



UNIVERSIDAD DE ALMERÍA

ESCUELA POLITÉCNICA SUPERIOR

TITULACIÓN DE INGENIERÍA TÉCNICA AGRÍCOLA  
ESPECIALIDAD MECANIZACIÓN Y CONSTRUCCIONES RURALES

INTEGRACIÓN DE DATOS GEOESPACIALES PARA EL SEGUIMIENTO  
DEL SELLADO SUPERFICIAL DE ZONAS COSTERAS MEDIANTE  
TÉCNICAS DE ANÁLISIS DE IMÁGENES DIGITALES BASADAS EN  
OBJETOS (OBIA)

ALUMNO:

FELIPE FLORES IMBERNÓN

DIRECTORES:

D. FERNANDO JOSÉ AGUILAR TORRES

D. ISMAEL FERNANDEZ LUQUE

ALMERÍA, JULIO DE 2011

## INDICE

<b>0. RESUMEN.....</b>	<b>Pág 7-10</b>
<b>1. INTRODUCCIÓN.....</b>	<b>Pág11-27</b>
1.1 FUENTES DE INFORMACIÓN GEORREFERENCIADA.....	Pág 14-19
1.1.1 IMÁGENES AÉREAS.....	Pág 14-15
1.1.2 MODELOS DIGITALES DE ELEVACIONES.....	Pág 16-18
1.1.3 CLASIFICACIÓN DE IMÁGENES DIGITALES.....	Pág 19
1.2. EXTRACCIÓN DE INFORMACIÓN A PARTIR DE LOS DATOS MULTIFUENTE...Pág	19-27
1.2.1. CLASIFICACIÓN POR PÍXELES VS CLASIFICACIÓN POR OBJETOS (OBIA)...Pág	19-20
1.2.2. TÉCNICAS DE CLASIFICACIÓN.....	Pág 20-21
1.2.3 PROCESO DE SEGMENTACIÓN EN LA CLASIFICACIÓN OBIA.....	Pág 21-27
<i>1.2.3.1. LA SEGMENTACIÓN MULTIRRESOLUCIÓN.....</i>	<i>Pág 22-27</i>
<b>2. INTERÉS Y OBJETIVOS. ....</b>	<b>Pág 28-30</b>
2.1. INTERÉS.....	Pág 29-30
2.2. OBJETIVOS. ....	Pág 30
<b>3. MATERIALES Y MÉTODOS.....</b>	<b>Pág 31-65</b>
3.1. DESCRIPCIÓN DEL ÁREA DE TRABAJO.....	Pág 32-34
3.2. MATERIALES EMPLEADOS.....	Pág 34-39
3.2.1. DIVISIÓN DE LAS ORTOIMÁGENES POR HOJAS.....	Pág 34-35
3.2.2. ORTOIMÁGENES RGB+NIR DE ALTA RESOLUCIÓN.....	Pág 35-36
3.2.3. DATOS ALTIMÉTRICOS LIDAR. PRODUCTOS DERIVADOS.....	Pág 36-38
3.2.4. DATOS CATASTRALES USADOS PARA LA OBTENCIÓN DEL <i>GROUND TRUTH</i> .....	Pág 38-39
3.3. METODOLOGÍA.....	Pág 40-63
3.3.1. METODOLOGÍA PARA LA SEGMENTACIÓN Y CLASIFICACIÓN DE IMÁGENES BASADA EN OBJETOS.....	Pág 40-55
3.3.2. METODOLOGÍA PARA LA GENERACIÓN DEL “ <i>GROUND TRUTH</i> ”.....	Pág 55-63
<i>3.3.2.1. METODOLOGÍA PARA LA DIGITALIZACIÓN MANUAL DE CLASES Y GENERACIÓN DEL “GROUND TRUTH” . ....</i>	<i>Pág 57-62</i>

3.3.2.2. METODOLOGÍA PARA LA GENERACIÓN DEL “GROUND TRUTH” A PARTIR DE MUESTRAS ALEATORIAS.....	Pág 62-63
3.3.3. METODOLOGÍA PARA LA OBTENCIÓN DEL ACIERTO GLOBAL, DE LA FIABILIDAD DEL PRODUCTOR Y DE LA FIABILIDAD DEL USUARIO MEDIANTE <i>ECOGNITION</i> ®.....	Pág 63-64
3.3.4. METODOLOGÍA PARA LA REPRESENTACIÓN PARCELARIA DEL PORCENTAJE DE IMPERMEABILIDAD.....	Pág 65
<b>4. RESULTADOS Y DISCUSIÓN.....</b>	<b>Pág 66-82</b>
4.1. NIVELES DE SEGMENTACIÓN. ....	Pág 67-68
4.2. RESULTADOS DE UMBRALES POR CLASIFICACIÓN.....	Pág 68-76
4.2.1 CLASIFICACIÓN <i>MAR-TIERRA</i> . ....	Pág 71
4.2.2. CLASIFICACIÓN <i>OBJETOS-NO OBJETOS</i> . ....	Pág 72
4.2.3. CLASIFICACIÓN <i>OBJETOS_SOMBRAS</i> Y <i>OBJETOS_NO SOMBRAS</i> .....	Pág 72-73
4.2.4. CLASIFICACIÓN <i>EDIFICIOS</i> Y <i>ÁRBOLES</i> .....	Pág 73
4.2.5. CLASIFICACIÓN <i>OBJETOS_SOMBRAS</i> EN <i>EDIFICIOS</i> Y <i>ÁRBOLES</i> .....	Pág 74
4.2.6. CLASIFICACIÓN <i>URBANO</i> Y <i>NO URBANO</i> .....	Pág 74
4.2.7. CLASIFICACIÓN <i>PLAYA</i> .....	Pág 75
4.2.8. CLASIFICACIÓN <i>ZONA DE PUERTOS</i> .....	Pág 75
4.2.9 CLASIFICACIÓN <i>IMPERMEABLE</i> Y <i>PERMEABLE</i> .....	Pág 76
4.3 RESULTADOS DEL <i>ACCURACY ASSESSMENT</i> .....	Pág 76-81
4.3.1 RESULTADOS PARA LA DIGITALIZACIÓN MANUAL DE CLASES Y GENERACIÓN DEL “GROUND TRUTH”.....	Pág 76-77
4.3.2 RESULTADOS DE LA CLASIFICACIÓN MEDIANTE UN NÚMERO DE MUESTRAS DETERMINADAS.....	Pág 77-81
4.4. <i>RESULTADOS OBTENIDOS DE IMPERMEABILIDAD PARA LA ZONA PILOTO</i> .....	Pág 81-82
<b>5. CONCLUSIONES GENERALES.....</b>	<b>Pág 83-84</b>
<b>6. FUTUROS TRABAJOS.....</b>	<b>Pág 85-86</b>
<b>7. REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>Pág 87-91</b>

## INDICE DE FIGURAS

- Figura 1.** Esquema del flujo de trabajo llevado a cabo para la clasificación y subclasificación de los objetos. Los recuadros redondeados verdes corresponden a cada una de las segmentaciones llevadas a cabo. Por otro lado, los recuadros azules representan cada una de las clases-subclases, mientras que los círculos anaranjados corresponden a las súperclases finales. ....Pág 9
- Figura 2.** Mapa de inundaciones de la zona de la costa Vera (Almería) ante dos hipotéticos escenarios de incremento de nivel del mar (SLR: “Sea Level Rise”) como consecuencia del cambio climático. Izquierda tenemos SLR = + 3 m. y derecha SLR = + 1 m. ....Pág 12
- Figura 3.** Presión antrópica sobre la línea de costa debido, entre otros motivos, a la proliferación no planificada de urbanizaciones e infraestructuras litorales. ....Pág 13
- Figura 4.** Representación del terreno mediante Modelos Digitales de Elevaciones (MDEs). ....Pág 16
- Figura 5.** 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.....Pág 17
- Figura 6.** Componentes de un sensor LiDAR aerotransportado.....Pág 18
- Figura 7.** Procedimiento general para la clasificación de una imagen multiespectral mediante técnicas de clasificación supervisada.. ....Pág 19
- Figura 8.a)** Imagen original b) Resultado de la segmentación multirresolución con escala 500 c) Resultado de la segmentación multirresolución con escala 200 d) Resultado de la segmentación multirresolución con escala 50, para todas estas segmentaciones la forma ha sido 0,1 y la compacidad de 0,5. ....Pág 23
- Figura 9.** Cada objeto de la imagen utiliza el criterio de homogeneidad para determinar el mejor vecino para fusionarse con este. ....Pág 24
- Figura 10.** Si el mejor vecino del objeto primera imagen (rojo) no reconoce el objeto de la primera imagen (gris) de la mejor manera vecino, el algoritmo se mueve (flecha roja) con el objeto de la segunda imagen para encontrar el mejor vecino. ....Pág 24
- Figura 11.** Esta rama a rama de salto se repite hasta que encuentra los mejores vecinos asociados. ....Pág 25
- Figura 12.** Si la homogeneidad del objeto de la nueva imagen no supere el parámetro de escala, la pareja dos objetos de la imagen se fusionan.....Pág 25
- Figura 13.** Localización de la zona de estudio. ....Pág 32
- Figura 14.** Emplazamiento de estudio. ....Pág 33

<b>Figura 15.</b> Sismología en la zona de estudio. ....	<b>Pág 34</b>
<b>Figura 16.</b> Vuelo del estudio. ....	<b>Pág 35</b>
<b>Figura 17.</b> División de las ortoimágenes en partes en la zona utilizada para este proyecto. ....	<b>Pág 36</b>
<b>Figura 18.</b> Distribución de las pasadas LiDAR sobre la zona de estudio (marco en rojo). ....	<b>Pág 37</b>
<b>Figura 19.</b> Representación, de arriba abajo, de MDS, MDT y MDO respectivamente. ....	<b>Pág 38</b>
<b>Figura 20.</b> Capas en AutoCAD.....	<b>Pág 39</b>
<b>Figura 21.</b> Mala digitalización manual.....	<b>Pág 39</b>
<b>Figura 22.</b> Esquema del flujo de trabajo llevado a cabo para la clasificación y subclasificación de los objetos. Los recuadros redondeados verdes corresponden a cada una de las segmentaciones llevadas a cabo. Por otro lado, los recuadros azules representan cada una de las clases-subclases, mientras que los círculos anaranjados corresponden a las súperclases finales. ....	<b>Pág 41</b>
<b>Figura 23.</b> Importación de datos.....	<b>Pág 42</b>
<b>Figura 24.</b> Asignación de valores sin datos. ....	<b>Pág 42</b>
<b>Figura 25.</b> Ejemplo Segmentación escala 600.....	<b>Pág 43</b>
<b>Figura 26.</b> Antes y después de la reclasificación.....	<b>Pág 45</b>
<b>Figura 27.</b> Ejemplo Segmentación escala 50. ....	<b>Pág 46</b>
<b>Figura 28.</b> Clasificación de Objetos y No Objetos.....	<b>Pág 47</b>
<b>Figura 29.</b> Clasificación Objetos_Sombras y Objetos_No sombras.....	<b>Pág 48</b>
<b>Figura 30.</b> Reclasificación de edificios.....	<b>Pág 49</b>
<b>Figura 31.</b> Ejemplo Segmentación escala 200.....	<b>Pág 50</b>
<b>Figura 32.</b> Clasificación Urbano-No Urbano.....	<b>Pág 51</b>
<b>Figura 33.</b> Ejemplo de segmentación en escala 300. ....	<b>Pág 52</b>
<b>Figura 34.</b> Ejemplo de clasificación de Playa. ....	<b>Pág 53</b>
<b>Figura 35.</b> Clasificación de Zona de puertos.....	<b>Pág 54</b>
<b>Figura 36.</b> Resultado clasificación final de la ortofotografía 2.2.....	<b>Pág 55</b>
<b>Figura 37.</b> Error provocado por la abstracción en la digitalización manual de grupos de árboles. ....	<b>Pág 56</b>
<b>Figura 38.</b> Digitalización manual de los edificios. ....	<b>Pág 58</b>
<b>Figura 39.</b> Capas permeables e impermeables.....	<b>Pág 59</b>

<b>Figura 40.</b> Carreteras, caminos y polígonos astilla. ....	<b>Pág 60</b>
<b>Figura 41.</b> Resultado después de unir las capas impermeable y permeable. ....	<b>Pág 60</b>
<b>Figura 42.</b> Resultado tras pasar a img. ....	<b>Pág 61</b>
<b>Figura 43.</b> Muestras impermeables y permeables. ....	<b>Pág 62</b>
<b>Figura 44.</b> Resultado de la matriz de confusión de la ortofotografía 2.2.....	<b>Pág 64</b>
<b>Figura 45.</b> Zona de estudio subdivida en cuadrados.....	<b>Pág 65</b>
<b>Figura 46.</b> Imágenes de segmentaciones a) Segmentación en escala 600 b) Segmentación en escala 300. c) Segmentación en escala 200.d) Segmentación en escala 50. ....	<b>Pág 68</b>
<b>Figura 47.</b> Cambios de color. ....	<b>Pág 69</b>
<b>Figura 48.</b> Cambios de altura. ....	<b>Pág 70</b>
<b>Figura 49.</b> Zona de solape entre ortofotografías.....	<b>Pág 70</b>
<b>Figura 50.</b> Zona sin datos MDO. ....	<b>Pág 71</b>
<b>Figura 51.</b> Representación grafica de la desviación estándar según numero de muestras. ....	<b>Pág 79</b>
<b>Figura 52.</b> Intervalo de confianza (IC) según número de muestras.....	<b>Pág 80</b>
<b>Figura 53.</b> Intervalo de confianza (IC) según número de muestras. ....	<b>Pág 81</b>
<b>Figura 54.</b> % área impermeable en la zona de estudio subdivida.....	<b>Pág 82</b>

INDICE DE TABLAS

<b>Tabla 1.</b> Resumen de la clasificación según niveles.....	<b>Pág 55</b>
<b>Tabla 2.</b> Valor de cada nivel digital. ....	<b>Pág 61</b>
<b>Tabla 3.</b> Forma del archivo csv. ....	<b>Pág 64</b>
<b>Tabla 4.</b> Segmentaciones realizadas. ....	<b>Pág 67</b>
<b>Tabla 5.</b> Umbrales utilizados para separar las clases <i>Mar</i> y <i>Tierra</i> .....	<b>Pág 71</b>
<b>Tabla 6.</b> Umbrales utilizados para separar las clases <i>Objetos</i> y <i>No Objetos</i> . .....	<b>Pág 72</b>
<b>Tabla 7.</b> Umbrales utilizados para separar las clases <i>Objetos_Sombras</i> y <i>Objetos_No Sombras</i> . ....	<b>Pág 73</b>
<b>Tabla 8.</b> Umbrales utilizados para separar las clases <i>Edificios</i> y <i>Árboles</i> .....	<b>Pág 73</b>
<b>Tabla 9.</b> Umbrales utilizados para separar los <i>Objetos_Sombras</i> en las clases <i>Edificios</i> y <i>Árboles</i> . ....	<b>Pág 74</b>
<b>Tabla 10.</b> Umbrales utilizados para separar las clases <i>Urbano</i> y <i>No Urbano</i> .....	<b>Pág 74</b>
<b>Tabla 11.</b> Umbrales utilizados para clasificar la clase <i>Playas</i> .....	<b>Pág 75</b>
<b>Tabla 12.</b> Porcentaje de acierto de todas las ortofotografías.....	<b>Pág 76</b>
<b>Tabla 13.</b> Resultado de <i>ground truth</i> por muestras.....	<b>Pág 78</b>
<b>Tabla 14.</b> Desviación estándar según el número de muestras.....	<b>Pág 78</b>
<b>Tabla 15.</b> Intervalos de confianza según número de muestras.....	<b>Pág 79</b>
<b>Tabla 16.</b> Porcentaje de acierto según número de píxeles.....	<b>Pág 80</b>

# CAPÍTULO 0

## RESUMEN

## 0. RESUMEN.

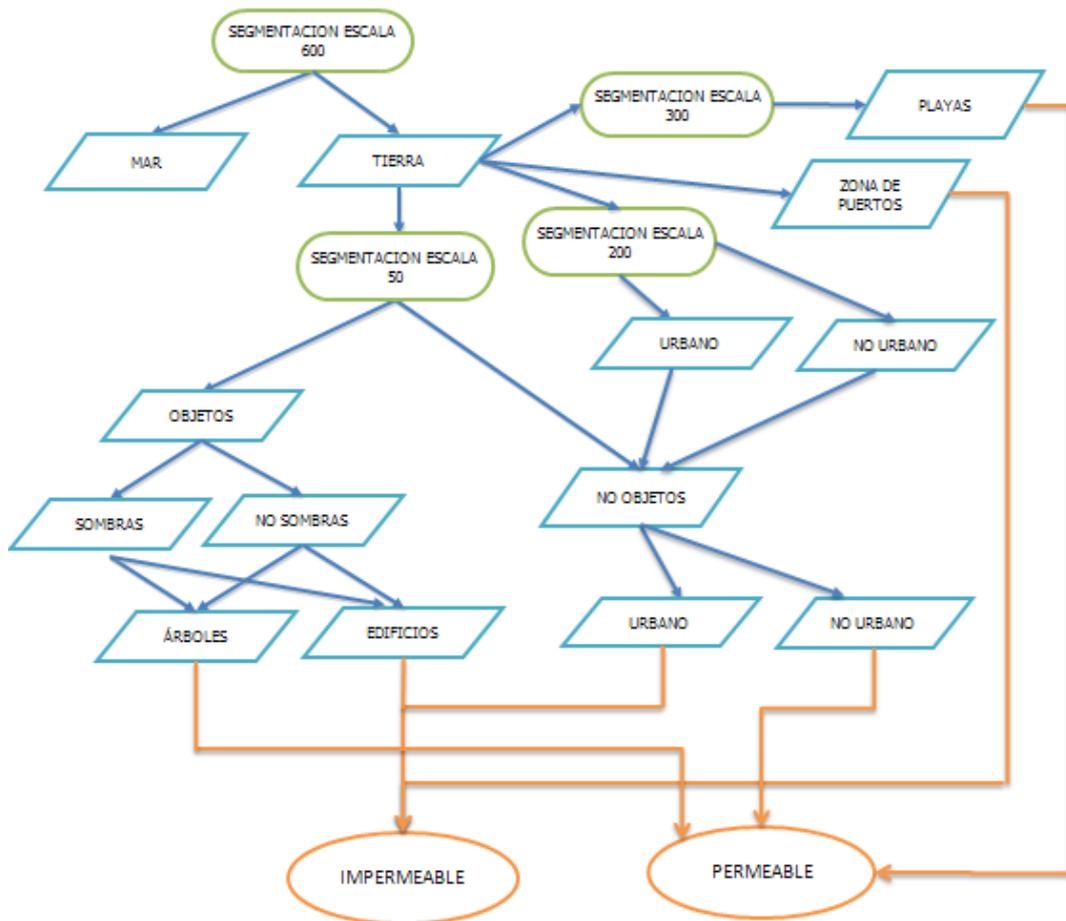
Este proyecto trata sobre el análisis de la técnica OBIA (*Object Based Image Analysis*) basada en la clasificación de objetos o agrupaciones de píxeles, frente a la clasificación tradicional de píxeles individuales, aplicando dicha metodología en la determinación de zonas permeables o impermeables en un área concreta. Para la aplicación de esta técnica se utilizó el software *eCognition*®. La estrategia seguida consistió en la división y separación de clases mediante umbrales de clasificación determinando finalmente qué clases son permeables (por ejemplo, suelo desnudo) y qué clases son impermeables (por ejemplo, edificios), por lo que la frase "divide y vencerás" es aplicable a este proyecto, ya que nuestro objetivo está basado en la resolución de un problema de manera jerárquica, es decir, utilizando clases y subclases de forma que para llegar a clasificar las subclases finales se requieren divisiones a nivel superior, lo que facilita la implementación de los umbrales. El proceso continúa hasta que finalmente, las soluciones a cada uno de los subproblemas es la solución al problema original, de forma que todas las clases finales son agrupadas según sean de naturaleza permeable o impermeable.

La creación de objetos homogéneos ha sido realizada en diferentes escalas (ver apartados posteriores 1.2.3 y 1.2.3.1) teniendo en cuenta las clases que iban a ser separadas así como la información que iba a ser utilizada. Esta parte inicial del trabajo que es la creación de objetos formados por agrupaciones de píxeles mediante *eCognition*®, se realizó una segmentación multiresolución a gran escala. Y se pasó a clasificar por un lado los objetos pertenecientes al Mar y por otro los pertenecientes a Tierra (clases *Mar* y *Tierra*). Las zonas portuarias fueron clasificadas también en esta escala mayor.

Posteriormente se volvió a realizar tres segmentaciones, pero sólo teniendo en cuenta los objetos clasificados como *Tierra*. La segmentación más pequeña se aplicó a escala 50 y se realizó para poder separar las clases *Objetos* (Modelo Digital de Objetos o MDO mayor a 0,8 m) y *No Objetos* (MDO menor a 0,8 m). Estos *Objetos* fueron subdivididos en *Sombras* y *No Sombras* y los *Objetos* que no contenían sombras fueron reclasificados en *Árboles* y *Edificios*. Tras esta clasificación los árboles se reclasificaron como *Zona Permeable* mientras que los edificios se clasificaron como *Zona Impermeable*. Es decir, se realizó un proceso de división-subdivisión hasta llegar a las subclases finales (*Árboles* y *Edificios*) para finalmente realizar una agrupación de clases, identificando unas nuevas "superclases" (*Zona Impermeable* y *Zona Permeable*).

Para la clasificación de la clase *Playas* se realizó una segmentación a la escala intermedia de 300. Dicha clase fue reagrupada en la súperclase *Zona*

*Permeable*. La última segmentación que se realizó fue en escala intermedia de 200 cuyo objetivo fue separar las clases de *Zona Urbana* y *No Urbana*. Posteriormente, la información de esta clasificación se pasó a la escala de referencia 50 con el fin de clasificar la clase *No Objetos* en zonas urbanas y no urbanas, reclasificándose posteriormente en *Zona Impermeable* y *Zona Permeable*, respectivamente. A continuación a modo de resumen se muestra un diagrama de flujo (Figura 1).



**Figura 1.** Esquema del flujo de trabajo llevado a cabo para la clasificación y subclasificación de los objetos. Los recuadros redondeados verdes corresponden a cada una de las segmentaciones llevadas a cabo. Por otro lado, los recuadros azules representan cada una de las clases-subclases, mientras que los círculos anaranjados corresponden a las súperclases finales.

Tras la clasificación se comparó lo clasificado mediante *eCognition*® con el *ground truth* extraído como resultado de la digitalización manual de las ortoimágenes correspondientes a la zona de trabajo y que pretende representar los

elementos que se encuentran en el área de trabajo a fin de estimar la precisión de la clasificación realizada.

Además del *ground truth* anteriormente descrito, se empleó un nuevo *ground truth* basado en la toma aleatoria de muestras, a fin de comprobar qué metodología es la más apropiada para la estimación de la precisión de la clasificación. Para ello se seleccionaron muestras al azar mediante el software MATLAB en una porción del proyecto y tras clasificarlas manualmente como permeables o impermeables, se procedió a compararlas con la clasificación realizada mediante *eCognition*®. Esta experiencia se realizó para 100 muestras, 250 muestras y 500 muestras y para cada número de muestra se realizó 4 repeticiones, de forma que se pudo observar la relación entre la precisión de la clasificación y el número de muestras tomadas.

Un objetivo final del proyecto es la representación del porcentaje de superficie permeable/impermeable por unidad de área o parcela. Para ello, se procedió a la exportación de los resultados obtenidos en la clasificación a formato vectorial (*shapefile*) para poder ser tratados mediante software SIG (*ArcGis*®). Para realizar la determinación del porcentaje de permeable e impermeable lo primero que se realizó fue, mediante una segmentación *chessboard*, dividir la zona de estudio en pequeños cuadrados o parcelas. Esta segmentación también se exportó a *ArcGis*® para así poder dividir la zona de estudio en estos cuadrados. A partir de estos se obtiene el área de cada cuadrado y para cada uno de estos cuadrados se obtiene el porcentaje de permeabilidad y el porcentaje de impermeabilidad.

# CAPÍTULO 1

## INTRODUCCIÓN

## 1. INTRODUCCIÓN.

Estudios realizados por el IPCC (*Intergovernmental Panel on Climate Change*) señalan que la costa mediterránea, sobre todo las zonas clasificadas como áridas o semiáridas, son las que más problemas sufrirán como consecuencia de las variaciones del clima. Entre los cambios que se prevén podemos destacar la disminución de las precipitaciones, temperaturas más extremas, retraimiento de la línea de costa por elevación del nivel del mar (Figura 2), etc. A este desesperanzador escenario hay que añadir la presión constante que sobre el litoral ejerce el hombre, más pernicioso y preocupante en la actualidad que el propio cambio climático, aunque más desconocida y, desde luego, con un menor impacto mediático. En efecto, más de la mitad de la población mundial vive a menos de 60 Km. de la línea de costa, lo que significa una densidad de población a veces inadmisibles para este tipo de ecosistemas altamente vulnerables. La Naturaleza ha mantenido durante miles de años un complejo equilibrio dinámico entre el mar y la tierra, equilibrio que está siendo alterado por el hombre y su ancestral sentido estático de dicho equilibrio.



**Figura 2.** Mapa de inundaciones de la zona de la costa Vera (Almería) ante dos hipotéticos escenarios de incremento de nivel del mar (SLR: “*Sea Level Rise*”) como consecuencia del cambio climático. Izquierda tenemos SLR = + 3 m. y derecha SLR = + 1 m.

La costa de la provincia de Almería no se ha librado de las perturbaciones antrópicas. Asistimos a un constante sellado artificial del suelo producido por la proliferación de urbanizaciones e infraestructuras costeras (Figura 3), cuyo efecto cuantitativo sobre la evolución de la línea de costa es, a menudo, desconocido. Los procesos de sellado o impermeabilización del suelo de la franja costera producen la rotura del equilibrio sedimentario al sustituir arenales costeros por edificaciones y disminuir el aporte de sedimentos al mar.

Por otra parte, durante los años 60-90 se extrajeron del orden de 20 millones de m<sup>3</sup> de arena de las playas para ser usada en los invernaderos.



**Figura 3.** Presión antrópica sobre la línea de costa debido, entre otros motivos, a la proliferación no planificada de urbanizaciones e infraestructuras litorales.

Ante esta preocupante situación parece obvia la necesidad de implementar sistemas eficaces de seguimiento (*monitoring*) de los efectos producidos por este tipo de actuaciones sobre nuestro litoral. Las técnicas emergentes de fusión y análisis de datos multi-temporales que ofrecen la moderna Ingeniería Geomática y el procesamiento de imágenes digitales (fotogrametría digital e imágenes de satélite de alta resolución, láser aerotransportado, segmentación y clasificación automática de imágenes, modelos digitales de elevaciones, etc.) permiten el desarrollo de metodologías rápidas y precisas para la obtención de modelos 3D del terreno y de las infraestructuras y vegetación que se sustentan sobre él (Modelos Digitales de Elevaciones y de Superficies respectivamente). A partir de dichos productos, y de otros como ortofotografías y cartografía digital vectorial, puede modelarse la evolución temporal de la línea costera y la dinámica de la erosión-acreción en la franja litoral. Dicha evolución puede relacionarse mediante técnicas de estadística espacial con la dinámica de sellado del terreno debido a la proliferación de urbanizaciones e infraestructuras costeras detectadas y cartografiadas de forma automática a partir de imágenes aéreas y nubes de puntos láser.

En definitiva, podemos desarrollar la tecnología necesaria para conocer lo que está ocurriendo a nuestras costas. Sólo necesitamos implementar estos sistemas de monitoreo como una metodología continua de soporte a la toma de decisiones dentro de una política de Gestión Integrada de Áreas Costeras (GIAC), tal y como

establece el marco del Convenio para la Protección del Medio Marino y de la Zona Costera del Mediterráneo, denominado Convenio de Barcelona. Concretamente, en el territorio español se han llevado a cabo numerosos estudios que utilizan series temporales de fotografías históricas para estudiar la evolución costera (erosión/acreción) en los últimos 50 años en costas del litoral catalán (Crous, A. y Pintó, J., 2006), en la desembocadura del río Vélez en Málaga (Senciales, J.M.y Malvárez, G., 2003), en las playas de Sotavento de Fuerteventura (Alonso, I, *et al.*, 2007), en la costa entre Sanlúcar de Barrameda y Rota (Domínguez, L. *et al.*, 2004) o en la costa de Almería entre las playas de la ciudad de Almería y Retamar (Manzano, G. *et al.*, 2004).

## *1.1 FUENTES DE INFORMACIÓN GEOREFERENCIADA.*

### **1.1.1. Imágenes aéreas.**

Las imágenes aéreas, y concretamente las series temporales de las mismas, suele ser la información de base utilizada con mayor frecuencia en los estudios de análisis de los procesos de cambio en el territorio (Zheng *et al.*, 1997). Estas imágenes aéreas se pueden obtener mediante la fotogrametría mediante la realización de vuelos aerotransportados o también pueden ser obtenidas mediante teledetección obteniendo imágenes de los satélites (tales como el Landsat (primer satélite lanzado en 1972, que con cuatro bandas espectrales y 79 metros de resolución espacial) y el satélite SPOT (*Systeme Probatoire d'Observación de la Terre*, lanzado en 1986, que podía realizar multiespectrales de 20 metros y pancromáticas de 10) o los instrumentos MODIS y ASTER, han sido importantes en los estudios mundiales y regionales en referencia a la diversidad biológica, conservación de la naturaleza, la seguridad alimentaria, el impacto de la deforestación, el seguimiento de la desertificación, y otros campos de aplicación. El éxito se definió temprano con una amplia variedad de aplicaciones (Ogrosky 1975, Ashley y Rea 1975, Klemas et al., 1975, Aldrich 1975, Jackson y Ragan 1977, y Jensen et al., 1979) demostrando rápidamente el valor de la teledetección espectral multibanda como una valiosa herramienta para el monitoreo de fenómenos.

Cuando el sensor *Landstad Thematic Mapper* (TM) fue lanzado en 1982, una nueva era de la teledetección multiespectral fue establecida. El sensor TM mejoró la resolución espacial (30 metros de tamaño de píxel) y se compuso por siete bandas espectrales e incluyó grabaciones y regiones del infrarrojo térmico del espectro electromagnético. Estos cambios introducidos mejoraron las capacidades discriminatorias de análisis de teledetección, especialmente para las relacionadas con los ecosistemas urbanos.

Mientras que los tamaños de pixel se han mantenido generalmente más grandes que, o en el mejor de los casos, similares al tamaño de los objetos de interés, se ha hecho énfasis en el análisis por píxel o incluso sub-píxel, y con el aumento de la resolución espacial <1-m, de satélites como IKONOS (lanzado en 1999), y de los sensores *QuickBird* (2001) o *OrbView* (2003), nuevos campos de aplicación que anteriormente habían sido controlados por métodos aéreos, hoy en día pueden ser abordados mediante la tele-observación por satélite.

A finales de 2007, el primer satélite comercial con una resolución de menos de medio metro (*WorldView-1*, 0,44 m de pancromática) se convirtió en operacional. Asimismo, los datos comerciales de satélites proveedores como *Space Imaging, Inc.* y de *DigitalGlobe, Inc.* actualmente proporcionan imágenes pancromáticas digitales con una resolución espacial a partir del 1 por 1 m a 0,61 m por 0,61. Como resultado de estos avances, en la actualidad vemos como la teledetección se utiliza en las aplicaciones de seguridad, detección de vehículos, en aplicaciones de protección, y muchas aplicaciones urbanas en desarrollo, tanto en número como en sofisticación. En este proyecto decidimos escoger la fotogrametría realizada mediante un vuelo aerotransportado ya que la resolución de pixel de estas imágenes es de 0,10 m y por tanto mejor que la resolución de pixel que cualquier satélite.

Además de las imágenes de satélite anteriormente introducidas, la obtención de información radiométrica se puede realizar también a mayor escala mediante sensores aerotransportados pero no espaciales. Actualmente, las técnicas fotogramétricas utilizan cámaras digitales de muy alta resolución que permiten la extracción de información de una forma espacialmente muy precisa. Además, las cámaras digitales fotogramétricas están incorporando, recientemente, un número mayor de bandas de información, más allá de las bandas históricas del espectro visible, incluyendo sobretodo bandas en el espectro del infrarrojo que permiten análisis posteriores más detallados. Además, la combinación de cámara digital + LiDAR aéreo permite que la obtención de ortoimágenes digitales en color, generadas de manera simultánea uniendo los datos de imágenes y las elevaciones del terreno, sea altamente eficiente. Con esta tecnología, ahora se puede obtener una resolución espacial muy alta, pudiéndose obtener de forma adecuada modelos digitales de tipo malla con 1 metro de resolución y alrededor de 10-15 cm. de precisión altimétrica. Por todo ello, se considera que la tecnología LiDAR puede ser de gran valor para la extracción de información de superficies impermeables. (*North Carolina Flood Plain Mapping Program, The State of North Carolina, Raleigh, North Carolina*, [URL:http://www.ncfloodmaps.com](http://www.ncfloodmaps.com)).

### 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 (MDS) obtenidos a partir de escáneres láser aerotransportados (ALS- LiDAR; acrónimo de "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 (Figura 4).

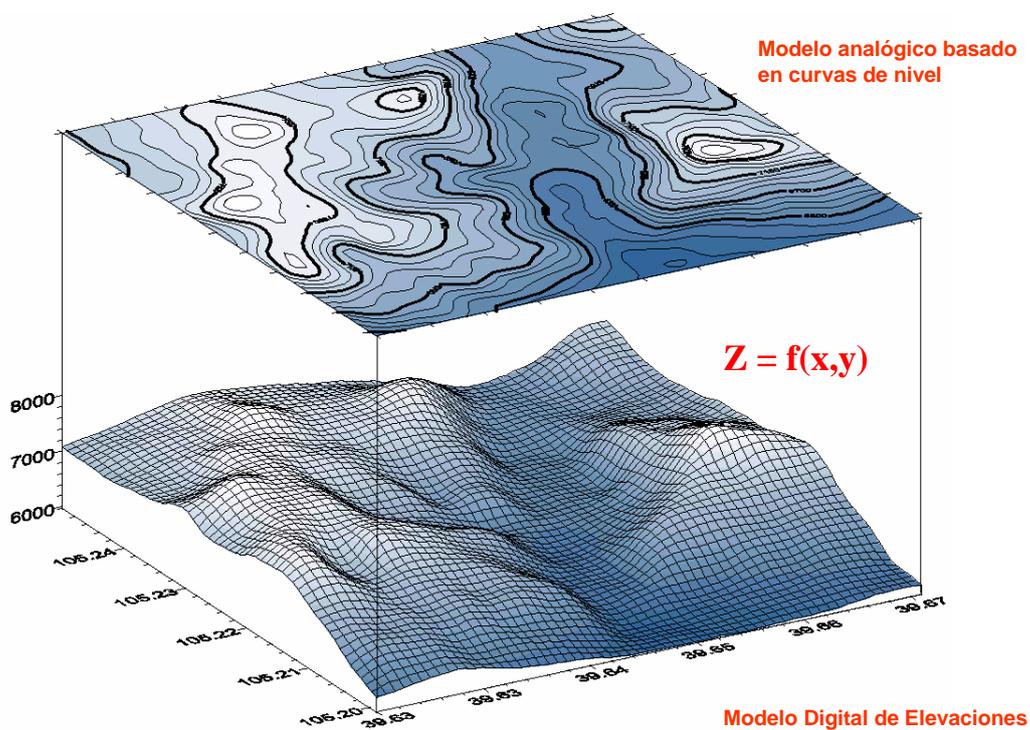
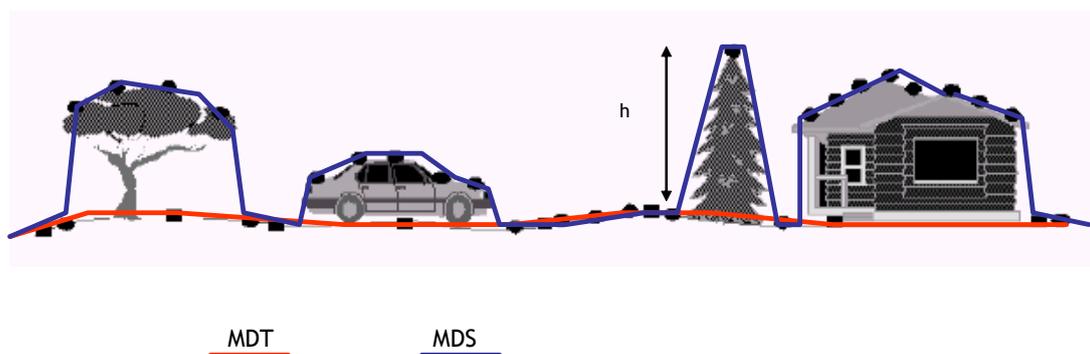


Figura 4. Representación del terreno mediante Modelos Digitales de Elevaciones (MDEs).

En la Figura 5 puede observarse la diferencia entre un MDE del terreno (MDT) y un MDS. En este último se tiene en cuenta el denominado microrrelieve (vegetación, edificios, etc.) que se asienta sobre el terreno desnudo, por lo que de la diferencia entre un MDS y el MDE del suelo desnudo podemos obtener lo que se denomina un modelo digital de alturas de objetos (MDO).

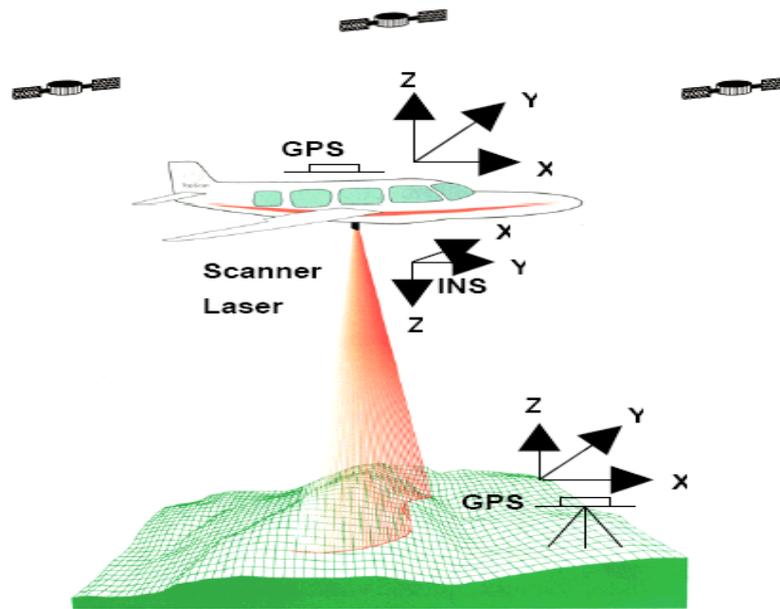
Un sistema LiDAR es un sensor activo aerotransportado que emite pulsos de luz infrarroja con una frecuencia muy elevada (en algunos modelos más de 150 kHz). Mediante unos relojes de elevadísima precisión se determina el tiempo que tarda cada pulso en volver al emisor y por tanto la distancia al objeto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



**Figura 5.** 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.

Los parámetros de orientación externa del sensor en cada momento se obtienen mediante el postproceso de los datos aportados por dos subsistemas complementarios (Figura 6): 1) 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); 2) Sistema IMU (*Inertial Measurement Unit*) para la obtención de los ángulos de orientación  $\omega$ ,  $\phi$ ,  $\kappa$ . 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.

Por otra parte, y según el modelo de sensor LiDAR, podemos obtener más de un retorno por cada pulso, lo que suele servir para diferenciar, en primera instancia, el suelo desnudo (último retorno) del microrrelieve (primer retorno).



**Figura 6.**Componentes de un sensor LiDAR aerotransportado.

La tecnología ALS tiene como principal ventaja la rapidez y precisión con la que se dispone de los datos altimétricos de la zona escaneada. Existen trabajos recientes que utilizan datos ALS para la extracción de objetos a partir de modelos digitales de alturas o intensidades de retorno (Miliaresis, G., y Kokkas, N., 2007), o los combinan con otro tipo de información, como por ejemplo imágenes en color dentro del espectro visible. Este tipo de tecnología puede ser utilizada para trabajos como detección de la erosión costera, monitoreo de la línea de costa, batimetrías, seguimiento de dunas, etc.

En general, los MDE conforman una información que puede resultar básica para la clasificación de imágenes basada en objetos (OBIA). De esta forma, cada objeto posee información de tres capas diferentes a las radiométricas (rojo, verde y azul, más alguna adicional como el infrarrojo), de forma que se retiene el valor medio de MDE, MDS y MDO para cada objeto. 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 o los árboles; o con la altura absoluta (clasificación de playas por altura). 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.

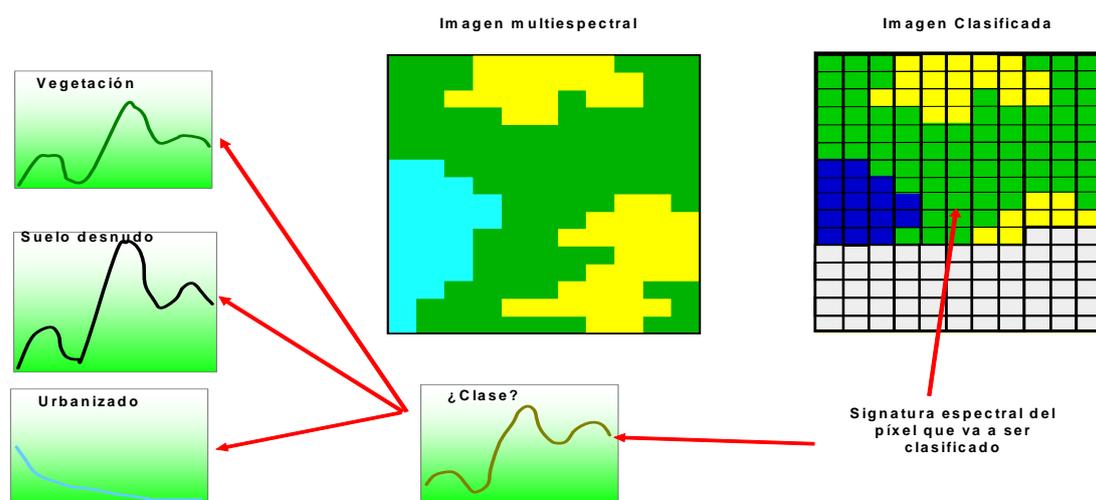
### 1.1.3 Clasificación de imágenes digitales.

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. Sin embargo, la mayoría de las disponibles hoy día se encuentran lejos de conseguirlo. Las principales causas que motivan las dificultades en este proceso de automatización están relacionadas por un lado con la variabilidad del tipo de información a extraer, la escala de trabajo, y el nivel de detalle requerido, y por otro lado con la dificultad en la diferenciación de los objetos reconocidos en la imagen.

#### *1.2 Extracción de información a partir de los datos multifuente.*

##### 1.2.1. Clasificación por píxeles vs. Clasificación por objetos (obia).

La mayoría de las técnicas usadas para la extracción de información son clasificaciones basadas en parámetros estadísticos deducidos de zonas de la imagen estudiada cuya realidad se conoce (signaturas espectrales; Figura 7), y que se pueden aplicar a nivel de píxel o a nivel de objetos homogéneos previamente definidos (segmentación de la imagen).



**Figura 7.** Procedimiento general para la clasificación de una imagen multispectral mediante técnicas de clasificación supervisada.

A partir del trabajo pionero de Ketting y Landgrebe, en el que desarrollaron la técnica que denominaron Extracción y Clasificación de Objetos Homogéneos (ECHO, acrónimo de "*Extraction and Classification of Homogeneous Objects*"), los métodos orientados a objetos se incluyen todos aquellos que, al contrario que los métodos de clasificación tradicionales (*píxel a píxel*), no solamente tienen en cuenta el nivel digital de cada píxel sino los de los píxeles vecinos. Teóricamente, una aproximación orientada a objetos se corresponde mejor con la realidad ya que las cubiertas del suelo ocupan (en las imágenes de alta resolución) áreas de mayor entidad que un píxel y, por tanto, es preferible clasificar estas áreas u objetos tomándolos como una sola unidad. Han sido numerosos los trabajos que han comparado estas técnicas validando los resultados iniciales, sobre todo cuando se procesan imágenes de alta resolución (Lee, J. Y., y Warner, T. A., 2006; Agüera, F., Aguilar *et al*, 2008). En relación a los datos ALS (*Airborne Laser Scanning*), los trabajos que abordan esta tarea suelen utilizar técnicas de filtrado para obtener modelos digitales de elevaciones y de superficies que son empleados como única fuente de información, o bien combinados con otros de diferente naturaleza como imágenes RGB o infrarrojas (Sohn, G. y Dowman, I., 2007).

### **1.2.2. 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 cuya realidad se conoce como clasificación supervisada, clasificación no supervisada y el método mixto, estos tres tipos de clasificaciones pueden ser realizadas tanto para clasificación por píxeles como para clasificación por objetos (OBIA).

En la clasificación supervisada, el analista define en la escena una serie de parcelas, llamadas campos 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 conocimiento 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 agruparán *clusters* de igual significación temática y se separarán en nuevos agrupamientos los que mezclen dos clases informacionales y el último paso será 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 la clase propuesta por el operador tiene un significado espectral y otras categorías señaladas como clases que no encontrarán afinidad por lo que su tratamiento habrá de particularizarse en el ámbito del proyecto (Pinilla, 1995).

### **1.2.3 Proceso de segmentación en la clasificación obia.**

Lo primero que se realiza para el análisis de imágenes consiste en segmentar la imagen. La segmentación subdivide una imagen en partes constituyentes u objetos. La segmentación es una de las tareas más difíciles del procesamiento de imágenes y puede determinar el éxito o fracaso del análisis. Existen varias técnicas para la segmentación como son (González, R. C y Woods, R. E., 1992):

- *Detección de discontinuidades:* este método consiste en dividir una imagen basándose en los cambios bruscos de nivel de gris. Las principales áreas de interés de esta categoría son la detección de puntos aislados y la detección de líneas y bordes de una imagen.
- *Enlazado de bordes y detección de límites:* En la práctica este conjunto de píxeles no suele caracterizar completamente a esos contornos debido a la presencia de ruido, ruptura en los propios contornos debido a la iluminación no uniforme y otros efectos que introducen falsedad en las discontinuidades de la intensidad. En general, después de los procedimientos de detección de bordes se suele emplear técnicas de enlazado u otras técnicas de detección de contornos designadas para unir los píxeles de bordes en contornos significativos.
- *Umbralización:* es uno de los métodos más importantes de la segmentación de imágenes y se realiza basándose en las propiedades de distribución de los píxeles, tales como la intensidad o el color.

- *Segmentación orientada a regiones*: esta técnica se basa en encontrar directamente las regiones. Sobre esta técnica es en la que se basa el programa utilizado para este trabajo fin de carrera llamado *eCognition®*. Las principales áreas de interés son el crecimiento de regiones mediante la agregación de píxeles y la división y fusión de regiones.

La mayoría de las técnicas usadas para la extracción de información son clasificaciones basadas en parámetros estadísticos deducidos de zonas de la imagen estudiada cuya realidad se conoce como clasificación supervisada, clasificación no supervisada y el método mixto, estos tres tipos de clasificaciones pueden ser realizadas tanto para clasificación por píxeles como para clasificación por objetos (OBIA).

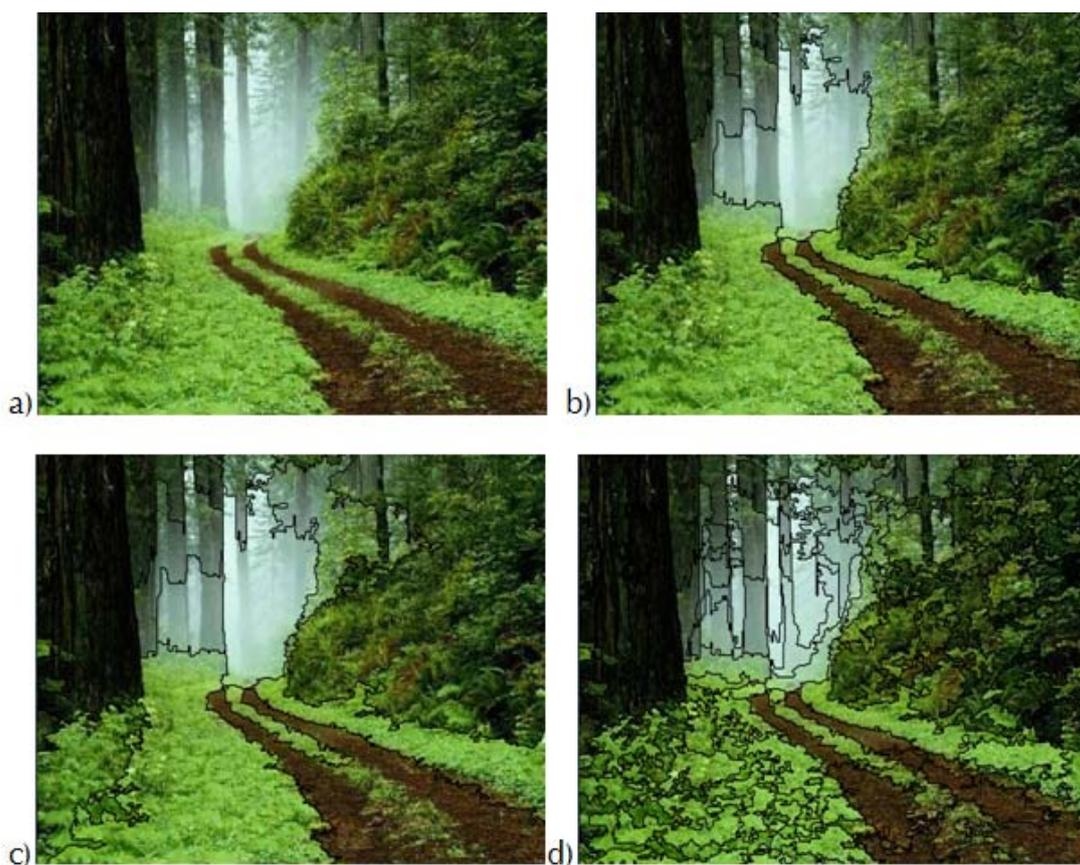
Los algoritmos de segmentación se utilizan para subdividir imágenes completas para obtener objetos directamente a partir de la información contenida en los píxeles individualmente (a nivel de píxel), o bien los objetos pueden ser obtenidos mediante la información contenida en otra segmentación realizada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

El software utilizado (*eCognition®*) ofrece varios enfoques diferentes para la segmentación, que van desde algoritmos muy simples, tales como tablero de ajedrez (*chessboard*) y la segmentación de *quadtree* y otros basados en métodos altamente sofisticados tales como la segmentación multirresolución y la segmentación del filtro de contraste.

#### *1.2.3.1. La segmentación multirresolución.*

El algoritmo de segmentación multirresolución local, ampliamente utilizado y aceptado por la comunidad científica y aplicada en este trabajo, minimiza la heterogeneidad media de los objetos de la imagen para una resolución dada de objetos de imagen. Se puede ejecutar en un nivel de imagen objeto existente o el nivel de píxel para crear nuevos objetos de imagen en un nivel de imagen nuevo objeto. El algoritmo de segmentación multirresolución consecutiva funde píxeles u objetos de imagen existentes. Por lo tanto, es un algoritmo de segmentación de abajo hacia arriba que se basa en la técnica de fusión de regiones por parejas. La segmentación multirresolución es un procedimiento de optimización que, para un número determinado de objetos de imagen, minimiza la heterogeneidad media y maximice su homogeneidad respectiva.

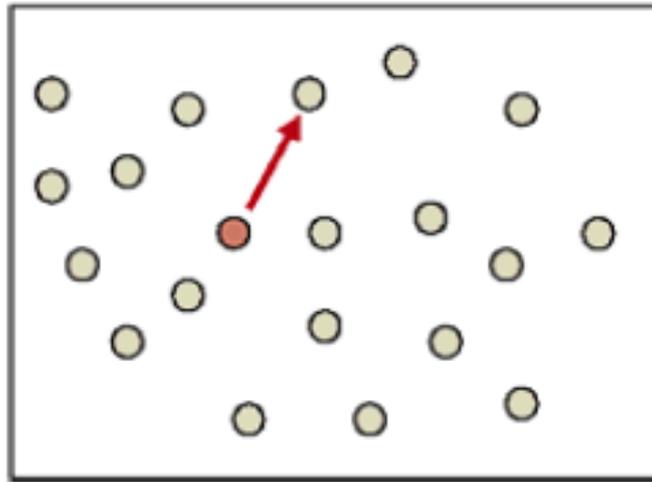
El procedimiento de segmentación se inicia considerando cada píxel como un objeto inicial uniéndose iterativamente los píxeles dos a dos, siempre que no se supere un umbral de homogeneidad de forma local. Este criterio de homogeneidad se define como una combinación de los parámetros homogeneidad espectral 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. (Figura 8).



**Figura 8.** a) Imagen original b) Resultado de la segmentación multiresolución con escala 500 c) Resultado de la segmentación multiresolución con escala 200 d) Resultado de la segmentación multiresolución con escala 50, para todas estas segmentaciones la forma ha sido 0,1 y la compacidad de 0,5.

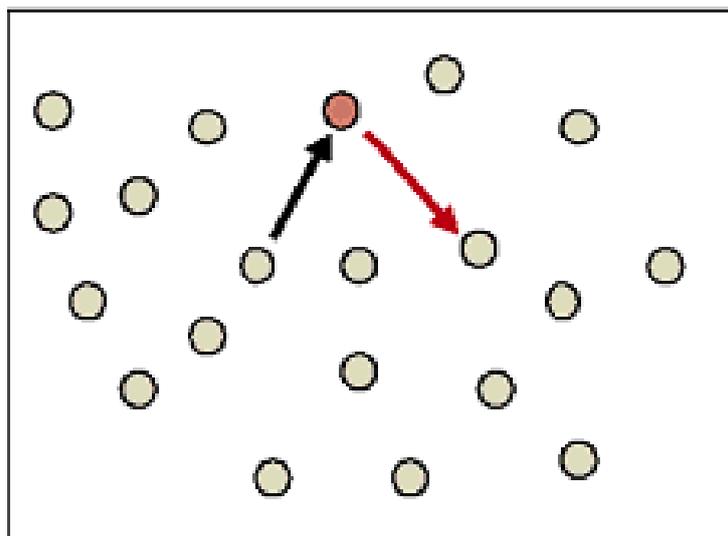
Como el primer paso del procedimiento, cada objeto de la imagen utiliza el criterio de homogeneidad para determinar el mejor vecino para fusionarse con este (Figura 9). Si el mejor vecino del objeto no reconoce el objeto de la primera imagen como el mejor vecino, el algoritmo se mueve con el objeto de encontrar el mejor vecino (Figura 10). Esta rama a rama de salto se repite hasta que encuentra los mejores vecinos asociados (Figura 11). Si la homogeneidad del objeto de la nueva

imagen no supera el parámetro de la escala, la pareja de objetos se fusionan y estos lazos de fusión continuarán hasta que no sea posible seguir (Figura 12).

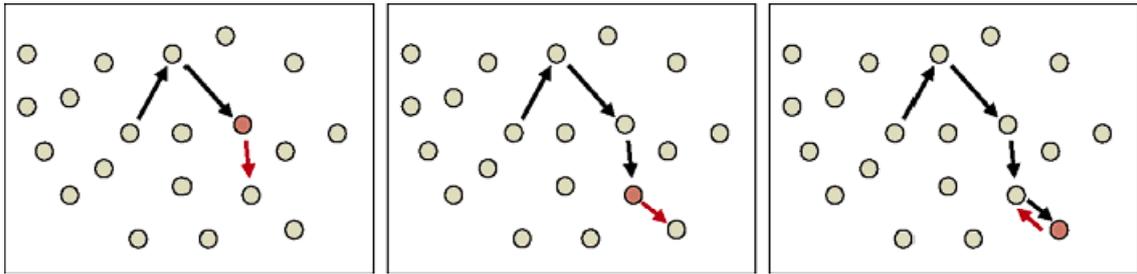


**Figura 9.** Cada objeto de la imagen utiliza el criterio de homogeneidad para determinar el mejor vecino para fusionarse con este.

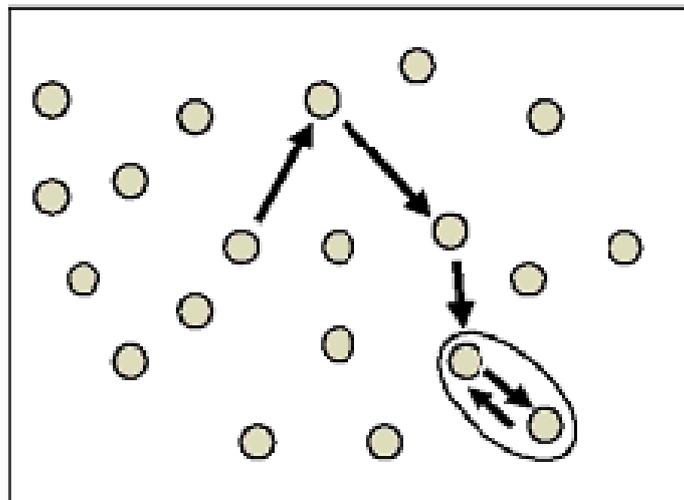
Los algoritmos de segmentación se utilizan para subdividir imágenes completas para obtener objetos directamente a partir de la información contenida en los píxeles individualmente (a nivel de píxel), o bien los objetos pueden ser obtenidos mediante la información contenida en otra segmentación realizada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



**Figura 10.** Si el mejor vecino del objeto primera imagen (rojo) no reconoce el objeto de la primera imagen (gris) de la mejor manera vecino, el algoritmo se mueve (flecha roja) con el objeto de la segunda imagen para encontrar el mejor vecino.



**Figura 11.** Esta rama a rama de salto se repite hasta que encuentra los mejores vecinos asociados.



**Figura 12.** Si la homogeneidad del objeto de la nueva imagen no supere el parámetro de escala, la pareja dos objetos de la imagen se fusionan.

El campo de nombre de nivel le permite definir el nombre para el nivel de objetos de la nueva imagen. Para crear nuevos niveles de objetos de imagen, utilice el dominio de objeto de la imagen el nivel de píxel en el cuadro de diálogo o nivel de objeto de imagen usado anteriormente para crear encima o por debajo el nivel nuevo.

Configuración de la segmentación, basada en los parámetros que requiere *eCognition®* para la segmentación multiresolución:

- 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 objetos de la imagen se debe dar poco o ningún peso. Cuando no se le quiera dar peso a alguna capa se debe poner en 0. Por ejemplo, las capas tenidas en cuenta en este proyecto son las correspondientes a los valores de: Rojo, Verde, Azul, Infrarrojo Cercano, Intensidad, MDO, MDT y MDS. Estas capas son utilizadas a conveniencia para las segmentaciones multirresolución y para las posteriores clasificaciones según los umbrales detectados. El identificar las capas de información que serán incluidas en la segmentación resulta un paso de una importancia crítica por dos razones: primero, el proceso de segmentación es el más costoso de cuantos se aplican en una clasificación OBIA, por lo que, una reducción de la información utilizada (empleando el menor número de capas que ofrezcan mayor nivel de información) influye directamente en una mayor eficiencia del procedimiento; y segundo, e igualmente importante, el conocimiento previo de los mejores clasificadores-umbrales que serán utilizados en el proceso de clasificación hace que dicha información sea tenida en cuenta de manera imperativa en el proceso de segmentación ya que es éste el que define qué información homogénea es la que se va a tomar en cuenta. Un ejemplo de este último punto es el supuesto de que la clasificación va a realizarse según las alturas de los objetos (MDO), de forma que los objetos deben ser homogéneos según la información del MDO, por lo que dicha capa ha de ser incluida con un peso importante en la segmentación.

- Uso de capas temáticas.

Cada capa temática, entendida como fichero vectorial de tipo polígonos, que se utiliza para la segmentación conducirá a la división adicional de los objetos de imagen mientras que permite un acceso consistente a su información temática. Se puede segmentar una imagen con más de una capa temática. Los resultados son objetos de imágenes que representan las intersecciones adecuado entre las capas temáticas.

- 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 que todavía en los que todavía se distinguían las diferentes regiones de la imagen que deban ser clasificadas, es decir, los objetos deben ser lo más grande posible y tan finos como sea necesario de forma que contengan la información requerida en la clasificación posterior.

- Parámetro de Forma

Este parámetro constituye el criterio de homogeneidad que va a ser aplicado en la segmentación mediante la ponderación entre los parámetros de forma y color. El valor del campo forma se modifica con la relación entre la forma y el color (información de los niveles digitales), de forma que al modificar el umbral o peso que se le da a la forma, se está cambiando complementariamente el peso del color ( $\text{color} = 1 - \text{forma}$ ). En efecto, al disminuir el valor asignado al campo de forma, se define a 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. El valor de la forma no puede tener un valor superior a 0,9, debido al hecho de que sin la información espectral de la imagen, los objetos resultantes no estarían relacionados con la información espectral en absoluto. Además de la información espectral, la homogeneidad de objetos se ha optimizado con respecto a la forma del objeto, definido por el parámetro de tamaño compacto. Sin embargo, la información espectral es la información primaria contenida en datos de la imagen. Utilizando el criterio de forma muy intensa por lo tanto puede reducir la calidad de los resultados de la segmentación, primando más la homogeneidad en cuanto a la forma geométrica que en cuanto a la radiometría de la imagen.

- 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. (*Reference Book de eCognition®*).

## CAPÍTULO 2

# INTERÉS Y OBJETIVOS

## 2. INTERÉS Y OBJETIVOS.

### 2.1. INTERÉS.

Un aspecto importante, y no demasiado bien conocido, que afecta a la evolución de nuestras costas son las modificaciones antrópicas del terreno natural de la franja litoral, que conllevan la modificación de las características físico-químicas del mismo. Así, la actividad antrópica tienen como consecuencia directa un aumento del coeficiente de escorrentía de las aguas de lluvia debido a su prácticamente nula permeabilidad, provocando que casi toda esta agua vierta en la red de drenaje (Paul *et al.*, 2003). Estas modificaciones antrópicas se deben a:

- Construcción de Embalses y Extracción de Áridos. Ambos comportan la reducción del aporte sedimentario fluvial, con la consiguiente pérdida de arena de las playas y aumento del grado de erosión.
- Construcción de Espigones. Provocan un efecto pantalla sobre las corrientes de deriva litoral dando lugar a la descarga de gran parte del material en suspensión; se produce por tanto un déficit de aporte de sedimento una vez que la corriente supera el obstáculo que supone el espigón. Las estructuras de este tipo también pueden provocar erosión de las costas donde no existe una deriva litoral importante, especialmente cuando se construyen diques de embocadura en puertos, bocanas o desembocaduras fluviales.
- Allanamiento de las Playas. Supone un incremento del carácter reflectivo de la playa que la hace más susceptible a la erosión; aumenta la probabilidad de inundación de la parte alta de la playa durante los temporales, con la consiguiente desprotección de los cordones de dunas asociados a las playas.
- Extracción de Arena de las Playas. Implica una modificación de los procesos litorales de sedimentación-erosión natural.
- Urbanización de la Primera Línea de Mar. Supone la creación de una pantalla frente a la dinámica eólica natural de las playas, la destrucción de hábitats y la modificación de la morfología litoral; además, la construcción de viviendas y otras infraestructuras próximas a la zona de influencia de la amenaza por dinámica natural hace aumentar el grado de exposición de las personas y de sus bienes.
- Sobreexplotación de los Acuíferos próximos a la franja litoral y descenso del nivel freático, con el consiguiente peligro de intrusión marina y agotamiento del recurso hídrico.
- Deforestación. Implica una desprotección del suelo de manera que aumenta el potencial de erosión y destrucción del sistema fluvial que desemboca en el mar.

En las zonas donde la transformación de los usos del suelo haya provocado un aumento considerable de las áreas urbanas es imprescindible contar con datos actualizados del porcentaje de superficie impermeable (*ISA o Impervious Surface Area*), puesto que este es uno de los inputs de mayor peso en los modelos que estiman la escorrentía total para una determinada área (Zug *et al.*, 1999).

Es por tanto crucial la extracción de información espacial de calidad a partir de imágenes procedentes de sensores remotos para el seguimiento y verificación de la hipótesis enunciada. Dicha extracción de información suele llevarse a cabo de forma manual en la mayoría de los casos. Sin embargo, este tipo de tareas son lentas, requieren operadores bien entrenados, y son por consiguiente 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 de imágenes procedentes de sensores remotos.

Las principales causas que motivan las dificultades en este proceso de automatización están relacionadas con la variabilidad del tipo de información a extraer, la escala de trabajo, y el nivel de detalle requerido (Wang *et al.*, 2003), y por otro lado con la dificultad en la diferenciación de los objetos reconocidos en la imagen (Mayunga *et al.*, 2007).

## *2.2. OBJETIVOS.*

El objetivo principal es el desarrollo y evaluación de técnicas basadas en la integración-fusión de datos georreferenciados, segmentación de objetos y clasificación de los mismos (técnicas OBIA; *Object Based Image Analysis*) para la detección automática y eficiente de zonas impermeables y permeables en entornos costeros. Se emplearán vuelos de última generación (cámara digital y altimetría láser con georreferenciación directa).

Otro objetivo es el estudio comparativo entre un *ground truth* total que es el resultado de la digitalización manual de la verdad terreno, cuya obtención fue costosa debido al tiempo que este lleva a cabo obtenerlo y los problemas que debido a la abstracción ya que digitalizar a manualmente provoca errores debido a la abstracción y otro *ground truth* en el que se seleccionaron muestras al azar mediante el software MATLAB en una porción del proyecto y tras clasificarlas manualmente como permeables o impermeables, se procedió a compararlas con la clasificación realizada mediante *eCognition®* ya que se pretende comprobar la fiabilidad de un *ground truth* total frente a un *ground truth* muestral.

# CAPÍTULO 3

## MATERIALES Y MÉTODOS.

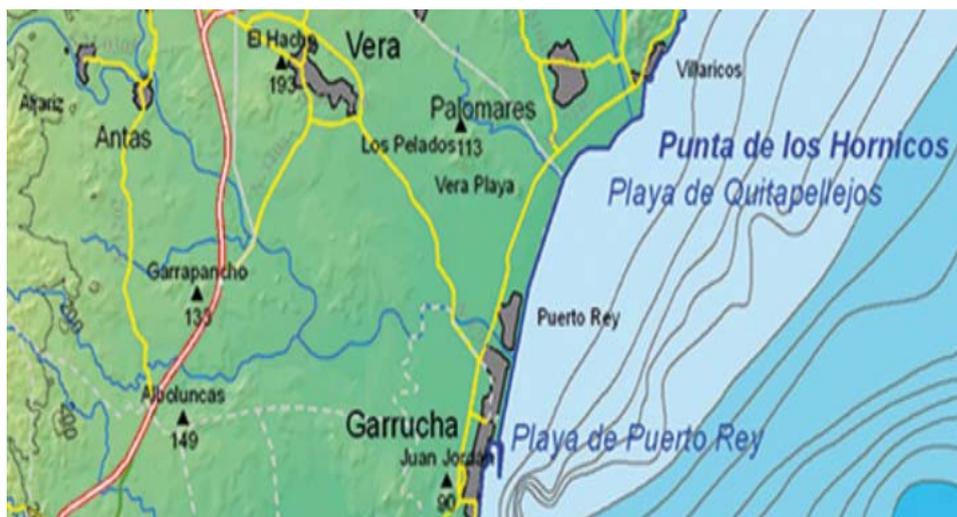
### 3. MATERIALES Y MÉTODOS.

#### 3.1. DESCRIPCIÓN DEL ÁREA DE TRABAJO.

El área de trabajo seleccionada corresponde a la zona de costa situada entre las poblaciones de Villaricos (pedanía perteneciente al término municipal de Cuevas del Almanzora) y Vera comprendiendo una longitud de unos 11 Km en la costa del levante almeriense (Figura 13 y Figura 14 ). 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 debido a la expansión inmobiliaria como resultado del desarrollo del sector turístico en la zona. En un estudio reciente realizado (Consejería de Medio Ambiente de la Junta de Andalucía, 2006), la desembocadura del río Antas era catalogada como una zona con riesgo de inundación “muy grave”, ocupando una extensión de unas 12.6 has. Estos terrenos inundables mantienen una lámina de agua permanente a lo largo del ciclo anual, aunque su volumen depende de las precipitaciones recogidas en el área. Asimismo, se ha propuesto por parte de la Consejería de Medio Ambiente la declaración del Río Antas como Lugar de Interés Comunitario, con una extensión de 23,08 hectáreas (<http://mediomarino.almediam.org/node/43>).



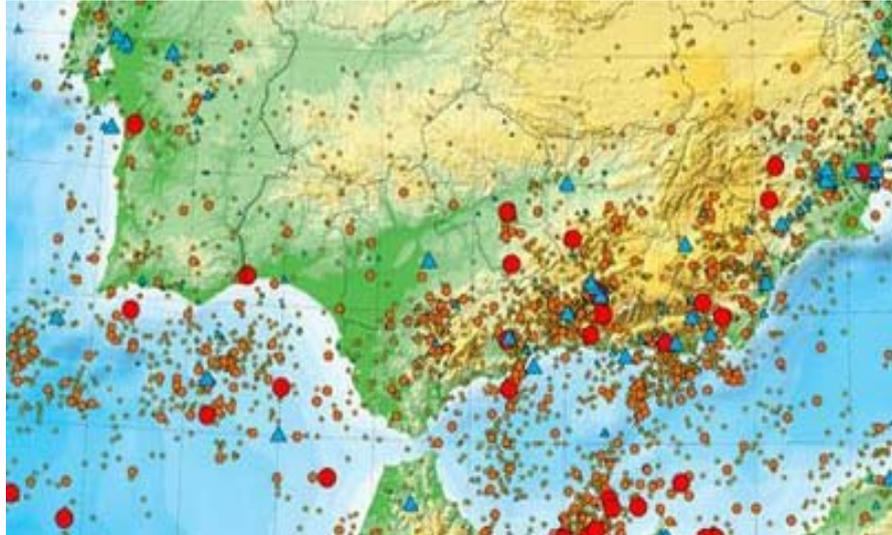
Figura 13. Localización de la zona de estudio.



**Figura 14.** Emplazamiento de estudio.

En esta zona el sellado artificial del suelo producido por la proliferación de urbanizaciones e infraestructuras costeras, conllevan, en la mayoría de las ocasiones, a la modificación de las características físico-químicas del mismo. Así, la construcción de edificios, carreteras, pistas deportivas, polígonos industriales, etc., tienen como consecuencia directa un aumento del coeficiente de escorrentía de las aguas de lluvia debido a su prácticamente nula permeabilidad, provocando que casi toda esta agua se vierta en la red de drenaje. Los procesos de sellado o impermeabilización del suelo de la franja costera producen la rotura del equilibrio sedimentario al sustituir arenales costeros por edificaciones y disminuir el aporte de sedimentos al mar provocando que se realice el aporte de arena para la restauración y conservación de las playas. Para esto también realizaron la construcción de varios espigones con el objetivo de favorecer la acumulación de arena en estas playas. También esta zona presenta un riesgo importante por inundaciones de zonas interiores urbanizadas debido a que existen zonas cercanas al mar con mayor altimetría que zonas interiores y alejadas del mar. .

Por otra parte, la falla Carboneras-Palomares dota a la zona de unas características especiales en cuanto a la posibilidad de actividad sísmica susceptible de provocar tsunamis de naturaleza sismogénica provocando que esta zona tenga riesgo de inundaciones. En la Figura 16 se muestra la cantidad de movimientos sísmicos que se producen en la zona de Almería e incluida la zona del levante almeriense donde está incluida nuestra zona de estudio.



**Figura 15.** Sismología en la zona de estudio.

### *3.2. MATERIALES EMPLEADOS.*

#### **3.2.1. Ortoimágenes RGB+NIR de alta resolución.**

En agosto de 2009 se realizó un vuelo aerotransportado combinado de cámara fotogramétrica digital + ALS (*Airborne Laser Scanner*) mediante el cual se obtuvieron imágenes en cuatro canales de información RGB+NIR (*Red, Green and Blue + Near InfraRed*) es decir, Rojo, Verde y Azul o verdadero color y el canal del Infrarrojo Cercano. Estas imágenes fueron de alta resolución y fueron tomadas junto a 4 pasadas de datos altimétricos LiDAR (*Light Detection and Ranging*) (Stereocarto, 2009).

Durante el vuelo se constató que las condiciones meteorológicas y de visibilidad para la realización de los trabajos fotogramétricos de la zona estudio eran las idóneas, es decir, una buena iluminación en la hora del día adecuada, así como la inexistencia de nubosidad que impidiera la visibilidad de la zona.

El vuelo se realizó a una altura sobre el terreno de aproximadamente 1000 metros, el número de pasadas fue de 4 (Figura 16), tanto para imágenes como para bandas LiDAR, siendo el número de fotografías de 86 en total. La cámara utilizada fue del tipo DMC "*Digital Mapping Camera*" con una distancia focal (*c*) igual a 120 mm y una resolución de pixel de 0,10 m. El recubrimiento longitudinal fue de 65% mientras que para el recubrimiento transversal de 60%.



**Figura 16.** Vuelo del estudio.

A partir de las imágenes originales, se obtuvieron un conjunto de 14 ortoimágenes en forma de hojas independientes, para cubrir toda la zona de estudio. Para ello, siguiendo un proceso de trabajo de fotogrametría digital, se utilizaron los datos de orientación directa (posicionamiento instantáneo de la aeronave), así como el modelo digital de elevaciones (MDE) obtenido mediante la previa edición de los datos LiDAR (apartado 3.2.3). Las ortoimágenes finales están compuestas por 4 bandas (Rojo, Verde, Azul e Infrarrojo) con una resolución radiométrica de 12 bits y fueron entregadas en formato tiff y posteriormente fueron transformadas a 8 bits.

### **3.2.2. División de las ortoimágenes por hojas.**

La división de las ortoimágenes en hojas fue realizada a escala 1:2000, para así poder trabajar con mayor eficacia con los programas o software necesarios en el proyecto, ya que con la ortoimagen completa el funcionamiento de cada software se ralentiza e imposibilita el análisis debido a la cantidad de información. La división de las ortoimágenes en hojas fue realizada y quedó distribuida de la forma que muestra la Figura 17. Debido a que este proyecto es de tipo monográfico y no es productivo, no se ha usado todo el área del proyecto original, si no que, se ha utilizado la mitad del mismo, aproximadamente.



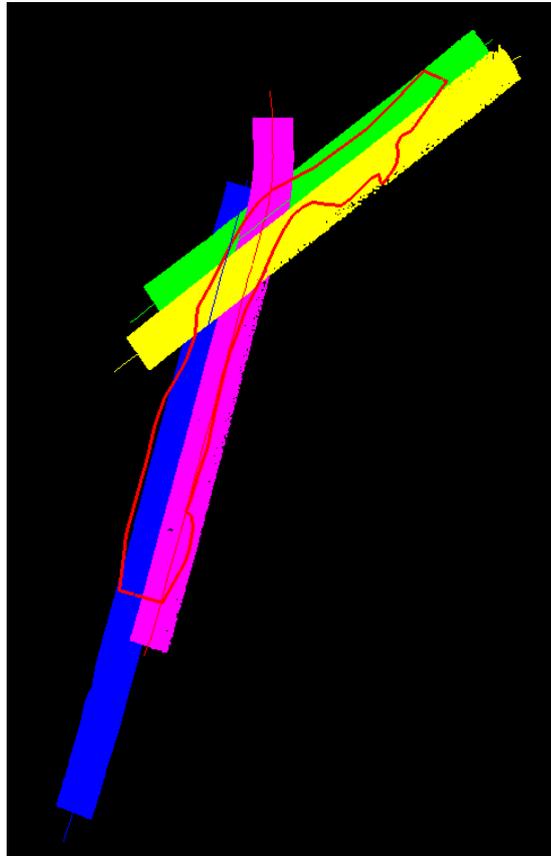
**Figura 17.** División de las ortoimágenes en partes en la zona utilizada para este proyecto.

### 3.2.3. Datos altimétricos LiDAR. Productos derivados.

Las características de los datos *LiDAR* tomados en Agosto de 2009 (Stereocarto, 2009) son:

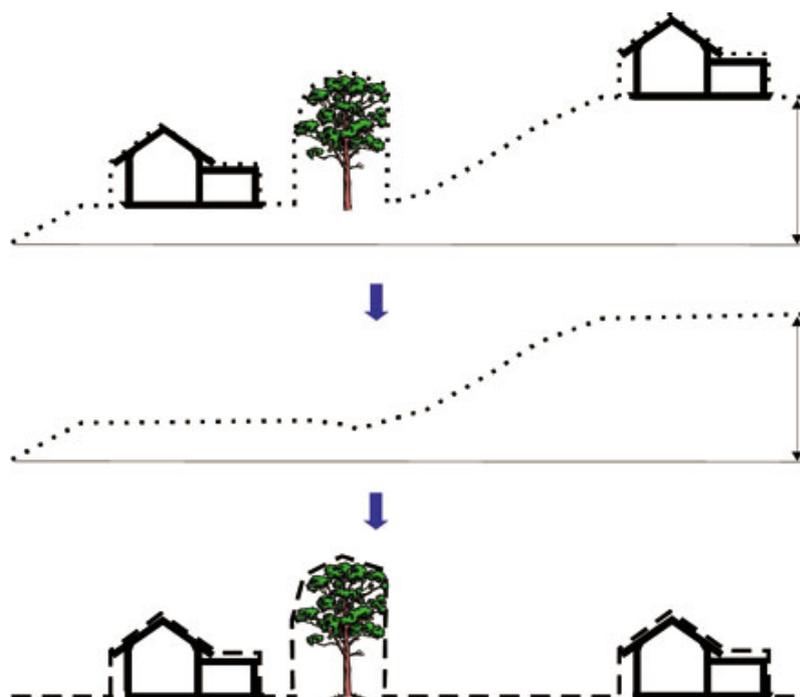
- Sensor empleado: ALS60 de *Leica Geosystems*®
- Altura de vuelo: 1.000 m.
- Número de pasadas: 4 (¡Error! No se encuentra el origen de la referencia.)
- FOV (*field of view*): 35°
- Ratio de pulso láser: 96100 Hz.
- Ratio de escaneo: 63,37 Hz.
- Densidad de puntos promedio: 1,61 puntos/m<sup>2</sup>

En la Figura 18 se observa la distribución de las pasadas LiDAR sobre la zona de estudio.



**Figura 18.** Distribución de las pasadas LiDAR sobre la zona de estudio (marco en rojo).

A partir de estos datos LiDAR se obtiene esta fuente de información de alto valor ya que nos permite la extracción en una determinada zona del Modelo Digital de Elevaciones (MDE) y el Modelo Digital de Superficie (MDS) obtenidos a partir del tratamiento de las nubes de datos LiDAR originales mediante el empleo de algoritmos de clasificación automática del terreno (o terreno desnudo) que, usualmente se encuentran en los software específicos de tratamiento de datos LiDAR, por ejemplo, TerraScan®, con el que han sido tratados los datos correspondientes a este trabajo. En la Figura 19 se observa que el primer dibujo representa el MDS. En el segundo dibujo se representa el MDE y en este último dibujo de la figura se obtiene en el denominado modelo digital de alturas de objetos (MDO) que es la diferencia entre un MDS y el MDE del suelo desnudo.



**Figura 19.** Representación, de arriba abajo, de MDS, MDT y MDO respectivamente.

Los resultados de MDE, MDS y MDO fueron igualmente divididos por hojas, siendo éstas coincidentes con las descritas en el apartado anterior (Figura 19) de forma que para cada hoja se tienen los datos de las 4 capas radiométricas y las 3 capas altimétricas.

#### **3.2.4. Datos catastrales usados para la obtención del *ground truth*.**

Los datos catastrales usados para la realización del proyecto fueron facilitados por la Administración Catastral de Almería. Estos datos fueron entregados en formato de CAD, en este caso, el archivo propio de AutoCAD® *dwg*. Los datos presentados por catastro presentaban problemas por la mala ordenación de la información en capas ya que en archivo en CAD aparece capas nombradas sólo con números por lo que para una mejor utilización de esta información se procedió a comprobar la utilidad de cada capa de información para nuestro trabajo. También estos datos presentaban problemas de emplazamiento de algunas casas, urbanizaciones y parcelas. Por lo que estos errores fueron en algunos casos rectificados y en otros modificados. En la Figura 20 y Figura 21 se muestran los errores que poseen los datos de la Administración. Los datos aun con errores nos sirvieron de gran utilidad, ya que nos permitió agilizar el proceso de generación del *ground truth*. Para la identificación de la información del archivo facilitado por catastro fue mediante la comparación de este archivo CAD con la información que se puede ver en la oficina virtual de catastro <https://www1.sedecatastro.gob.es>.

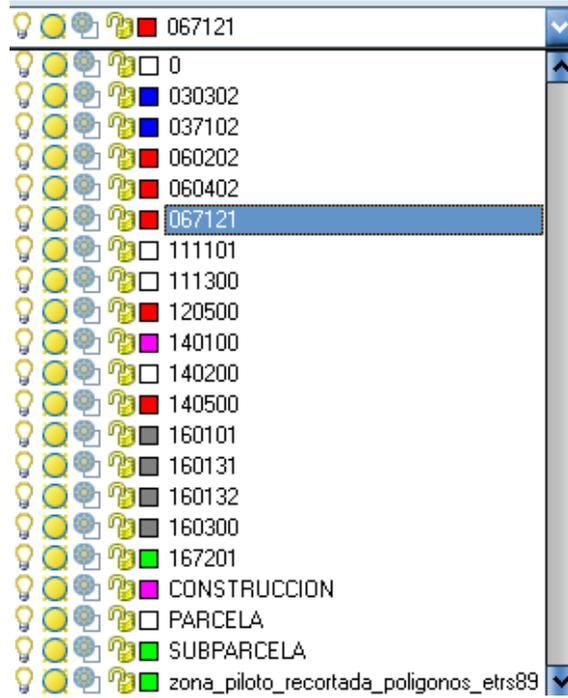


Figura 20. Capas en AutoCAD



Figura 21. Mala digitalización manual

### 3.3. METODOLOGÍA.

#### 3.3.1. Metodología para la segmentación y clasificación de imágenes basada en objetos.

La metodología para la segmentación y la clasificación de imágenes basada en objetos se realizó mediante el software *eCognition* v. 8.64®. La estrategia seguida en este proyecto fue la de ir dividiendo los objetos siempre en dos tipos de clases a través de un umbral que nos permite su clasificación en dos clases distintas.

La metodología comienza con la importación de los datos empleados referidos en los apartados 3.2.1 y 3.2.3, después se procedió a la segmentación a una escala grosera (con nivel de escala 600) de la imagen original a fin de obtener el conjunto de objetos más representativos posibles. Para proceder después a la clasificación de las clases *Mar* y *Tierra*, con el fin de separar los segmentos incluidos en la superficie marina, que no deben ser tenidos en cuenta ni como permeables ni como impermeable. A continuación se realizó otra segmentación más detallada (con nivel de escala 50) ya que de esta forma mediante un umbral nos permitía poder clasificar las clases *Objetos* y *No objetos*. Para seguir la clase *Objetos* se volvió a dividir mediante un umbral para obtener las clases *Objetos\_Sombras* y *Objetos\_No sombras*. Después tras esta clasificación se volvió a dividir los *Objetos\_No Sombras* en las clases *Árboles* y *Edificios* mediante el hallazgo de un nuevo umbral de clasificación.

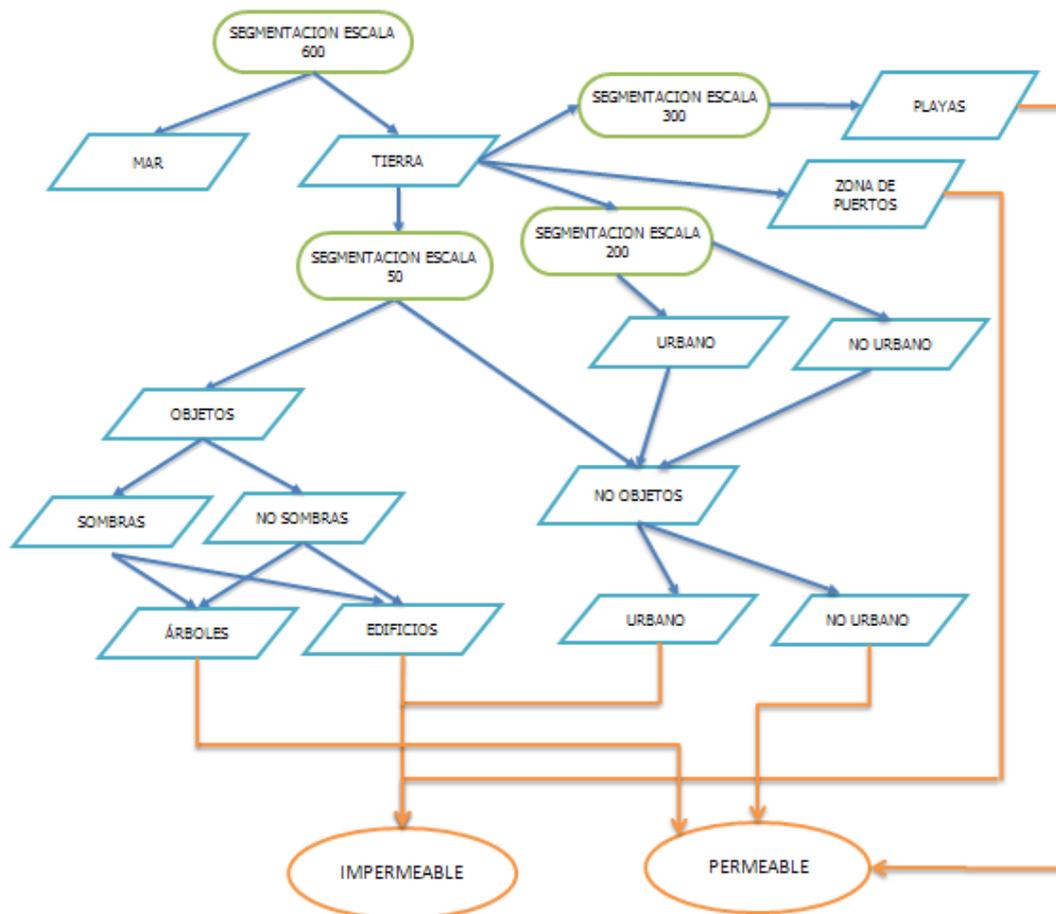
Para continuar con el proceso se realizó una segmentación a la escala intermedia (con nivel de escala 300) con el fin de, posteriormente, clasificar la clase *Playas*. La ultima segmentacion que se realizó fue en escala intermedia (nivel de escala 200) cuyo objetivo fue separar las clases de *Zona Urbana* y *No Urbana*. Posteriormente, toda la información de la escala 200 se pasó a la escala de referencia 50.

Para terminar se observó que las zonas portuarias no se clasificaron convenientemente, por lo que fue necesaria una subclasificación mas concreta.ó la *Zona de puertos* en la escala 600 mediante la aplicación de un triple umbral de clasificación.

Toda esta información de la escala 600, 300 y 200 se pueden incluir en la escala 50 debido a que los objetos de la escala 600 son superobjetos de los objetos de las demas escalas (300, 200 y 50).

Para concluir se procedió a la reagrupación de las clases *Urbano*, *Edificios* y *Zonas de Puertos* en una nueva clase llama *Zona Impermeable*, mientras que las clases *No Urbano*, *Playas* y *Árboles* fueron reclasificadas en *Zona Permeable*. A

continuación en la Figura 22 a modo de resumen se muestra el esquema de flujo de trabajo llevado a cabo para la clasificación y subclasificación de los objetos.



**Figura 22.** Esquema del flujo de trabajo llevado a cabo para la clasificación y subclasificación de los objetos. Los recuadros redondeados verdes corresponden a cada una de las segmentaciones llevadas a cabo. Por otro lado, los recuadros azules representan cada una de las clases-subclases, mientras que los círculos anaranjados corresponden a las súperclases finales.

### *3.3.1. a. Importación de los datos empleados.*

La importación de las ortoimágenes, estas están compuestas por 4 capas de información: el RGB (Rojo, Verde y Azul) e Infrarrojo Cercano y a parte de estas también se deben de incorporar los datos correspondientes a la Intensidad, y al modelo digital de Elevaciones entre los que ya hemos visto en el apartado 3.2.3: el modelo digital de objetos (MDO), el modelo digital de superficies (MDS) y el modelo digital del terreno (MDT). Tras la incorporación de la información vemos como en la Figura 23. Las capas anteriormente comentadas aparecen incorporadas en el nuevo proyecto.

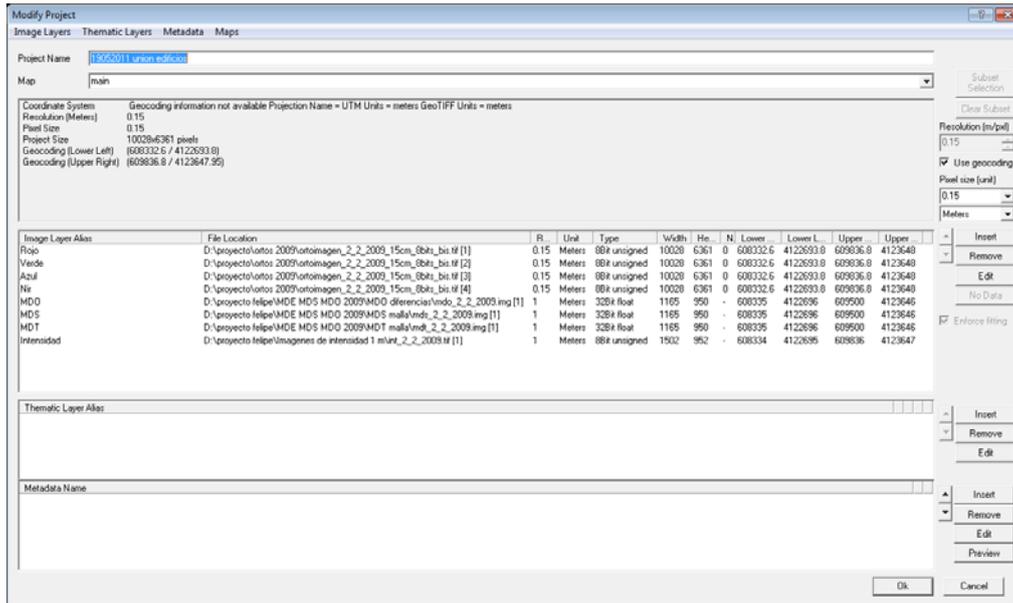


Figura 23. Importación de datos

En el software empleado se pueden definir inicialmente las áreas en las que no existen datos (*No Data*), 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 la cámara digital o 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 24).

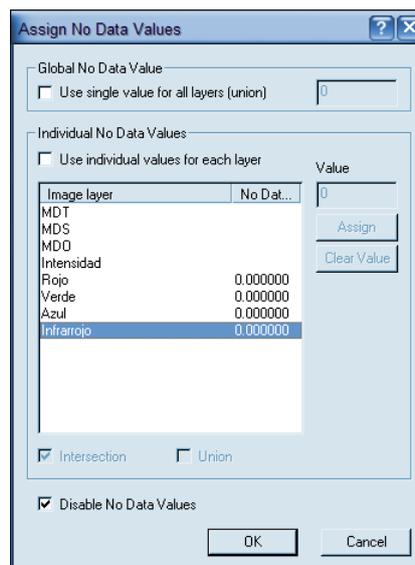
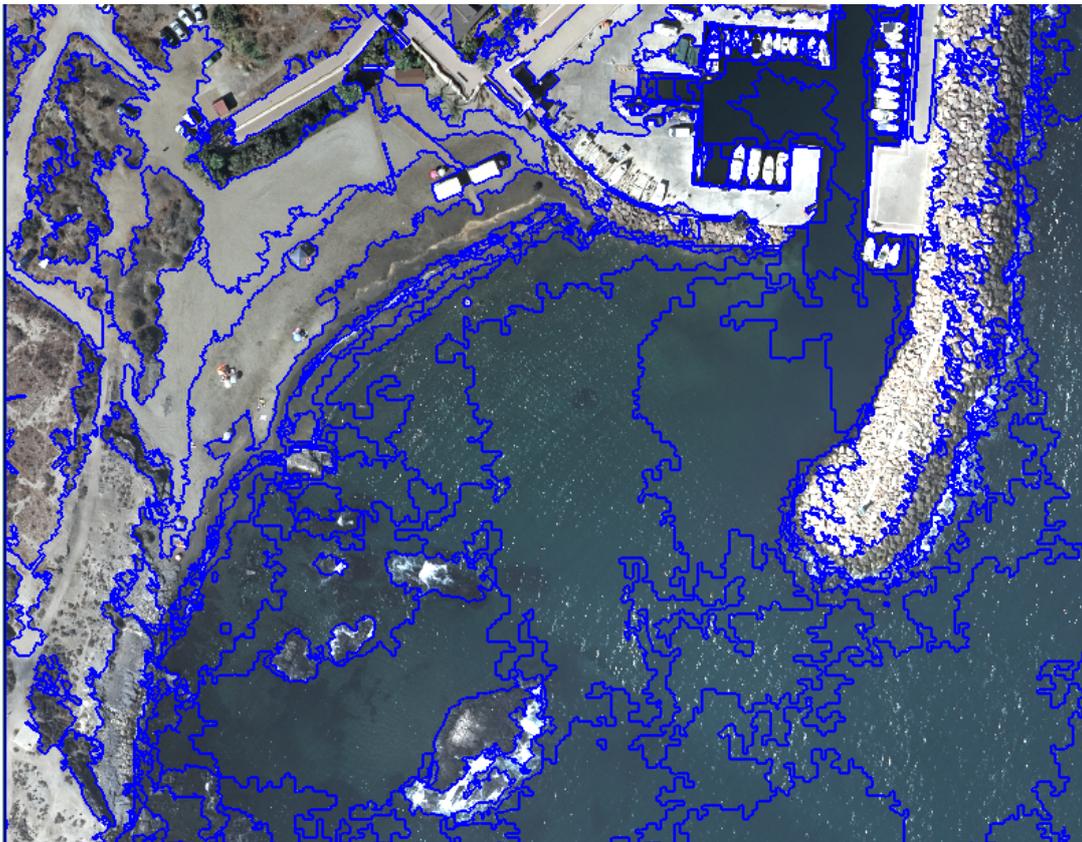


Figura 24. Asignación de valores sin datos.

### *3.3.1. b. Segmentación inicial.*

Esta parte inicial del trabajo comienza con la creación de objetos formados por agrupaciones de píxeles mediante *eCognition®*, para lo cual se realizó una segmentación multirresolución con nivel de escala 600 (escala grosera) con una forma de 0,3 y una compacidad de 0,5 (apartado 1.2.3). Las capas utilizadas para esta segmentación fueron el MDO, la Intensidad y el Infrarrojo Cercano (NIR). Los pesos utilizados para estas capas fueron los mismos. Esta escala se realizó con la intención de clasificar con facilidad las clases *Mar* y *Tierra*. Esta separación entre clase se llevo a cabo ya que lo que nosotros pretendíamos clasificar como *Permeable* o *Impermeable* era lo incluido en la clase *Tierra*, ya que la clase *Mar* no es ni permeable ni impermeable. Por lo que los objetos podían ser del máximo tamaño posible siempre y cuando se detectará bien la línea de costa que es el límite entre las clases *Mar* y *Tierra*. Debido a comprobaciones en anteriores segmentaciones los objetos obtenidos en escala inferiores eran muy pequeños y esto provocaba que existan mayores variaciones radiométricas mientras que si usábamos escalas superiores la línea de costa no quedaba bien definida. Por lo que tal y como muestra la Figura 25 la escala 600 delimita correctamente la línea de costa.

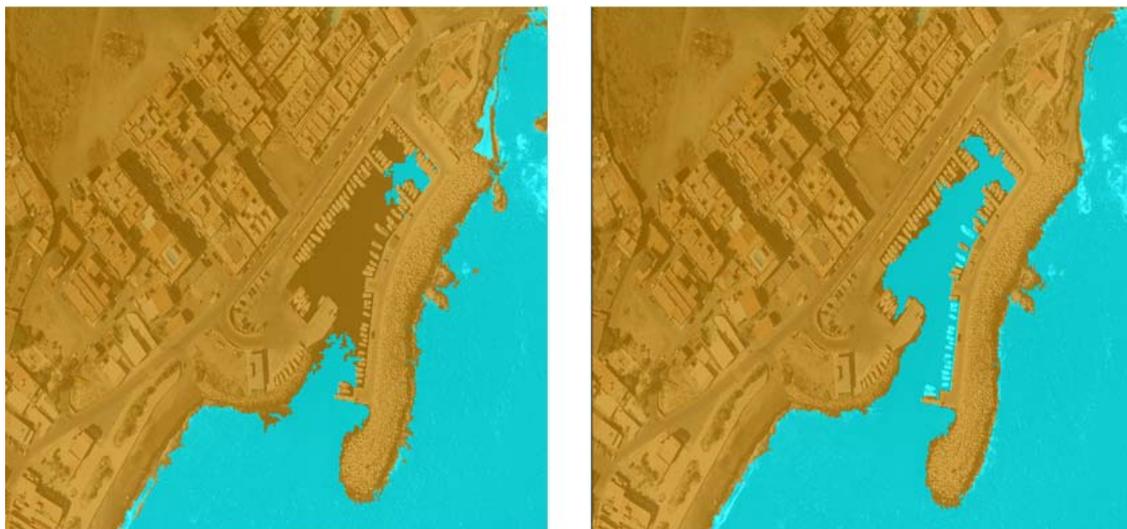


**Figura 25.** Ejemplo Segmentación escala 600.

### *3.3.1.c. Clasificación Mar-Tierra.*

Anteriormente a esta clasificación en el apartado anterior se realizó una segmentación multirresolución con nivel de escala 600 (escala grosera) con una forma de 0,3 y una compacidad de 0,5 (apartado 1.2.3). Las capas utilizadas para esta segmentación fueron el MDO, la Intensidad y el Infrarrojo Cercano (NIR). El objetivo de esta segmentación fue poder obtener la línea de costa, ya que esta es el límite entre las clases *Mar* y *Tierra*. Para posteriormente poder clasificar las clases *Mar* y *Tierra*. Esta separación entre clase se llevo a cabo ya que lo que nosotros pretendíamos clasificar como *Permeable* o *Impermeable* era lo incluido en la clase *Tierra*, porque la clase clasificada como *Mar* no es ni permeable ni impermeable. Para esta clasificación se introdujo un nuevo *Feature* llamado *Normalized Difference Vegetation Index* (Ecuación 1). Esta clasificación fue posible debido a que el *Mar* presenta valores de infrarrojo muy bajos, ya que la longitud de onda a la que se refiere es absorbida por las superficies acuáticas. En nuestro caso se encontró el umbral de que todo objeto que tuviera un valor  $NDVI < -0,24$  este sería clasificado como *Mar*. Mientras que para un valor de  $NDVI$  mayor o igual a  $-0,24$  esto sería clasificado como *Tierra*. Tras esta clasificación se observó que había algunas zonas en las que claramente era *Mar* y la había incluido en la clase *Tierra* por ejemplo el mar próximo al puerto marítimo, las crestas de las olas, pequeñas rocas e isletas innecesarias en nuestra clasificación, para resolver este error lo primero que se hizo fue hacer otra clasificación en la que todo lo que tuviera un infrarrojo menor a 30 fuera incluido en la capa *Mar* con esto se soluciona el problema que teníamos en la zona de los puertos deportivos. Tras esta reclasificación vemos que todavía hay zonas en *Mar* que están mal clasificadas como *Tierra*, esto se debe a las olas del *Mar* son de color blancas y estas poseen valores radiométricos distintos al mar, por lo que para solucionar el problema se aplicó la función del software *relative border*. Esta función sirve para determinar el ratio de la longitud de borde compartido de un objeto de la imagen (con cualquier objeto vecino asignado a una clase definida) del total de la longitud del borde. Para este caso se realizó con un valor de *relative border*  $\leq 0,45$  para la clase *Tierra*, es decir, que lo que este clasificado como *Tierra* sea reclasificado como *Mar* siempre y cuando este rodeado por *Mar* en un 45%. En la Figura 26 se observa el antes y el después de la reclasificación. En esta Figura 26 la clase *Tierra* es de color marrón y la clase *Mar* es de color azul claro.

$$\text{Ecuación 1: } NDVI = \frac{INFRARROJO - ROJO}{INFRARROJO + ROJO}$$

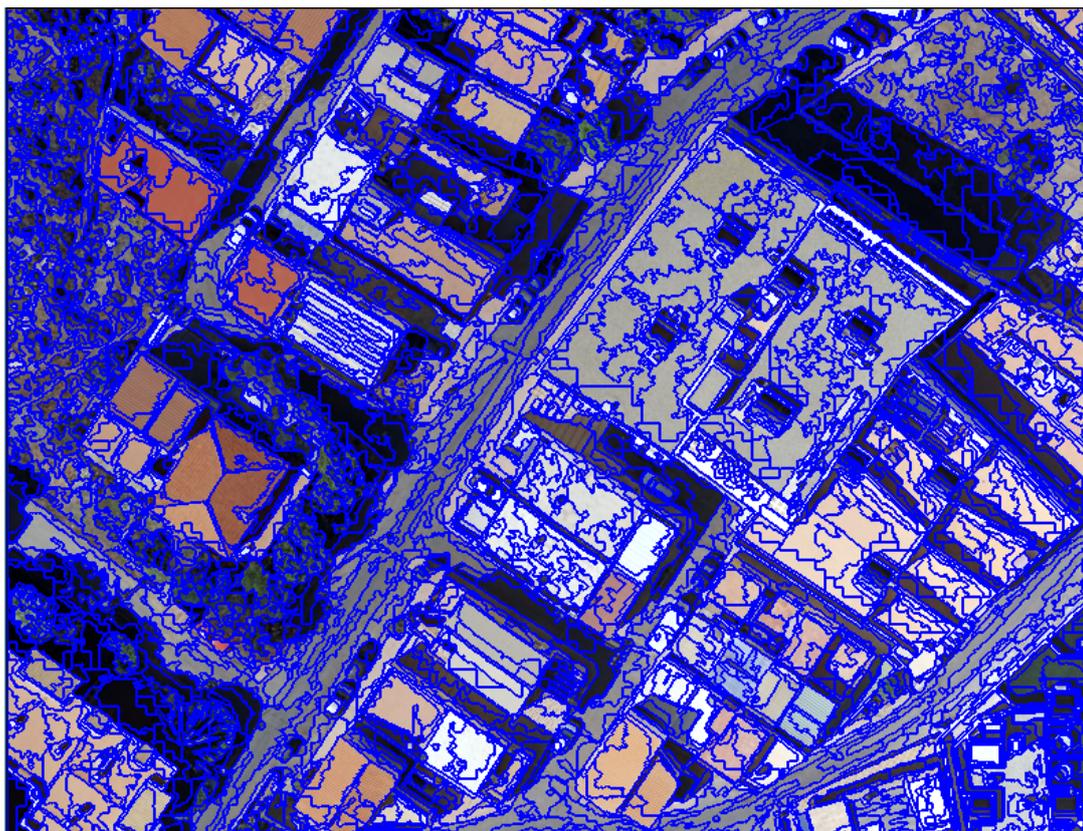


**Figura 26.** Antes y después de la reclasificación.

Tras la clasificación de las clases Tierra y Mar se segmentó la clase *Tierra* con una segmentación multirresolución de escala 50 se tomó como base la escala 600 con una forma de 0,1 y una compacidad de 0,5, para su posterior clasificación.

#### *3.3.1.d. Segmentación escala 50.*

La clase Tierra fue clasificada en la escala 600 para así no tener en cuenta la clase *Mar* en esta nueva segmentación. La segmentación multirresolución de escala 50 se tomó como base la escala 600, para que los objetos de la escala 50 fueran subobjetos de la escala 600, con una forma de 0,1 y una compacidad de 0,5. Las capas utilizadas para esta segmentación fueron el MDO, la Intensidad, el Infrarrojo Cercano (NIR) y el RGB. Los pesos utilizados para estas capas fueron los mismos. En la Figura 27 podemos ver un ejemplo de segmentación a escala 50. Esta segmentación se hace con el objetivo de poder clasificar los objetos de altura de los objetos que están a ras de suelo. Este nivel de segmentación fue escogido así ya que delimitaba correctamente los edificios y los árboles que son unas de las clases finales en la clasificación.

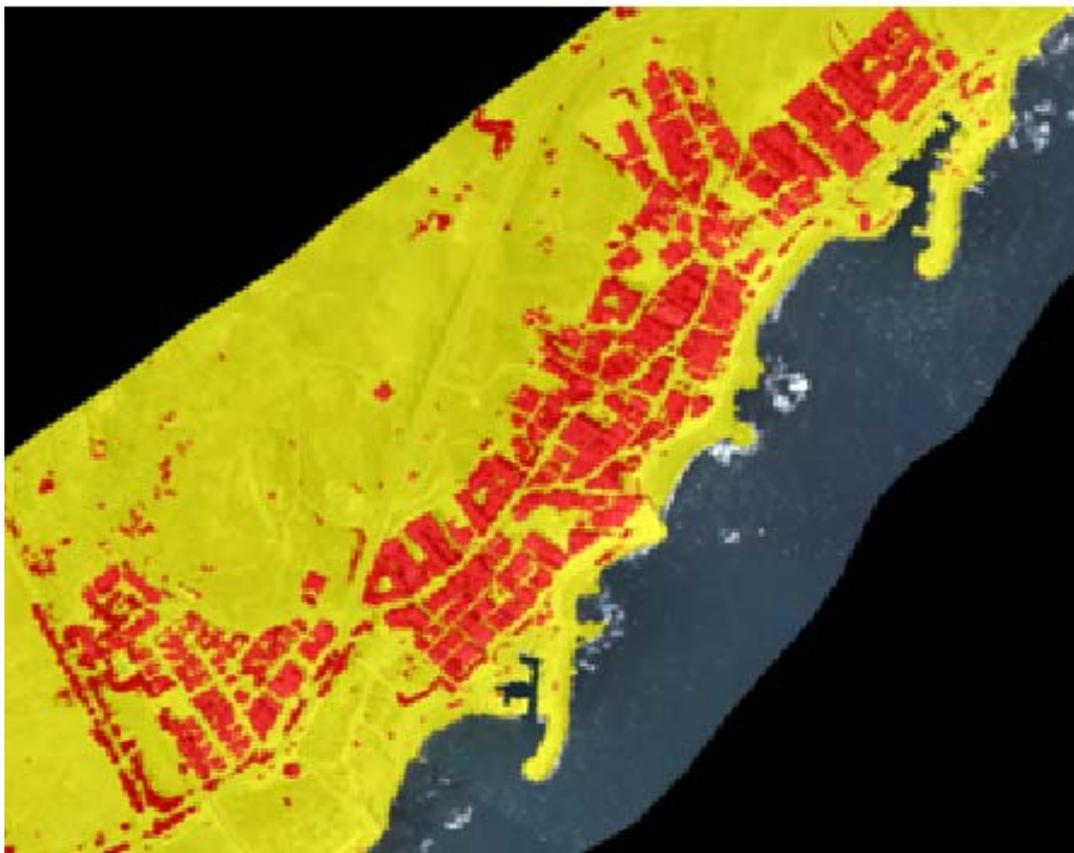


**Figura 27.** Ejemplo Segmentación escala 50.

#### *3.3.1.e. Clasificación Objetos-No Objetos.*

Tras la segmentación multirresolución de escala 50 tomando como base la escala 600 con una forma de 0,1 y una compacidad de 0,5. Este nivel de segmentación fue escogido así ya que delimitaba correctamente los edificios y los árboles que son unas de las clases finales en la clasificación.

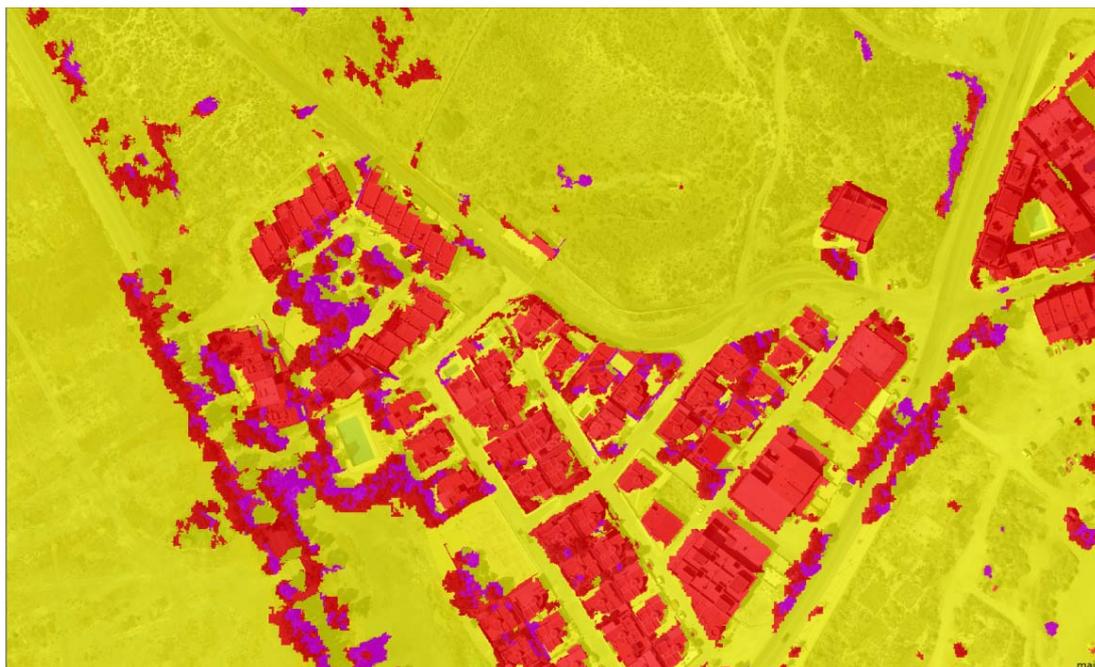
Se clasificó los objetos obtenidos tras esta segmentación en las clases las clases *Objetos* (Modelo Digital de Objetos o MDO mayor a 0,8 m) y *No Objetos* (MDO menor a 0,8 m). Las ventajas que nos da esta forma de clasificación es que podemos separar los objetos que poseen altura de los objetos situados a ras de suelo. Otra ventaja de este tipo de clasificación es que mediante la aplicación del MDO podemos clasificar en una clase mediante un mismo umbral todos los edificios lo que mediante la información radiométrica es complicado. En la Figura 28 se muestra los *Objetos* en color rojo y los *No Objetos* en color amarillo. Posteriormente se realiza otra clasificación para separar los *Objetos\_Sombras* y los *Objetos\_No Sombras* mediante el *Brighness o brillo*.



**Figura 28.** Clasificación de Objetos y No Objetos.

### *3.3.1.f. Clasificación *Objetos\_Sombras* y *Objetos\_No sombras*.*

Después de clasificar los objetos obtenidos, tras la segmentación multirresolución con nivel de escala 50, en las clases *Objetos* (MDO mayor a 0,8 m) y *No Objetos* (MDO menor a 0,8 m). A continuación tras varios intentos frustrados se detectó que dentro de lo ya clasificado como *Objetos* se podía separar los *Objetos\_Sombras* y los *Objetos\_No Sombras* para ello se aplicó la función *Brightness*, es decir, el brillo que se puede definir como la cantidad de oscuridad o claridad que tiene un color, es decir, representa lo claro u oscuro que es un color respecto de su color patrón. Tras varias pruebas con la modificación de los umbrales se obtuvo que para un valor menor e igual a 60 se clasificaban los *Objetos\_Sombras* y que para un brillo mayor a 60 se clasificó los *Objetos\_No Sombras*. El objetivo de esta clasificación era separar los *Objetos\_Sombras* de los *Objetos\_No Sombras*, para poder posteriormente dividir la clase *Objetos\_No Sombras* en las clases *Árboles* o *Edificios*. Como podemos ver en la Figura 29 en color magenta se representa la clase *Objetos\_Sombras*, en color rojo la clase *Objetos\_No sombras* y en color amarillo la clase *No Objetos*.

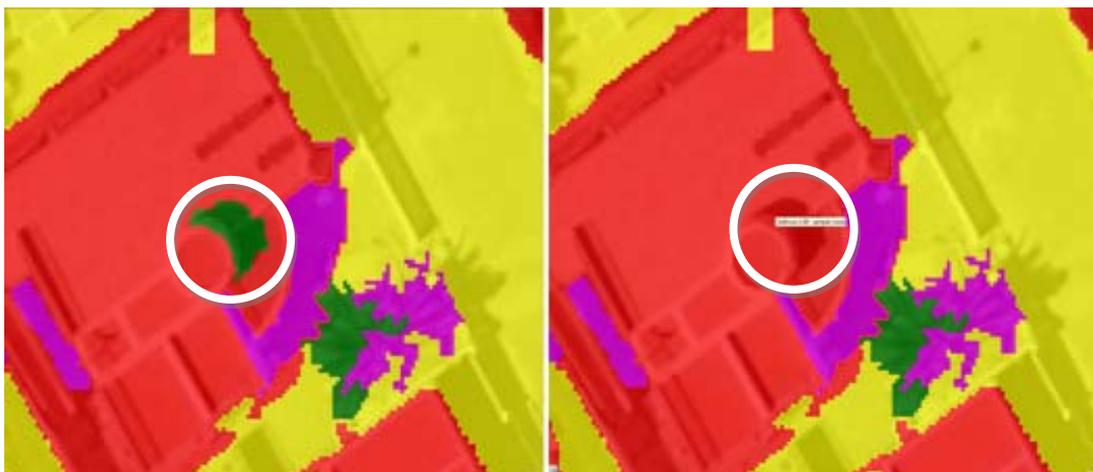


**Figura 29.** Clasificación Objetos\_Sombras y Objetos\_No sombras

### *3.3.1.g. Clasificación Edificios y Árboles.*

A continuación los *Objetos\_No sombras* de la escala 50 son divididos en dos subclases: *Edificios* y *Árboles* clasificado mediante el índice de vegetación de diferencia normalizada o NDVI. Se obtuvo el valor de 0,14 como valor diferenciador entre ambas clases, dado que dicho indicador es potencialmente diferenciador entre las clases vegetales y las no vegetales. La clase *Edificios* se clasificó con un valor de NDVI menor a 0.14 mientras que los *Árboles* fueron clasificados con NDVI mayor e igual a 0.14. Para afinar más en la clasificación reclassificamos los clasificados anteriormente como *Árboles* en *edificios* mediante la función densidad (calculada por el número de píxeles que forman el objeto de la imagen dividido por el radio del objeto), por lo que lo clasificado como *Árboles* con densidad menor a 1,1 sea reclassificado como *Edificios*. La utilización de esta función era porque se comprobó que los edificios tienen densidad baja a diferencia de los árboles cuyo valor de densidad es alto.

También se aplicó la función *relative border* para que todo árbol que esté rodeado por edificios en su totalidad, es muy probable que se trate de un edificio mal clasificado. De esta forma se consigue eliminar las zonas que fueron diferenciadas como árboles pero se veía claramente en la imagen que eran edificios (Figura 30).



**Figura 30.** Reclasificación de edificios.

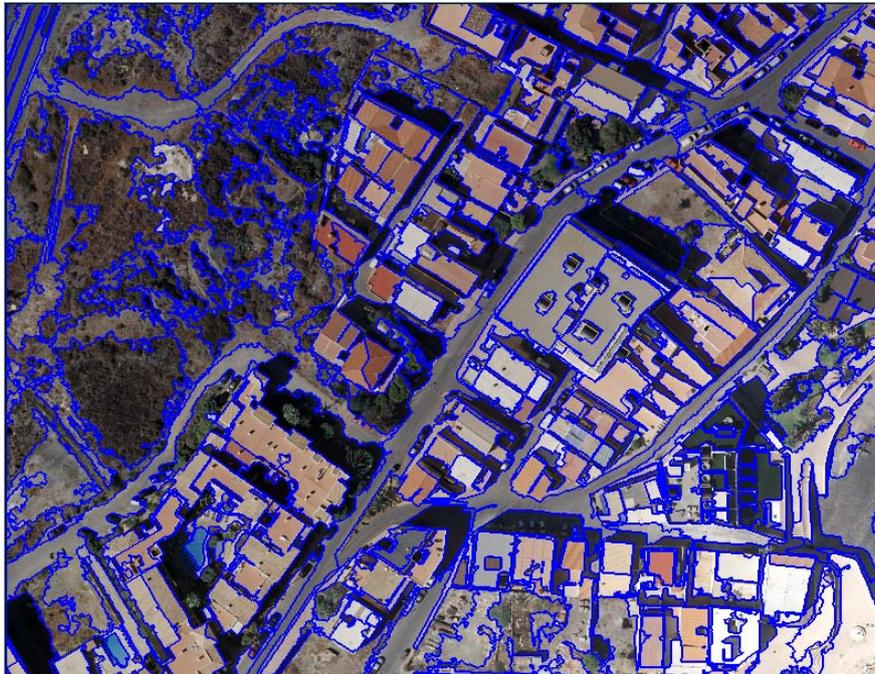
También se detectaron zonas que claramente son árboles y el programa los clasificaba mal como edificios debido a problemas radiométricos que posee las ortoimágenes. Para solucionar este problema se aplicó la función *merge* que lo que hace es fusionar o combinar los objetos vecinos siempre que ambos pertenezcan a la misma clase. Después de esto aplicamos la condición de que todo lo anteriormente clasificado como la clase *Edificios* cuya área fuese menor de 4000 píxeles se reclasificará como *Árboles* ya que no hay *edificios* tan pequeños. Posteriormente tras la clasificación de los *Objetos\_No sombras* en *Árboles* y *Edificios* se pasó a clasificar los *Objetos\_Sombras* en *Edificios* y *Árboles*.

### *3.3.1.h Clasificación Objetos\_Sombras en Edificios y Árboles.*

Tras la clasificación de los *Objetos\_No sombras* en *Edificios* y *Árboles* se continuó clasificando la clase *Objetos\_Sombras* en *Edificios* y *Árboles*. Para ello se aplica la función *relative border* para ambas clases. Así, para el caso de que una sombra estuviera rodeada en más del 50% por objetos de la clase *Edificios*, este sería también incluido en la clase *Edificios*. Mientras que en el caso de que una sombra estuviera rodeada en más del 50% por objetos de la clase *Árboles*, este sería también incluido en la clase *Árboles*. Esto se realizó para solucionar el problema de las sombras detectadas en medio de los árboles y en los tejados de los edificios. Una vez clasificado los *Objetos*, se realizó una nueva segmentación de escala 200 tomando como base los objetos de la escala 600.

### *3.3.1.i. Segmentación escala 200.*

Después de clasificar las sombras en Árboles y Edificios en la escala 50 se realizó una segmentación multirresolución de escala 200 se tomó como base la escala 600 con una forma de 0,3 y una compacidad de 0,5. Las capas utilizadas para esta segmentación fueron Canny que es extraída mediante el cálculo de la entropía de Canny (*GLCM Entropy Canny all directions*) cuyo interés esta segmentación es alto debido a que separa los objetos por variaciones de la textura. También se utiliza las capas de la Intensidad, el Infrarrojo Cercano (NIR) y el RGB. Los pesos utilizados para estas capas fueron los mismos. En la Figura 31 podemos ver un ejemplo de segmentación a escala 200. Debido a esta segmentación posteriormente se clasifica las clases *Urbano* y *No urbano*.

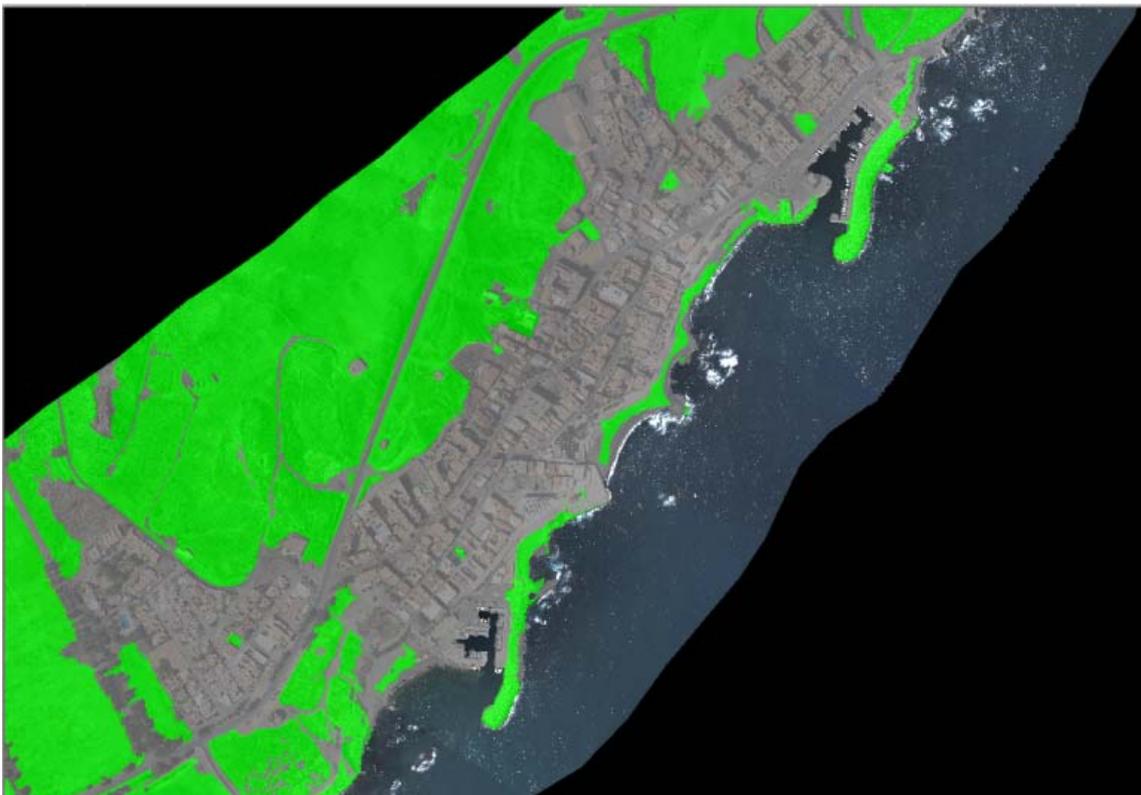


**Figura 31.** Ejemplo Segmentación escala 200

### *3.3.1.j. Clasificación Urbano y No Urbano.*

Tras finalizar en la clasificación de la clase *Objetos* se continúa con la clasificación de los *No Objetos* que eran aquellos cuyo MDO es menor a 0,8 metros (3.3.1.e.). Esta clase fue subdividida en *Urbano* y *No Urbano*. Para llegar a cabo esta clasificación lo primero que se realizó fue una nueva segmentación con escala 200, teniendo como base la escala 600. Se utilizó esta escala intermedia ya que pretendíamos clasificar objetos en la escala 600 se mezclaban las dos clases en un mismo objeto mientras que los objetos en la escala 50 eran tan pequeños que provocaba dificultades en la clasificación. A partir de aquí se crean dos clases: *Urbano* en las van a estar los objetos cuya altura sea mayor o igual de 0,8 metros y

cuya entropía de Canny (GLCM Entropy Canny all directions) sea menor a 6,5 cuyo color será gris. Mientras que en la clase *No Urbano* van a estar los objetos cuya altura sea menor de 0.8 metros y cuya entropía de Canny (GLCM Entropy Canny all directions) sea mayor a 6,5 y cuyo color será verde claro. El significado de esta segmentación es para poder clasificar mejor las zonas permeables. Para terminar toda esta información es relacionada mediante la función *existence of super objects*. Esta función permite relacionar superobjetos de la 200 con los subobjetos de la escala 50 (escala de referencia), esta relación es posible debido a que ambas escalas son subobjetos de la escala 600. En nuestro caso para la aplicación de esta función se puso de filtro la clase *No Objetos*, es decir, que solo queríamos que nos pasara la clasificación *Urbano* y *No Urbano* pero que solo tuviera en cuenta los clasificados como *No Objetos* en la escala 50. En la Figura 32 se muestra el resultado de la clasificación *Urbano* y *No Urbano* en la escala 200. Los objetos en color gris son los clasificados como *Urbano* mientras que los objetos en color verde son los clasificados como *No Urbano*.



**Figura 32.** Clasificación Urbano-No Urbano

### *3.3.1.k. Segmentación escala 300.*

Después de la clasificación en *Urbano* y *No Urbano* vemos que había zonas de playa mal clasificadas como *Urbano* (Figura 32). Por lo que se procedió a la clasificación de la clase *Playas* para esto se hace nueva segmentación multiresolución con escala 300 teniendo como base la escala 600. Las capas que tuvieron peso en la segmentación fueron Canny, la intensidad, el infrarrojo cercano (NIR) y el RGB con una forma de 0,1 y una compacidad de 0,5. En la Figura 33 podemos ver un ejemplo de segmentación a escala 300.



**Figura 33.** Ejemplo de segmentación en escala 300.

### *3.3.1.l. Clasificación Playa.*

Después de la clasificación en *Urbano* y *No Urbano* vemos que había zonas de playa mal clasificadas como *Urbano* por lo que se hizo nueva segmentación multiresolución con escala 300 teniendo como base la escala 600. Para clasificar la clase *Playa* se aplicó una doble condición en la que los objetos que incluiría esta nueva clase tenían que tener un valor de MDT menor o igual a 1,81 metros y una entropía de Canny (*GLCM Entropy Canny all directions*) mayor o igual a 5,8.

Para terminar se pasó de la escala 300 a la escala 50 (escala de referencia) mediante la función *existence of super objects*. Como podemos ver en la Figura 34 el resultado de clasificación de la clase *Playas* es bastante bueno (en color blanco).



**Figura 34.** Ejemplo de clasificación de *Playa*.

#### *3.3.1.m. Clasificación Zona de Puertos.*

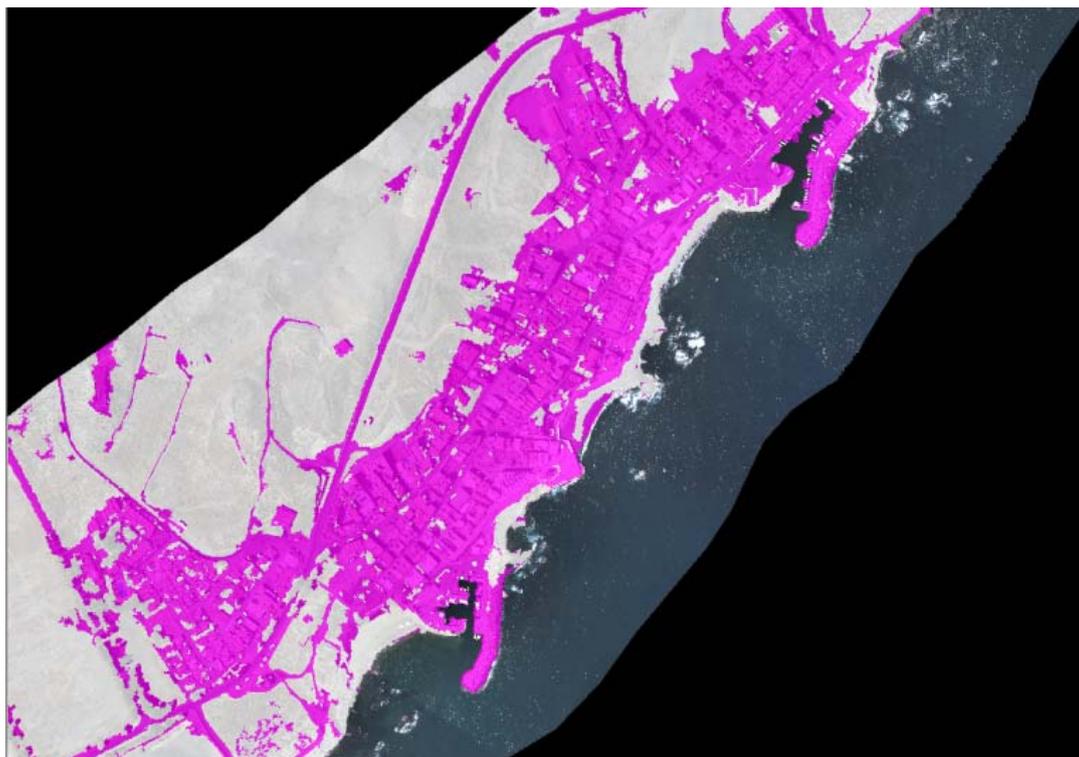
También se comprobó en la Figura 32 que la zona de puertos marítimos también estaba mal clasificada, por lo que se procedió a clasificarla como una clase. Para finalizar se clasificó la clase *Zona de Puertos* en la escala 600. Estas áreas fueron clasificadas, tras múltiples pruebas, mediante una triple condición: el valor del NDVI debía de ser mayor e igual a -0.19, menor e igual a -0.13 y su MDO mayor o igual a 0,2 metros. Para terminar se pasó de la escala 600 a la escala 50 (escala de referencia) mediante la función *existence of super objects* que permite la relación de superobjetos de la escala 600 con los subobjetos de la escala 50. En la Figura 35 se representa la clase *Zona de puertos* en color magenta.



**Figura 35.** Clasificación de *Zona de puertos*.

### *3.3.1.n. Clasificación Impermeable y Permeable.*

Para finalizar se lleva a cabo la clasificación final. Esta clasificación es el objetivo principal del desarrollo de este proyecto. Con todas las clases ya en la escala 50 (escala de referencia) se procedió a una nueva y última clasificación mediante la separación entre la clase *Impermeable* y la clase *Permeable*. En la clase *Impermeable* se encuentra las clases *Urbano*, *Edificios* y *Zonas de Puertos*. En la clase *Permeable* se encuentra las clases *No Urbano*, *Árboles* y *Playas*. Obteniéndose el resultado de la Figura 36 en la que se muestra en color magenta la clase *Impermeable* y en color blanco la clase *Permeable*. Como el objetivo principal era la obtención de estas dos clases, durante todo el proyecto se ha tratado de clasificar todas las clases desarrolladas en este apartado 3.3.1 teniendo claro que el objetivo principal era esta clasificación final.



**Figura 36.** Resultado clasificación final de la ortofotografía 2.2.

Para mayor claridad y simplicidad en la Tabla 1 se muestra a modo de resumen todo lo explicado anteriormente.

Nivel	Clasificación de clases	Relación con otros niveles
Escala 600	<i>Tierra, Mar y Zonas de Puertos</i>	50
Escala 300	<i>Playas</i>	600
Escala 200	<i>Urbano y No urbano</i>	600
Escala 50 (de referencia)	<i>Árboles y Edificios</i>	600 ,300 y 200

**Tabla 1.** Resumen de la clasificación según niveles

### 3.3.2. Metodología para la generación del "ground truth".

*Ground Truth* es un término utilizado en la cartografía, la meteorología, el análisis de fotografías aéreas, imágenes de satélite y una serie de otros sensores remotos en las técnicas que se recogen datos a distancia. El *ground truth* se refiere a la información que se recoge en el terreno mediante una clasificación o identificación manual por parte de algún operario. En teledetección, esto es especialmente importante para relacionar los datos de imagen a las características reales y materiales sobre el terreno. La colección de la "verdad" en el terreno y los

datos de suelo permiten la calibración de datos de teledetección, y ayuda en la interpretación y el análisis de lo que se está detectando.

Este *ground truth* se requiere para proceder a la comparación de este conjunto de datos o verdad absoluta con la clasificación que se va a realizar mediante teledetección.

Existen dos formas de extraer el *ground truth* de la imagen:

- Mediante la clasificación manual de las clases en todas las imágenes.
- Mediante la clasificación de un numero de muestra en todas las imágenes.

Utilizando una clasificación manual de las clases en todas las imágenes, la ventaja que tenemos es la compleción de este tipo de *ground truth* debido a abarca toda la zona a clasificar y a que cada clase que va a ser clasificada, es identificada en la zona de trabajo. Las desventajas que presenta este tipo de *ground truth* es que provoca un periodo largo de tiempo de trabajo para la su generación y las imperfecciones de clasificar manualmente, debido al proceso requerido de abstracción que hay que realizar al delimitar las áreas y a que ésta debe ser en todo momento constante, manteniendo unos mismos criterios en todo el área de trabajo. Como vemos en la Figura 37 la digitalización de agrupaciones de árboles se llevo mediante la generación de un polígono que contenga a todo el grupo de árboles, lo que resulta inapropiado si lo que se pretende representar es cada árbol por separado, por ejemplo, teniendo en cuenta que hay árboles que no son colindantes unos con otros.



**Figura 37.** Error provocado por la abstracción en la digitalización manual de grupos de árboles.

Otra forma de extracción del *ground truth* es extraer un número de muestras representativo que constituya un porcentaje del total adecuado con respecto a la zona de estudio. La ventaja es que la toma de muestra es muy rápida con respecto a la obtención completa del *ground truth*, aunque presenta la desventaja de que puede variar el acierto dependiendo de las muestras que se escojan, por lo que diversas pruebas pueden ser requeridas.

#### *3.3.2.1. Metodología para la digitalización manual de clases y generación del "ground truth".*

La digitalización de las clases sobre las ortoimágenes obtenidas se realizó mediante software CAD (AutoCAD®) y la formación de polígonos mediante polilíneas, generándose para cada clase una capa independiente de AutoCAD®. Las clases que, basadas en la identificación visual a través de la imagen original, se tuvieron en cuenta para realizar las capas son:

- Agua Mar
- Balsas
- Balsas Vacías
- Edificios
- Invernaderos
- Piscinas y fuentes
- Otras zonas impermeables
- Suelo desnudo
- Vegetación media-baja arbustiva densa
- Árboles
- Pistas deportivas
- Carreteras y caminos

En la Figura 38 vemos un ejemplo del trabajo realizado en el caso de la digitalización manual de un edificio:



**Figura 38.** Digitalización manual de los edificios.

Posteriormente estas clases fueron reclasificadas como zona impermeable y zona permeable. En la zona impermeable se incluyeron las Balsas, Balsas vacías, Edificios, Invernaderos, Piscinas y fuentes, Pistas deportivas, Carreteras y caminos y otras zonas impermeables. Para el caso de la zona permeable se incluyeron las capas: Suelo desnudo, Vegetación media-baja arbustiva densa y Árboles.

En el caso de los caminos se tuvieron como capa impermeable debido a que el paso de vehículos confiere al suelo las propiedades de una nula permeabilidad al paso del agua.

Para poder utilizar el *ground truth* para compararlo con la clasificación realizada en el software *eCognition*® primero se pasó el archivo de dibujo habitual sobre el software *Autocad*® (.dwg) a un tipo de fichero vectorial válido para su empleo en Sistemas de Información Geográfica (SIG) como *ArcGis*® (*shapefile* con extensión .shp). Posteriormente este archivo de *ArcGis*® es convertido a un archivo de imagen mediante la operación de rasterización que convierte la información espacial del modelo vectorial al modelo ráster. El fichero ráster utilizado ha sido *geotiff* (.geotiff), el cual está georeferenciado, y será el empleado para la comparación con la clasificación realizada mediante técnicas OBIA.

El paso del archivo tipo CAD a SIG vectorial se realiza de forma automática sobre el software *ArcGIS*® de forma que éste es capaz de leer directamente la información vectorial contenida sobre los polígonos, transformando las polilíneas cerradas en polígonos. Por lo tanto, el archivo SIG vectorial inicial corresponde a una capa de información donde la estructura es por polígonos.

Después de añadir el *ground truth* permeable e impermeable, ambos son cortados mediante la función *erase* de ArcGis® con la que podemos cortar un shapefile respecto de otro y poder evitar tener una zona impermeable que este clasificada como permeable y viceversa. Después de esto se procede a la unión de la zona impermeable y permeable con la función *merge* en ArcGis® (Figura 39).



**Figura 39.** Capas permeables e impermeables

En este punto aparece un problema con la información contenida en el *ground truth*, y es que, al digitalizar los bordes de los edificios, los polígonos exteriores a éstos (calles, caminos, etc.) quedan sin digitalizar, por lo que han de ser obtenidos mediante otro tipo de operaciones. Posteriormente, para obtener las carreteras se aplica de nuevo la función *erase*, así para obtener éstas se resta las capas permeable e impermeable a un shapefile que contiene solo un cuadrado, al restarlo se obtiene las carreteras, los caminos y unos “polígonos astilla” obtenidos debido a la imperfección de la digitalización manual (Figura 40).



Figura 40. Carreteras, caminos y polígonos astilla.

Posteriormente, tras observar los resultados obtenidos se hizo una separación de los objetos para poder borrar los polígonos con forma de astilla que quedan entre los polígonos. Para ello se aplicó la función "*multipart to singlepart*" que sirve para desagregar el polígono en varios polígonos más pequeños. A continuación, se eliminan los polígonos que no nos interesen y se procede a la unión mediante la función *merge* en ArcGis® de las carreteras y caminos con la capas impermeable, para posteriormente mediante la función *merge* en ArcGis® unir las capas permeable e impermeable (Figura 41).

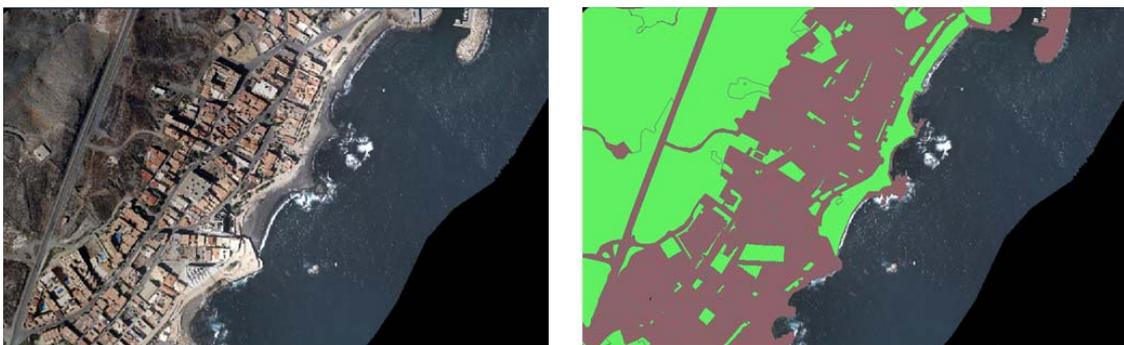


Figura 41. Resultado después de unir las capas impermeable y permeable.

Con el fin de que este *ground truth* sea comparado con la clasificación automática OBIA, será llevado a cabo sobre cada ortofotografía independientemente. Así el *ground truth* completo es recortado según la extensión de cada imagen, creando un total de 8 archivos. Finalmente, cada archivo es convertido de formato vectorial a formato ráster mediante la función *polygon to raster* de ArcGis. Para convertir los archivos de formato vectorial a raster debe mantener la misma resolución espacial que la de la ortoimagen original (0,20 m.), de forma que se pueda comparar, píxel a píxel, cada *ground truth* con la clasificación.

En este caso, el archivo ráster georreferenciado utilizado fue del tipo img. En la Figura 42 se muestra la información que contiene este archivo ráster. La capa impermeable se muestra en color negro mientras que la capa permeable se muestra en color blanco. Los valores digitales de ambas clases pueden observarse en la Tabla 2.



Figura 42. Resultado tras pasar a img.

Rojo(0-255)	Verde (0-255)	Azul(0-255)	Nombre Clases
0	0	0	Impermeable
255	255	255	Permeable

Tabla 2. Valor de cada nivel digital.

A continuación con ERDAS IMAGINE 9.1® se realiza la exportación de img a geotiff, ya que constituye el formato más adecuado para su uso en el software *eCognition®*, donde se realizará el control de precisión de la clasificación.

### *3.3.2.2. Metodología para la generación del “ground truth” a partir de muestras aleatorias.*

Lo primero que se realizó fue una segmentación multiresolución de escala 25 y con escala de base la escala 50 para así asegurarnos que las muestras seleccionadas al azar mediante el software MATLAB pertenecerían a un superobjeto de la escala 50. El número de muestras con el que se realizó esta experiencia fue de 100 muestras, 250 muestras y 500 muestras, para cada número de muestra se realizaron 4 repeticiones para así obtener una mayor fiabilidad. Estas muestras fueron clasificadas manualmente en *Permeable* o en *Impermeable* de forma que se comparó con la clasificación realizada mediante *eCognition®* y pudo observarse la relación entre la precisión de la clasificación y el número de muestras tomadas.

Con el fin de que este *ground truth* sea comparado con la clasificación automática OBIA, dicha comparación será llevada a cabo únicamente sobre la ortofotografía 2.2. El *ground truth* será recortado según la extensión de la imagen, creando un archivo. En la Figura 43 se observan las muestras impermeables y permeables utilizadas para la generación del *ground truth*. En color verde están las muestras impermeables y las muestras en color rojo se refieren a las muestras permeables.



**Figura 43.** Muestras impermeables y permeables.

Finalmente, este archivo es convertido a formato ráster mediante la función *polygon to raster* de ArcGis® con la resolución espacial igual a la de la ortoimagen original (0,20 m.), de forma que se pueda comparar, píxel a píxel, este *ground truth* con la clasificación. En este caso, el archivo ráster georreferenciado utilizado fue del tipo img. Después con *ERDAS IMAGINE 9.1*® se exporta el archivo de formato img al formato geotiff, ya que constituye el formato más adecuado para su uso en el software *eCognition*®, donde se realizará el control de precisión de la clasificación.

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

El siguiente paso en la verificación de la clasificación consiste en obtener de cada celdilla de la muestra su verdadera composición 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 celdillas 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 y riesgo del usuario. El primero de ellos consiste en la probabilidad de error en la que incurre el analista como consecuencia de la no inclusión de algunas 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 de lo clasificado mediante *eCognition®* y el *ground truth* ya sea el total (digitalización manual) o el *ground truth* muestral (identificación de distintas muestras). Para ello debemos cargar la máscara que se compone del *ground truth* en formato geotiff y un archivo csv compuesto de la forma que muestra la Tabla 3.

Id	Rojo(0-255)	Verde (0-255)	Azul(0-255)	Nombre Clases
0	0	0	0	Impermeable
1	255	255	255	Permeable

Tabla 3. Forma del archivo csv.

A continuación tras cargar la máscara, calculamos en evaluador de exactitud mediante la función *Accuracy Assessment* de *eCognition®* y en la pestaña que emerge seleccionamos la escala de referencia (por esto se debe de pasar los datos de otros niveles a la escala de referencia) y escogemos la opción Error basado en la máscara (*Error Matrix based on TTA Mask*) y comprobamos los resultados. Los valores que más nos interesan son los que se tienen un cuadrado alrededor en la Figura 44. El valor de *overall accuracy* es el acierto global que obtienes clasificando teniendo como punto de partida el *ground truth*.

Como vemos en la Figura 44, en el apartado de acierto (*accuracy*) tenemos un acierto de productor y usuario por cada clase que tenemos.

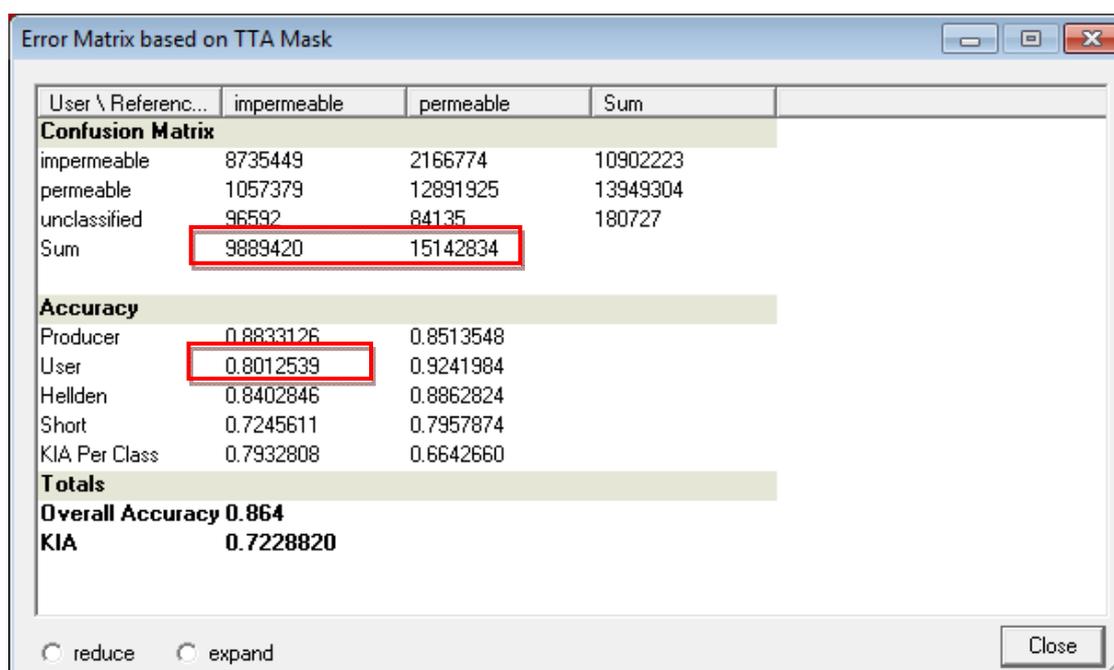
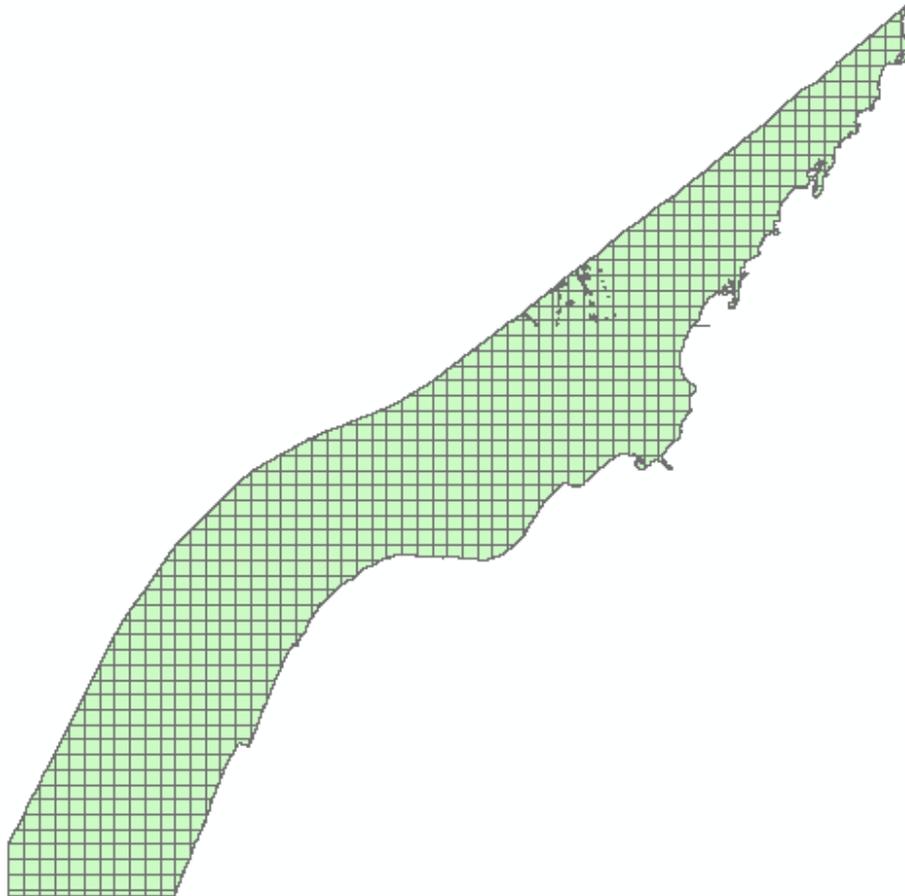


Figura 44. Resultado de la matriz de confusión de la ortofotografía 2.2.

### 3.3.4. Metodología para la representación parcelaria del porcentaje de impermeabilidad.

Tras la clasificación realizada mediante *eCognition*® se procedió a la exportación de los datos obtenidos en formato shapefile para que trabajar con ArcGis®. Para realizar la determinación del porcentaje de permeable e impermeable lo primero que se realizó fue mediante una segmentación *chessboard* con tamaño de objeto de 500 que en realidad representa un tamaño de 75 metros de lado para cada pequeño cuadrado (Figura 45).



**Figura 45.** Zona de estudio subdivida en cuadrados.

Posteriormente tras realizar esta segmentación se exporta, el resultado de esta segmentación que se muestra en la Figura 45, en formato shapefile para así poder comparar en ArcGis®, esta segmentación con la clasificación realizada en *eCognition*®. Y así obtener el área de cada cuadrado y para cada uno de estos cuadrados obtener el porcentaje de permeabilidad y el porcentaje de impermeabilidad. Posteriormente tras tener el valor de porcentaje de impermeabilidad para cada cuadrado, se puede obtener el porcentaje medio de impermeabilidad de la zona.

## CAPÍTULO 4

# RESULTADOS Y DISCUSIÓN

## 4. RESULTADOS Y DISCUSIÓN.

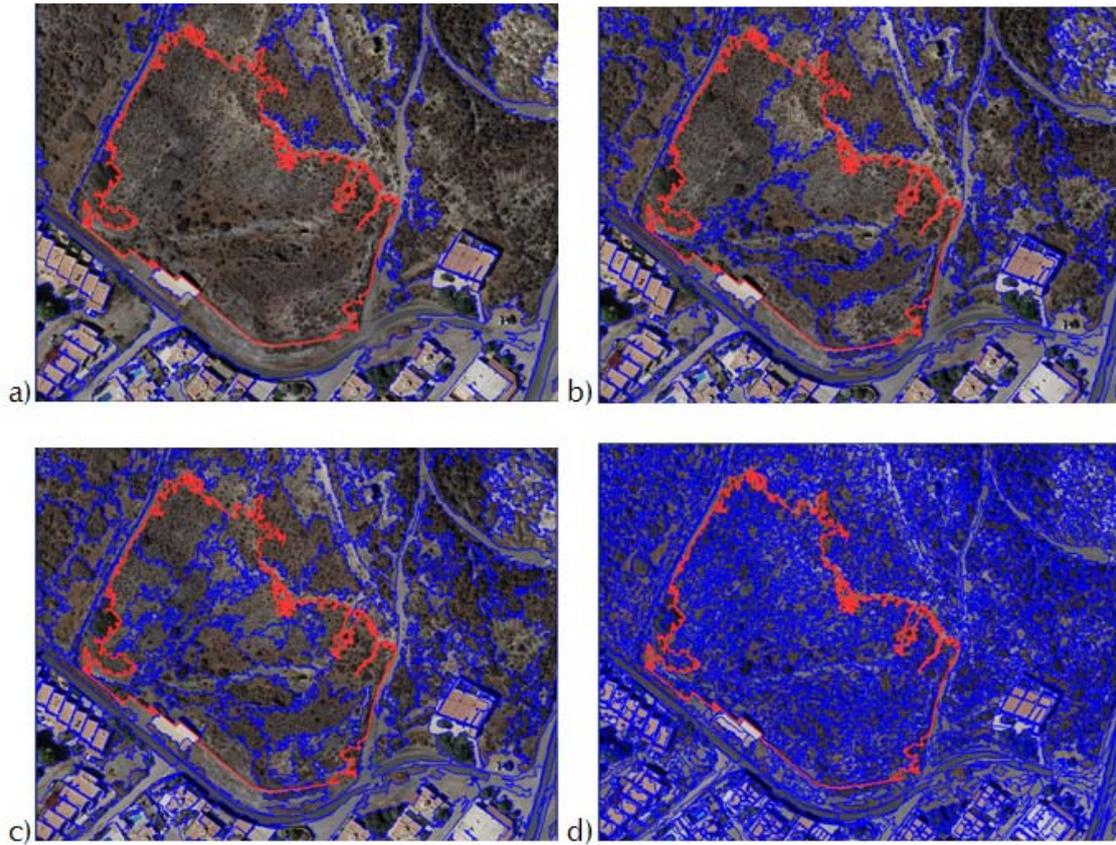
### 4.1 NIVELES DE SEGMENTACIÓN.

A continuación se va a desarrollar el capítulo de los resultados y discusión correspondiente, cuya metodología de trabajo ha sido explicada en el capítulo anterior. En la Tabla 4. Segmentaciones realizadas. se muestran las segmentaciones realizadas en este proyecto.

Escala	Procedencia (píxeles u otra escala)	Capas utilizadas	Shape	Compactness
600	Píxeles	MDO,Intensidad Y Nir	0,3	0,5
300	Escala 600	Canny,Intensidad, Nir + RGB	0,3	0,5
200	Escala 600	Canny,Intensidad, Nir + RGB	0,3	0,5
50	Escala 600	MDO,Intensidad, Nir + RGB	0,1	0,5

**Tabla 4.** Segmentaciones realizadas.

En la se muestran 4 imágenes para mostrar la diferencia de tamaño de objetos dependiendo de la escala utilizada. En la Figura 46 a se muestra en color rojo un objeto obtenido tras la segmentación mutirresolución en escala 600. En la Figura 46b se muestra como un objeto obtenido tras la segmentación mutirresolución en escala 600 en color rojo contiene a varios objetos obtenidos tras la segmentación mutirresolución en escala 300, En la Figura 46 c se muestra como un objeto obtenido tras la segmentación mutirresolución en escala 600 en color rojo contiene a algunos objetos obtenidos tras la segmentación mutirresolución en escala 200. En la Figura 46d se muestra como un objeto obtenido tras la segmentación mutirresolución en escala 600 en color rojo contiene a numerosos objetos obtenidos tras la segmentación mutirresolución de escala 50. Debido a que en las segmentaciones en escala 300, 200 y 50 se tuvo como nivel de base la segmentación realizada en la escala 600 podemos ver que en la Figura 46. Todos los objetos de la escala 300, 200 y 50 son subobjetos de un objeto de la escala 600, a través de esto se pudo establecer relaciones entre escalas.



**Figura 46.** Imágenes de segmentaciones a) Segmentación en escala 600 b) Segmentación en escala 300. c) Segmentación en escala 200.d) Segmentación en escala 50.

La justificación de la utilización de estas distintas segmentaciones es porque en el caso de la escala 600 era mejor la clasificación de *Mar y Tierra* ya que es más probable clasificar objetos si estos son más grandes. En el caso de la escala 50 se justifica su utilización debido a que para la clasificación de la clase *Árboles y Edificios* se observó que los objetos de la anterior segmentación eran muy grandes ya que incluían elementos que no queríamos clasificarlos en esta clase. En el caso de la escala 300 se utilizó para la clasificación de la clase *Playas*, ya que se observó que los objetos de la escala 600 eran muy grandes y los objetos de la escala 50 eran muy pequeños. En el caso de la escala 200 para la clasificación de la clase *Urbano y No urbano* se observó que los objetos de las anteriores segmentaciones eran muy grandes y los objetos de la escala 50 eran muy pequeños.

#### **4.2 RESULTADOS DE UMBRALES POR CLASIFICACIÓN.**

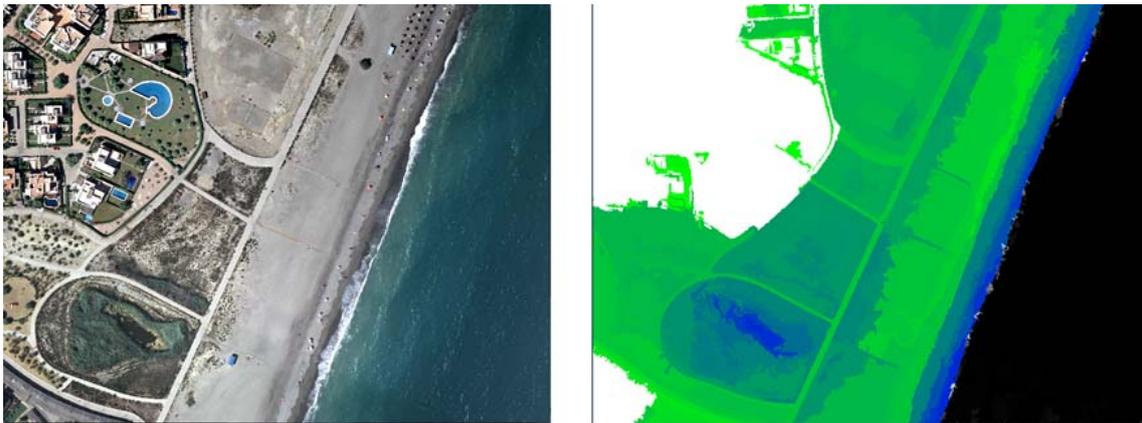
A continuación se va a mostrar los umbrales de clasificación para todas las clases utilizadas. Debido a la que la ortoimagen completa producía que se ralentizara el funcionamiento de este software, se procedió a la separación de la zona en ortoimágenes, tal y como se explica en el apartado 3.2.2. En los siguientes subapartados del capítulo 4.2 se van a mostrar los umbrales obtenidos para clasificar y a continuación se explicará la justificación de las variaciones en los umbrales de clasificación. Debidos principalmente a los siguientes errores que poseen las ortoimágenes:

- Cambios de color: este efecto se debe, al parecer, a la variación momentánea de las condiciones luminosas en el momento de la toma de imágenes, o bien a variaciones en el sensor (Figura 47). Esto provoca que en la ortofotografía 5.1 el resultado no sea tan bueno como en las demás.



**Figura 47.** Cambios de color.

- Cambios de altura: estos cambios son debido a la especial orografía que posee esta zona del levante almeriense que provoca que esta zona sea una zona de riesgo de inundaciones. En este ejemplo vemos como la playa tiene mayor valor de alturas (MDE) que algunas zonas del interior. La zona verde oscura de la derecha es la playa y la zona seleccionada (en rojo) es una zona interior que posee menor altura. En el rango de colores el azul representa donde se encuentra las zona con menor altura y según va tornando a verde son zonas de mayor altura. (Figura 48). Esto provoca que en la ortofotografía 5.1 el resultado no sea tan bueno (Tabla 12 del apartado 4.3.1)



**Figura 48.** Cambios de altura.

Zona de solape entre las ortofotografías: Este error provoca una zona de valores digitales nulos por la que no se puede analizar esa parte de la ortofotografía (Figura 49).



**Figura 49.** Zona de solape entre ortofotografías.

- Error provocado por MDO: la zona en rojo (Figura 50) no posee datos de MDO. En el área donde se produce (ortofotografía 3.1) el resultado es bueno pero el hecho de contar con los datos adecuados sería una posible mejora.



**Figura 50.** Zona sin datos MDO.

#### 4.2.1 Clasificación *Mar-Tierra*.

Siguiendo la metodología referida en el apartado 3.3.1c se realizó la clasificación de las clases *Mar* y *Tierra* en todas las ortoimágenes. Obteniéndose la **Tabla 4**. Segmentaciones realizadas. **Tabla 5** como umbrales de clasificación utilizados en cada una de las ortoimágenes.

Ortoimágenes	NDVI (índice)	Infrarrojo Cercano (NIR) (nivel digital)	Relative border (porcentaje)
1.2	-0,24	30	0,45
2.1	-	-	-
2.2	-0,24	30	0,45
3.1	-	-	-
3.2	-0,24	30	0,45
4.1	-0,24	30	0,45
4.2	-0,24	30	0,45
5.1	-0,24	30	0,45

**Tabla 5.** Umbrales utilizados para separar las clases *Mar* y *Tierra*.

En las capas 2.1 y 3.1 no se aplicaron las funciones para clasificar el Mar debido a que estas ortoimágenes no tienen zonas marítimas. Esta clasificación ha

sido una de las separaciones más sencillas, puesto que un único valor nos ha sido valido para todas las imágenes con zona marítima.

#### **4.2.2. Clasificación *Objetos-No Objetos*.**

Siguiendo la metodología referida en el apartado 3.3.1.e se realizó la clasificación de las clases *Objetos* y *No Objetos* en todas las ortoimágenes. Obteniéndose la Tabla 6 como umbrales de clasificación utilizados en cada una de las ortoimágenes.

<b>Ortoimágenes</b>	<b>MDO (m.)</b>
1.2	0,8
2.1	0,8
2.2	0,8
3.1	0,8
3.2	0,8
4.1	0,8
4.2	0,8
5.1	0,8

**Tabla 6.** Umbrales utilizados para separar las clases *Objetos* y *No Objetos*.

Esta clasificación ha sido en todas las imágenes igual debido a que este valor decidido mantener constante para todas las imágenes.

#### **4.2.3. Clasificación *Objetos\_Sombras* y *Objetos\_No sombras*.**

Continuando con la clasificación que aparece en el apartado 3.3.1.f se realizó la clasificación de las clases *Objetos\_Sombras* y *Objetos\_No Sombras* en todas las ortoimágenes. Obteniéndose la Tabla 7 como umbrales de clasificación utilizados en cada una de las ortoimágenes. Aun con variaciones radiométricas el valor del brillo no fue variado se mantuvo constante para mantener un árbol de proceso constante.

Ortoimágenes	Brillo (nivel digital)
1.2	60
2.1	60
2.2	60
3.1	60
3.2	60
4.1	60
4.2	60
5.1	60

Tabla 7. Umbrales utilizados para separar las clases Objetos\_Sombras y Objetos\_No Sombras.

#### 4.2.4. Clasificación *Edificios* y *Árboles*.

Siguiendo la metodología referida en el apartado 3.3.1.g se realizó la clasificación de las clases *Edificios* y *Árboles*. Obteniéndose la Tabla 8 como umbrales de clasificación utilizados en cada una de las ortoimágenes. El valor de NDVI que se usó para clasificar la clase *Árboles* fue mayor a 0,14 mientras que para clasificar la clase *Edificios* se realizó con valor menor a 0,14. Los valores de clasificación no se modificaron ya que se observó que con estos valores el resultado obtenido era bueno.

Ortoimágenes	NDVI (índice)	Densidad	Relative border (porcentaje)	Área (píxeles)
1.2	0,14	1,1	1	4000
2.1	0,14	1,1	1	4000
2.2	0,14	1,1	1	4000
3.1	0,14	1,1	1	4000
3.2	0,14	1,1	1	4000
4.1	0,14	1,1	1	4000
4.2	0,14	1,1	1	4000
5.1	0,14	1,1	1	4000

Tabla 8. Umbrales utilizados para separar las clases Edificios y Árboles.

#### 4.2.5. Clasificación *Objetos\_Sombras* en *Edificios* y *Árboles*.

Tal y como vimos en el apartado 3.3.1.h se realizó la clasificación de las clases *Edificios* y *Árboles*. Obteniéndose la Tabla 9 como umbrales de clasificación utilizados en cada una de las ortoimágenes. Los valores se decidió dejarlos así ya que era la mejor forma de clasificar los *Objetos\_Sombras* en *Edificios* y *Árboles*.

Ortoimágenes	Relative border to Árboles (porcentaje)	Relative border to Edificios (porcentaje)
1.2	0,5	0,5
2.1	0,5	0,5
2.2	0,5	0,5
3.1	0,5	0,5
3.2	0,5	0,5
4.1	0,5	0,5
4.2	0,5	0,5
5.1	0,5	0,5

Tabla 9. Umbrales utilizados para separar los *Objetos\_Sombras* en las clases *Edificios* y *Árboles*.

#### 4.2.6. Clasificación *Urbano* y *No Urbano*.

Siguiendo la metodología referida en el apartado 3.3.1.j se realizó la clasificación de las clases *Edificios* y *Árboles*. En esta clasificación como puede observarse en la Tabla 10 los umbrales de clasificación de Canny se modificaron ya que debido a las variaciones radiométricas si se mantenía los valores en algunas zonas se obtenía una mala clasificación final.

Ortoimágenes	Canny	MDO (m.)
1.2	6,5	0,8
2.1	6,1	0,8
2.2	6,5	0,8
3.1	6,1	0,8
3.2	6,5	0,8
4.1	6,5	0,8
4.2	6,5	0,8
5.1	6,1	0,8

Tabla 10. Umbrales utilizados para separar las clases *Urbano* y *No Urbano*.

#### 4.2.7. Clasificación *Playa*.

Si observamos el apartado 3.3.1.l se realizó la clasificación de la clase *Playas* en todas las ortoimágenes de la forma que muestra la Tabla 11 . Debido a problemas encontrados para clasificar esta clase bajo un mismo umbral se realizaron modificaciones según cada ortoimagen. Debido a los cambios de altura en las playas y a que en algunos casos mediante la aplicación de Canny se podía clasificar correctamente la clase *Playas*.

Ortoimágenes	Canny	MDT
1.2	-	$3,5 < \text{MDT} > 0$
2.1	-	$3,5 < \text{MDT} > 0$
2.2	5,8	$\text{MDT} < 1.81$
3.1	5,8	$\text{MDT} < 1.81$
3.2	-	$\text{MDT} < 1,5$
4.1	-	$\text{MDT} < 2,5$
4.2	-	$\text{MDT} < 2,7$
5.1	-	$\text{MDT} < 1,5$

Tabla 11. Umbrales utilizados para clasificar la clase Playas.

Debido a que la obtención de la clase *Playa* en la ortoimagen 5.1 era muy mala se optó por aplicar una condición que clasificará en esta clase aquellos objetos que estuviera a igual o menor distancia de 550 píxeles a una línea paralela a la línea de costa. Esta condición solo se utilizó para esta imagen, por lo que ni se usó en las otras imágenes que poseen zonas marítimas ni mucho menos en las imágenes sin zona marítima.

#### 4.2.8. Clasificación *Zona de Puertos*.

Siguiendo la metodología referida en el apartado 3.3.1.m se realizó la clasificación de la clase Zona de Puertos, pero debido a que esta clase no se encuentra en ninguna ortoimagen más que la ortoimagen 2.2 no se volvió a aplicar este umbral. Para clasificar la clase Zona de Puertos se hizo mediante una triple condición: el valor del NDVI debía de ser mayor e igual a -0.19, menor e igual a -0.13 y su MDO mayor o igual a 0,2 metros. Debido a la imposibilidad de clasificar esta zona mediante un único umbral se optó por esta opción de una clasificación mediante una triple condición.

#### 4.2.9 Clasificación *Impermeable* y *Permeable*.

Esta clasificación es el resultado final del proyecto. Esta clasificación depende totalmente de las clasificaciones anteriormente, por lo que una mala clasificación anterior provoca malos resultados. Esta clasificación es la que se compara con el *ground truth* total obteniéndose los resultados que aparecen en el apartado 4.3.1.

#### 4.3 RESULTADOS DEL ACCURACY ASSESSMENT.

##### 4.3.1 Resultados para la digitalización manual de clases y generación del "*ground truth*".

Tras el largo proceso de la clasificación de todas las imágenes en la que se realizó la clasificación de las clases *Mar* y *Tierra*, después se continuó con la clasificación de las clases *Objetos* y *No Objetos* subdividiendo esta última clase en Urbano y No Urbano. Mientras que los *Objetos* se dividían en *Árboles* y *Edificios*. Para continuar se procedió a la clasificación de las *Playas* y *Zonas de Puertos* debido a que se encontraban mal clasificadas y por último se reclasificó las clases *Árboles*, *No urbano* y *Playas* como la clase *Permeable* y también se clasificó la *Zona de Puertos*, la clase *Urbano* y la clase *Edificios* como la clase *Impermeable*. Tras esto se procedió a realizar la comparación entre lo clasificado por *eCognition®* y el *ground truth* total. Obteniéndose en este tipo de clasificación un acierto medio del 84,6%. Como podemos en la Tabla 12 podemos observar los aciertos globales para cada ortoimagen y también podemos observar la fiabilidad del productor y del usuario para clasificar tanto la clase *Permeable* como la clase *Impermeable*.

Parte	Acierto Total (%)	Fiabilidad del productor (%)		Fiabilidad del usuario (%)	
		Impermeable	Permeable	Impermeable	Permeable
1.2	86,77	84,07	87,67	70,99	94,32
2.1	81,21	56,79	89,57	72,56	86,17
2.2	86,40	88,33	85,14	80,13	92,42
3.1	82,29	57,90	88,45	58,08	89,51
3.2	85,28	75,65	86,87	49,66	95,58
4.1	81,88	88,98	79,64	57,96	95,82
4.2	95,14	29,23	97,06	22,53	97,92
5.1	78,24	89,13	70,10	69,04	89,61

Tabla 12. Porcentaje de acierto de todas las ortofotografías.

En los resultados del *ground truth* completo podemos observar cómo tanto en la fiabilidad del productor como en la fiabilidad del usuario los porcentajes de acierto son más bajos en la clase *Impermeable* que en la clase *Permeable*. Por lo que muestra en la tabla anterior la clasificación tiende más a errar clasificando la clase *Impermeable*. Tal y como vemos en la tabla anterior los resultados de la clasificación en la imagen 4.2, en lo referente al acierto total se muy buen porcentaje de acierto pero tal y como vemos tanto la fiabilidad del productor como la fiabilidad del usuario para la clase *Impermeable* es muy baja ya que las zonas impermeables en esta imagen son muy escasas por lo que si no clasifica correctamente alguna el porcentaje de error es muy alto. Esto también ocurre aunque en menor medida en las imágenes 2.1 y 3.1.

#### **4.3.2 Resultados de la clasificación mediante un número de muestras determinadas.**

Tras la muestra de los resultados del primer objetivo del proyecto procedemos a la muestra de resultados del segundo objetivo, es decir, a continuación se muestran los resultados de clasificación para el caso de *ground truth* obtenido a partir de un número limitado de muestras en la ortofotografía 2.2.

Tal y como muestra la Tabla 13 en este caso el acierto total varía entre el 83% y el 92 % y también podemos ver como los valores de fiabilidad del productor y la fiabilidad del usuario salvo alguna excepción muestra unos resultados muy buenos.

	Numero de muestras	Acierto Total (%)	Fiabilidad del productor (%)		Fiabilidad del usuario (%)	
			Impermeable	Permeable	Impermeable	Permeable
Sample A	100	84,08%	84,10	84,06	81,34	86,85
Sample B	100	90,93%	90,51	91,14	83,49	95,11
Sample C	100	84,20%	85,60	83,64	67,52	94,22
Sample D	100	86,93%	86,55	87,13	82,75	91,60
Sample E	250	83,20%	85,85	81,83	70,99	92,17
Sample F	250	87,40%	86,57	89,12	94,35	77,06
Sample G	250	88,28%	93,14	84,80	81,57	94,58
Sample H	250	86,10%	92,68	82,48	74,64	95,43
Sample I	500	89,51%	91,12	86,05	81,06	93,09
Sample J	500	91,22%	90,33	91,73	86,30	94,43
Sample K	500	89,13%	90,25	88,45	83,16	93,76
Sample L	500	89,94%	95,59	86,41	82,06	96,91

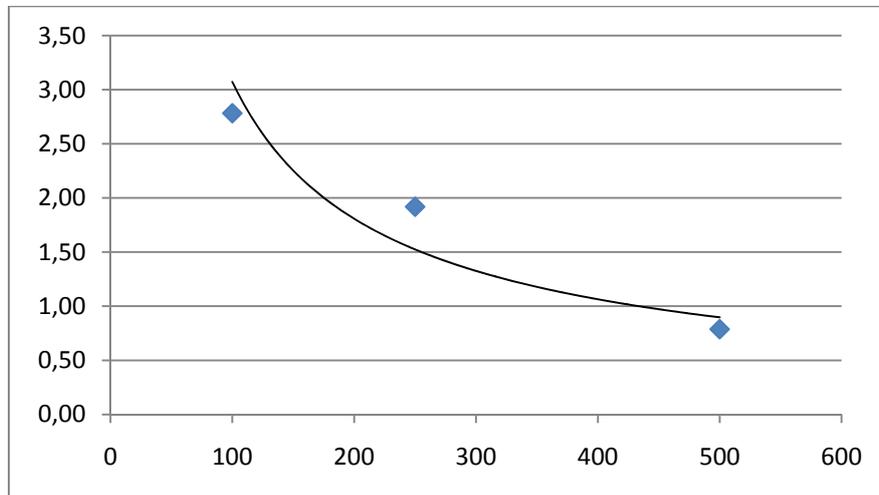
Tabla 13. Resultado de *ground truth* por muestras.

La explicación es porque al ir tomando cada vez mas muestras vemos que los porcentajes van aumentando y la variación entre ellos porcentajes de acierto es menor. Para explicar esto se procedió al cálculo de la desviación estándar que es un valor que muestra la concentración o dispersión de los valores obtenidos. En la Tabla 14 se muestra el valor de la desviación estándar según el número de muestras.

Numero de muestras	Desviación estándar ( $\sigma$ )
100	2,78%
250	1,92%
500	0,78%

Tabla 14. Desviación estándar según el número de muestras.

Si representamos en el eje de abscisas el número de muestras y en el eje de ordenadas la desviación estándar. A partir de estos datos comprobamos según la Figura 51 que a mayor cantidad de muestras menor va a ser la desviación estándar y por tanto mejor resultado medio vamos a obtener.



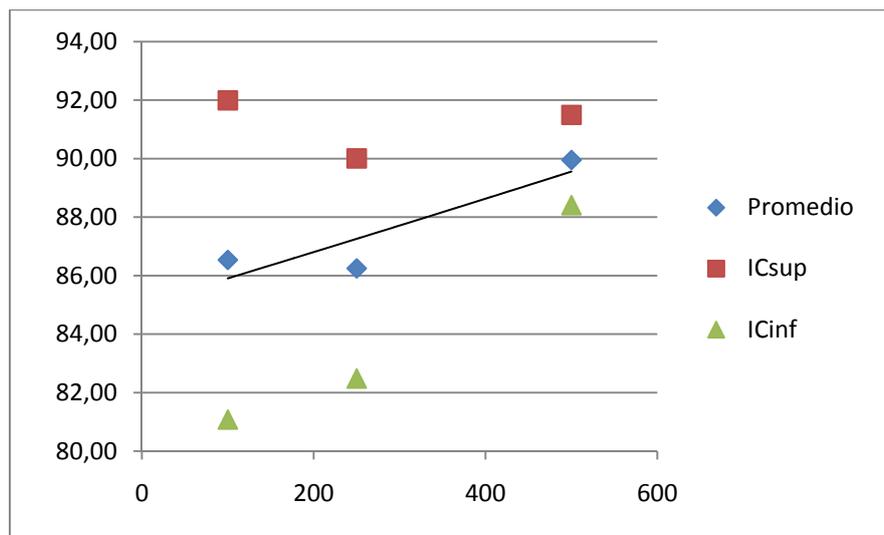
**Figura 51.** Representación grafica de la desviación estándar según numero de muestras.

También hemos dicho en la página anterior que a mayor número de muestras menor dispersión. Para comprobar esto se procede al cálculo del llamado intervalo de confianza cuya fórmula es  $IC = Media \pm \sigma * 1.96$ , por lo que tenemos un Intervalo de confianza superior y otro inferior (Tabla 15):

Numero de muestras	IC superior	Promedio	IC inferior
100	91,99%	86.54%	81,08%
250	90,01%	86.25%	82,48%
500	91,49%	89.95%	88.41%

**Tabla 15.** Intervalos de confianza según número de muestras.

Todo lo anterior se puede observar en la Figura 52:



**Figura 52.** Intervalo de confianza (IC) según número de muestras.

Tras comprobar según el número de objetos que con los conjuntos de 500 muestras se obtiene un intervalo de confianza significativamente menor. A continuación en la Tabla 16 vemos que a través del número de píxeles de cada muestra podemos destacar que a mayor número de píxeles mejor verificación vamos a obtener ya que el error posible por la mala identificación de alguna muestra, acarrearía un error menos sensible sobre el total.

Nombre de la muestra	Número	%
100samplea	33079	84,08
100sampleb	37345	90,93
100samplec	36119	84,20
100sampled	35159	86,91
250samplee	86897	83,20
250samplef	95819	87,40
250sampleg	91585	88,28
250sampleh	98147	86,10
500samplei	188259	89,51
500samplej	180632	91,22
500samplek	200904	89,13
500samplel	203840	89,94

**Tabla 16.** Porcentaje de acierto según número de píxeles.

Si representamos en el eje de abscisas el número de píxeles y en el eje de ordenadas el porcentaje de acierto. Obtenemos una figura como la Figura 53, en que extraer la conclusión a que la dispersión del resultado es menor cuanto mayor es el número de píxeles.

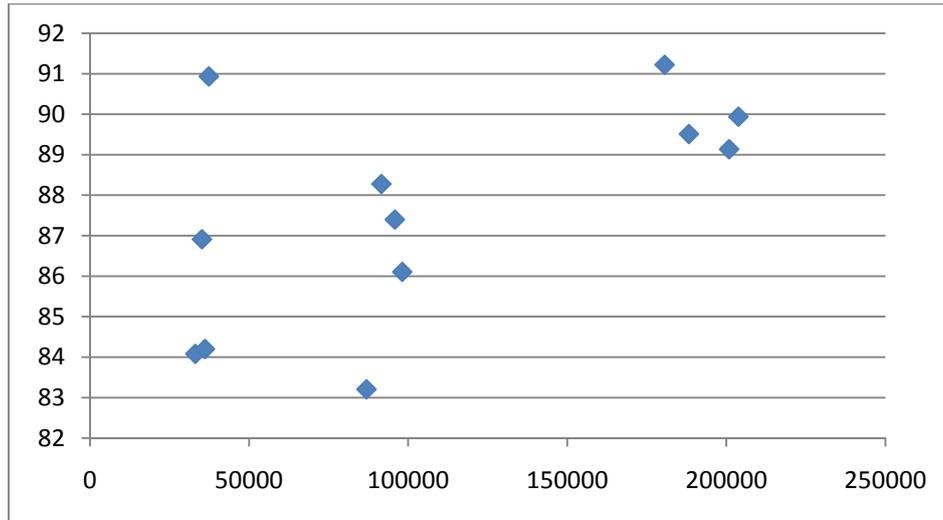


Figura 53. Intervalo de confianza (IC) según número de muestras.

Si comparamos el resultado obtenido en el apartado 4.3.1 referente a la imagen 2.2 se puede observar como el resultado obtenido por muestras obtiene un mejor porcentaje de acierto en la clasificación. Por lo que, la generación del *ground truth* total provoca una peor clasificación que el *ground truth* muestral. Esto unido al mayor tiempo de obtención del *ground truth* total provoca que sea mejor opción el *ground truth* muestral o por muestras.

#### 4.4. RESULTADOS OBTENIDOS DE IMPERMEABILIDAD PARA LA ZONA PILOTO.

Los resultados obtenidos de impermeabilidad podemos verlos en la Figura 54. Tal y como muestra la figura estos resultados son buenos ya que se asemejan a la realidad ya que se observa que las zonas más rojas y naranjas son las zonas de más de un 60% de impermeabilidad. Estas representan la pedanía de Villaricos y a Vera Playa. Las zonas amarillentas poseen un porcentaje medio de impermeabilidad mientras que las zonas verdes representan a las zonas rurales donde existen baja o muy baja impermeabilidad. Posteriormente tras la consecución de la Figura 54 y la obtención del área de cada cuadrado y el área de impermeabilidad de cada cuadrado, se pudo obtener la impermeabilidad total para la zona de estudio. El valor obtenido es de 48.92% lo que demuestra el elevado porcentaje de impermeabilidad de la zona y los posibles riesgos que esto conlleva.

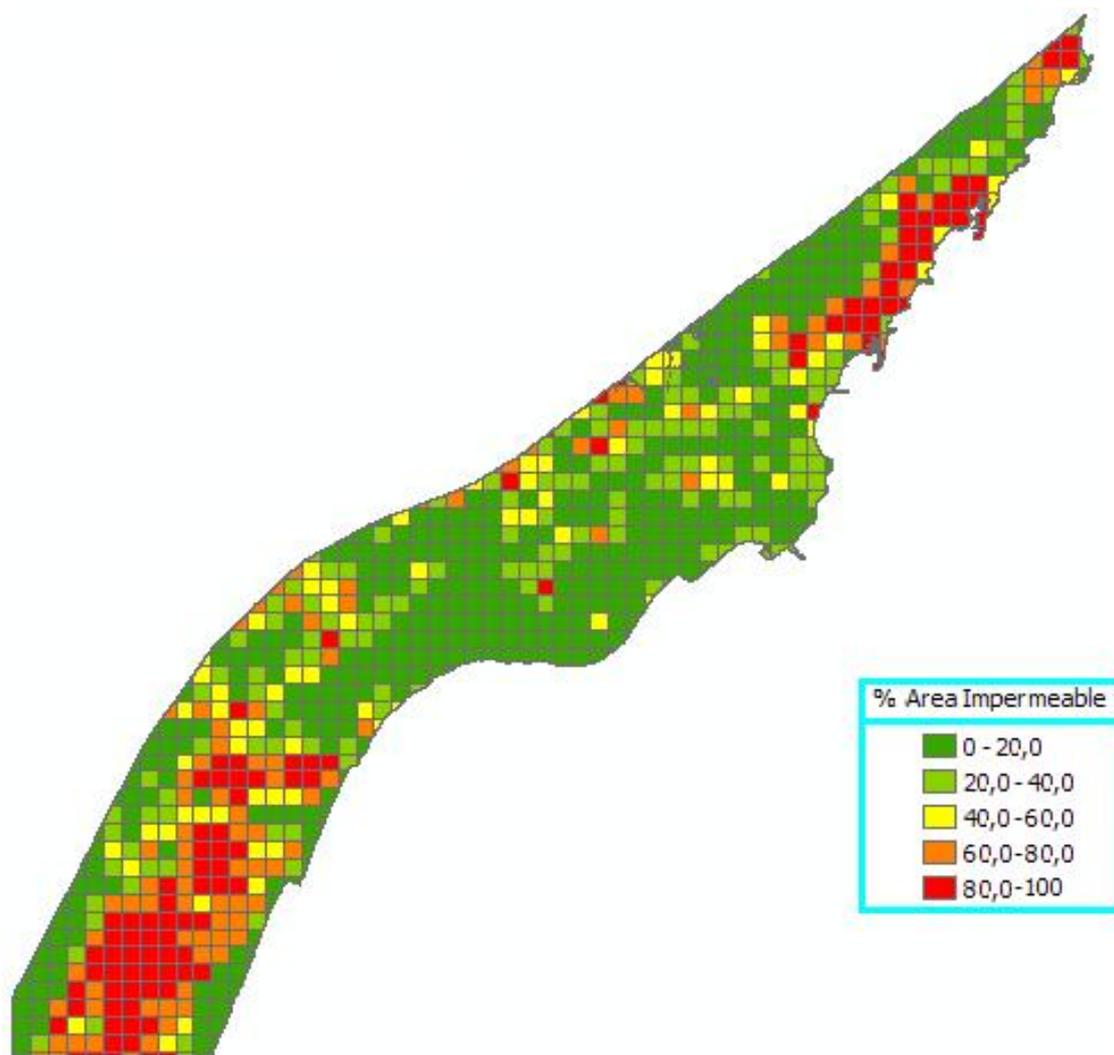


Figura 54. % área impermeable en la zona de estudio subdivida.

## CAPÍTULO 5

# CONCLUSIONES GENERALES

## 5. CONCLUSIONES GENERALES.

Las principales conclusiones a las que se ha llegado tras el desarrollo de este proyecto son:

- El tamaño del *ground truth* total, la abstracción al digitalizar, el coste de tiempo en obtenerlo y peor resultado de clasificación provoca que sea más ventajoso el uso del *ground truth* por muestras que es obtenido con menor coste de tiempo incluso tomando un tamaño de muestras del 1% del total y que se obtiene un mejor resultado de clasificación.
- El uso de la tecnología OBIA para el proceso de clasificación es muy ventajoso ya que permite relaciones entre objetos vecinos y relaciones entre superobjetos y subobjetos, mientras que en el caso de uso de píxeles a píxeles estas relaciones no pueden utilizarse.
- La precisión en la clasificación de una zona mediante ortoimágenes se ve afectada debido a la variación radiométrica de las ortoimágenes.
- El uso de ortoimágenes obtenidas por fotogrametría provoca la variación radiométrica mientras que las imágenes de satélite presenta una mayor uniformidad radiométrica.

## CAPÍTULO 6

### FUTUROS TRABAJOS

## 6. FUTUROS TRABAJOS.

- Comparación de ortoimágenes y satélites para determinar con cual se obtiene mejores resultados de clasificación en *eCognition®*.
- Estudio para determinar cuál es la escala que permite unos mejores resultados de clasificación en *eCognition®*.
- Clasificación no jerárquica que intente obtener directamente el área impermeable.
- Establecimiento de criterios homogéneos para la digitalización manual del GT total según la escala a utilizar.
- Estudio comparativo mediante la misma clasificación realizada en este proyecto con épocas posteriores o anteriores para observar la variación de superficies impermeables (*monitoring*). Para saber si se puede aplicar un estudio de repetitividad del método.
- Clasificación automática y detección del área impermeable mediante *nearest neighbor*.

## CAPÍTULO 7

# REFERENCIAS BIBLIOGRÁFICAS

## 7. REFERENCIAS BIBLIOGRÁFICAS.

- AGUILAR, F.J., AGÜERA, F., AGUILAR, M.A., 2007, A theoretical approach to modeling the accuracy assessment of digital elevation models. *Photogrammetric Engineering and Remote Sensing*, 73(12), 1367-1380.
- AGUILAR, F.J., AGUILAR, M.A., AGÜERA, F., 2007, Accuracy assessment of digital elevation models using a non-parametric approach. *International Journal of Geographical Information Science*, 21(6), 667-686.
- AGÜERA, F., AGUILAR, F. J., and AGUILAR, M. A., 2008, Using texture analysis to improve per-pixel classification of very high-resolution images for mapping plastic greenhouses, *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(6), 635-646.
- Aldrich, R. C. (1975) Detecting Disturbances in a Forest Environment. *Photogrammetric Engineering and Remote Sensing*, 41(1), 39-4
- ALONSO, I, CABRERA, L.L., JIMÉNEZ, J.A, VALDEMORO, H.I., SÁNCHEZ, I, 2007, Aplicación de la fotogrametría a estudios de erosión costera. In *Actas del XII Congreso de la Asociación Española de Teledetección, Mar del Plata, Argentina*, 2007.
- Ashley, M. D. and Rea, J. (1975) Seasonal Vegetation Differences from ERTS Imagery. *Photogrammetric Engineering and Remote Sensing*, 41(6), 713-721.
- CROUS, A., PINTÓ, J., 2006, Evolución de la playa de Sa Riera (Cap de Begur, Costa Brava) en los últimos 50 años. *Investigaciones geográficas*, 39, 119-130.
- DOMÍNGUEZ, L., GRACIA, F.J., ANFUSO, G., 2004, Tasas de avance/retroceso de la línea de costa mediante morfometría fotogramétrica en el sector Sanlúcar de Barrameda – Rota (provincia de Cádiz). *Rev. Soc. Geol. España*, 17 (1-2): 71-86.
- DUNN, C.P., SHARPE, D.M., GUNTENSPERGEN, G.R., STEARNS, F., YANG, Z., 1990, Methods for analyzing temporal changes in landscape pattern. In Turner, M.G. y Gardner, R.H. (Eds.) *Quantitative methods in Landscape Ecology. The analysis and interpretation of landscape heterogeneity*. Springer-Verlag. New York. 536 pp.

- GREEN, K., KEMPKA, D., LACKEY, L., 1994, Using remote sensing to detect and monitor land-cover and land-use change. *Photogrammetric Engineering and Remote Sensing*, **60**(3), 331-337.
- IVERSON, L.R., GRAHAM, R.L., COOK, E.A., 1989, Applications of satellite remote sensing to forested ecosystems. *Landscape Ecology*, **3**(2), 131-143.
- Jackson, T. J. and Ragan, R. M. (1977) Value of Landsat in Urban Water Resources Planning. *Journal of the Water Resources Planning and Management Division*, **103**(WR1), 33-46
- JENSEN, J. R. 1995. *Introductory Digital Image Processing: A Remote Sensing Perspective*, 2nd. New Jersey' Prentice-Hall
- KETTING, R. L., AND LANDGREBE, D. A., 1976, Classification of multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Geoscience and Remote Sensing*, **1**, 19-26.
- KIM, T., LEE, T. Y., AND KIM, K. O., 2006, Semiautomatic building line extraction from Ikonos images through monoscopic line analysis. *Photogrammetric Engineering and Remote Sensing*, **72**, 541-549.
- Klemas, V., Bartlett, D. and Rogers, R. (1975) Coastal Zone Classification From Satellite Imagery. *Photogrammetric Engineering and Remote Sensing*, **41**(4), 499-514
- LEE, J. Y., and WARNER, T. A., 2006, Segment based image classification. *International Journal of Remote Sensing*, **27**(16), 3403-3412.
- LEE, S. D., SHAN, J., AND BETHEL, J., 2003, Class-guided buildings extraction from Ikonos imagery. *Photogrammetric Engineering and Remote Sensing*, **69**(2), 143-150.
- LU, D., MAUSEL, P., BRONDIZIOS, E., and MORAN, E., 2004, Change detection techniques. *International Journal of Remote Sensing*, **25**: 2365-2407.
- MANZANO, G., MUÑOZ, A., MANZANO, F., 2004, Estudio de la evolución de la línea de costa entre Almería y Retamar mediante la integración de diferentes fuentes de información en un SIG. In XVI Congreso Internacional de Ingeniería Gráfica, Actas del Congreso, Zaragoza-Huesca España.

- MAYER, H., 1999, Automatic object extraction from aerial imagery –A survey focusing on buildings. *Computer Vision and Image Understanding*, 74(2), 138-149.
- MAYUNGA, S. D., COLEMAN, D. J., and 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.
- MILIAREISIS, G., and KOKKAS, N., 2007, Segmentation and object-based classification for extraction of the building class from LIDAR DEMs, *Computer and Geoscience*, 33: 1076-1087.
- Ogrosky, C. E. (1975) Population Estimates from Satellite Imagery. *Photogrammetric Engineering and Remote Sensing*, 41(6), 707-712.
- PAUL, M. J., MEYER, J. L., 2001, Streams in the urban landscape, *Annual Review Ecological Systems*, 32: 333-365.
- RUTHER, H., HAGAI, M. M., MTALO, E. G., 2002, Application of snakes and dynamic programming optimization in modelling of buildings in informal settlement areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 56, 269-282.
- SÁNCHEZ-ARCILLA, A., JIMÉNEZ, J.A., 1994, Breaching in Wave-Dominated Barrier Split: The Trabucador Bar (Northeastern Spain Coast). *Earth Surface Processes and Landforms*, 19, 483-498
- SENCIALES, J.M., MALVÁREZ, G., 2003, La desembocadura del río Vélez (Provincia de Málaga, España). Evolución reciente de un delta de comportamiento mediterráneo. *Rev. C. & G.*, 17(1-2), 47-61.
- SOHN, G., DOWMAN, I., 2007, Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62, 43-63.
- Stereocarto, 2009. Informe técnico del vuelo fotogramétrico combinado Digital y LiDAR en la costa de Almería.
- WANG, S., TSENG, Y. H., 2003. Semi-automated building extraction based on CSG model-image fitting. *Photogrammetric Engineering and Remote Sensing*, 69, 171-180.

- WANG, L., SOUSA, W., GONG, P., BIGING, G. S., 2004, Comparison of Ikonos and QuickBird images for mapping mangrove species on the caribbean coast of Panama. *Remote Sensing of Environment*, **91**, 432-440.
- WOODROFFE, C.D., 2002. *Coasts: form, process and evolution*. Cambridge University Press, Cambridge.
- ZHENG, D., WALLIN, D.O., HAO, Z., 1997, Rates and patterns of landscape change between 1972 and 1988. in the Changbai Mountain area of China and North Korea. *Landscape Ecology*, **12**, 241-254
- ZUG, M. L., PHAN, D. B., SCRIVENER, O., 1999, Pollution wash-off modelling on impervious surfaces: calibration, validation, transposition, *Water Science and Technology*, **39**(2): 17-24.