classification of high-resolution multispectral data over urban areas, *IEEE Transactions on Geoscience and Remote Sensing*, 41(10), 2354–2363.
- Trabajo Fin de Máster (Máster en Representación y Diseño en Ingeniería y Arquitectura) presentado en Julio de 2011 por M<sup>a</sup> del Mar Saldaña Díaz y dirigido por Manuel Ángel Aguilar y Fernando José Aguilar, titulado: Generación de datos georreferenciados de alta resolución a partir de imágenes de GeoEye-1.
- Treitz, P. y P.J. Howarth, 2000. High spatial resolution remote sensing data for forest ecosystem classification: An examination of spatial scale, *Remote Sensing of Environment*, 72, 268–289.
- Ton, J.C., J. Sticklen, & A.K. Jain, 1991. Knowledge-based segmentation of landsat images, *IEEE Transactions on Geoscience and Remote Sensing*, 29(2), 222–232.

Toutin, T., 2004a. Review article: Geometric processing of remote sensing images: models, algorithms and methods, *International Journal of Remote Sensing*, 25(10): 1893-1924.

Toutin, T., 2006. Comparison of 3D Physical and empirical models for generating DSMs from stereo HR images. *Photogrammetric Engineering and Remote Sensing*, 72(5): 597-604.

Townshend, J., & Justice, J. (1981). Information extraction from remotely sensed data, a user view, *International Journal of Remote Sensing*, 2, 313–329.

Turker, M. y San, K., 2010. Building detection from pan-sharpened Ikonos imagery through support vector machines classification. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science*, Volume XXXVIII, Part 8, Kyoto Japan 2010.

Viciana, A., 2007. La costa de Almería: Desarrollo socioeconómico y degradación físico-ambiental (1957-2007). *Paralelo 37*, 19, 149-183

Weber, C., Ranchin, T., 2003. Extraction of urban features in Strasbourg, France: Comparison of two fusion algorithms for Quickbird MS and Pan data. 2nd GRSS/ISPRS Joint Workshop on “Data Fusion and Remote Sensing over Urban Areas”.

Yan, D., Zhao, Z., 2003. Road Detection from Quickbird Fused Image Using HIS Transform and Morphology. 2nd GRSS/ISPRS Joint Workshop on “Data Fusion and Remote Sensing over Urban Areas”.

Yu, Q., P. Gong, N. Clinton, G. Biging, M. Kelly, & D. Schirokauer., 2006. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery, *Photogrammetric Engineering and Remote Sensing*, 72(7), 799-811.

Zoido, F., Morales, G., Mas, R., De La Vega, S., Lois, R., 2000. *Diccionario de Geografía Urbana, Urbanismo y Ordenación del Territorio*. Barcelona, Editorial Ariel. 407 p.