

Universitat Politècnica de València

Departamento de Ingeniería Cartográfica, Geodesia y Fotogrametría



**TESIS DOCTORAL**

**Detección automática de edificios y  
clasificación de usos del suelo en entornos  
urbanos con imágenes de alta resolución y  
datos LiDAR**

Valencia, junio 2011

Autor: **Txomin Hermosilla Gómez**  
Director: **Dr. Luis Ángel Ruiz Fernández**



*A mi madre*





# Agradecimientos

A Luis Ángel, por todo: por confiar en mí y darme la oportunidad de trabajar en lo que me gusta; por ser mi mentor; por enseñarme el arte y oficio de la investigación; por permitirme seguir aprendiendo; por guiarme y aconsejarme en el desarrollo de esta Tesis.

A mis compañeros y amigos del *Grupo de Investigación de Cartografía GeoAmbiental y Teledetección* por su inestimable apoyo y ayuda: Ángel, Josep, Jesús, Maru, Alfonso, Javier, y de manera especial a Jorge, mi apoyo incondicional.

A todos que me han acompañado y sufrido durante estos años, compartiendo espacio en el Seminario de Teledetección, en especial a José Luis, a Gerson y a Jaime, quien rara vez dejará de sorprenderme.

A Ana Ballester y José Balsa, por aportarme sus enfoques histórico y geográfico.

A Isusko Artabe, por diseñar de muy buen gusto y con muy buen gusto la portada de esta Tesis.

A las instituciones públicas: *Instituto Geográfico Nacional, Ministerio de Industria, Turismo y Comercio, Universidad Politécnica de Valencia, Instituto Cartográfico Valenciano, Instituto Murciano de Investigación y Desarrollo Agrario y Alimentario, Sociedade para o Desenvolvimento Comarcal de Galicia, Banco de Terras de Galicia*, y a la empresa *Agroseguro S.A.*, por su apoyo material y económico que, a través de contratos, convenios y proyectos, han hecho posible la investigación y el desarrollo de esta Tesis.

A toda mi familia, fuente de apoyo y alegrías, con especial cariño a mis hermanas, Goizalde y Zuriñe, y a mis primos y primas.

A Ece por su apoyo y su cariño.

Al resto de gente que me hace feliz y a la que aún no he tenido ocasión de citar: Jon, Kepa, Alberto, Xabi, Javi, Alain, Héctor, Lola, Salva, Carlos, María Cambra, Enrique, Diana, Andrés, Arantxa, Helena.

A todos los cartógrafos y geodestas vocacionales (a veces accidentales) con quienes he tenido el placer de compartir alegrías y experiencias en Vitoria-Gasteiz, Valencia, Silsoe, o a través de la *International Geodetic Student Organization*.

A todas las personas que durante este tiempo se han interesado por la marcha de esta Tesis: ¡Ya está aquí!



# Resumen

Las áreas urbanas son entornos importantes que agrupan a la mitad de la población mundial. Debido al poder de atracción de las ciudades, éstas constituyen zonas dinámicas y cambiantes en constante crecimiento. La urbanización descontrolada acarrea muchos problemas de índole medioambiental, poniendo en peligro, y en ocasiones invadiendo, los espacios naturales circundantes a la ciudad. Se trata, pues, de una de las causas principales en el cambio de los usos y coberturas en un territorio. Como solución a los problemas derivados de la urbanización, se hace cada vez más necesario implementar tecnologías que permitan visualizar los posibles efectos coaligados a las diferentes problemáticas para adoptar acciones en el menor tiempo posible. Esto implica un conocimiento preciso del escenario urbano actual que posibilite el desarrollo de un planeamiento urbano y territorial más eficiente. Debido a su gran dinamismo, la información relativa a las áreas urbanas queda desfasada rápidamente. Por ello, la disponibilidad de información cartográfica detallada y actualizada de estas zonas adquiere una gran relevancia. Tradicionalmente esta información se ha realizado mediante revisiones de campo y técnicas clásicas de fotointerpretación sobre imágenes aéreas, siendo estas metodologías lentas, caras y subjetivas. La utilización de técnicas de procesado digital de imágenes permite reducir el volumen de información a interpretar de forma manual y se adapta a los ritmos y necesidades de la sociedad actual, que requiere continuamente datos precisos que reflejen fielmente la realidad del territorio.

El objetivo de esta Tesis es establecer una metodología fiable de detección automática de edificaciones para la clasificación automática de los usos del suelo en entornos urbanos utilizando imágenes aéreas de alta resolución y datos LiDAR. Estos datos se corresponden con la información adquirida en el marco del Plan Nacional de Ortofotografía Aérea (PNOA), y se encuentran a disposición de las administraciones públicas españolas.

Para realizar la localización de edificaciones se adaptan y analizan dos técnicas empleando imágenes de alta resolución y datos LiDAR: la primera se basa en el establecimiento de valores umbral en altura y vegetación, y la segunda utiliza una aproximación mediante la clasificación orientada a objetos. Se analiza, además, el efecto de la inclusión de las sombras en el proceso de detección y localización de edificaciones. El rendimiento y la fiabilidad de estas metodologías se evalúa estadísticamente utilizando dos enfoques distintos: por un lado, se evalúa la calidad en la detección de las zonas que contienen edificaciones (evaluación por área o por píxel) y, por el otro, se comprueba la eficacia en la identificación de las edificaciones como unidades independientes (evaluación por objeto).

La clasificación de los entornos urbanos se ha realizado empleando un enfoque orientado a objetos, definidos a partir de los límites cartográficos de las parcelas catastrales. La descripción cualitativa de los objetos para su posterior clasificación se realiza mediante un conjunto de características descriptivas especialmente diseñadas para la

caracterización de entornos urbanos. Las características descriptivas propuestas tratan de emular la cognición humana y cuantificar numéricamente las propiedades particulares para la discriminación de los diferentes elementos de la imagen. La información que proporcionan estas características se refiere a la respuesta espectral de cada objeto o parcela, la textura, la altura y sus características geométricas y de forma. Además, se describe el contexto de cada objeto considerando dos niveles: interno y externo. En el nivel interno se extraen características referentes a las coberturas de edificaciones y vegetación contenidas en una parcela. En el nivel externo se calculan características globales de la manzana urbana en la que una parcela está enmarcada. Se analiza la contribución específica de las características descriptivas en la descripción, así como su aporte en la clasificación de los usos del suelo.

La detección automática de edificaciones empleando técnicas basadas en establecimiento de umbrales proporciona resultados más precisos tanto en la delineación como en la localización de los edificios. La precisión de los resultados es en gran medida dependiente de la tipología de edificación, de modo que las zonas urbanas e industriales muestran indicadores de calidad más favorables que las zonas periurbanas. La utilización de las sombras en el proceso de detección de las edificaciones tiene una elevada influencia en los valores de evaluación a nivel de objetos, permitiendo eliminar pequeños objetos detectados erróneamente y que actúan como ruido distorsionando los indicadores de calidad.

Las características descriptivas del contexto de un objeto presentan una alta complementariedad y producen un efecto sinérgico con las características calculadas a nivel del propio objeto en la descripción conjunta de los entornos urbanos, incrementando notablemente la fiabilidad de la clasificación y permitiendo alcanzar valores de fiabilidad global elevados. Es especialmente relevante el aporte que realizan las características referentes a las edificaciones, tanto a nivel del contexto interno como del externo. Las características del contexto permiten una mejor discriminación de las distintas tipologías de construcciones periurbanas, y de las áreas urbanas históricas frente a las de ensanche, así como de las zonas de ensanche frente a las construcciones más recientes de tipo aislado.

Las metodologías automáticas presentadas están especialmente indicadas para el cálculo de parámetros útiles para la construcción/actualización de bases de datos de ocupación del territorio, puesto que ofrecen resultados muy superiores a los obtenidos empleando metodologías basadas en métodos de percepción visual. Así, empleando técnicas de detección automática de edificaciones, se obtienen unos resultados de gran calidad en la estimación del porcentaje de superficie edificada de forma objetiva e independiente de operadores humanos. La combinación de la detección de edificaciones y clasificación automática de los usos del suelo permite distinguir y describir de manera más exhaustiva las diferentes tipologías urbanas del territorio, aportando mayor exactitud e información que las técnicas clásicas basadas en la estimación e interpretación visual.

# Abstract

Urban areas are important environments where approximately half of the world's population lives. These centres attract population because they offer greater opportunities for development. Urban sprawl phenomenon is produced due to the fast growing of cities and it entails diverse environmental consequences. Therefore, it is necessary to develop technologies and methodologies that permit monitoring the effects of the various problems that are partially caused by urban sprawl. These technologies would help enable the rapid adoption of policies that minimise the negative effects of urban sprawl. Solutions require a precise knowledge of the current urban environment to enable the development of more efficient urban and territorial plans. The high dynamism of urban areas produces a continuous alteration of land cover and use, and consequently, cartographic information is quickly outdated. Therefore, the availability of detailed and up-to-date cartographic and geographic information is imperative for an adequate management and planning of urban areas. Usually the process of creating land-use/land-cover maps of urban areas involves field visits and classical photo-interpretation techniques using aerial imagery. These methodologies are expensive, time consuming, and also subjective. Digital image processing techniques help reduce the volume of information that needs to be manually interpreted. These techniques satisfy current demands for continuously precise data that accurately describes a territory.

The aim of this Thesis is to establish a precise methodology to automatically detect buildings and to automatically classify land uses in urban environments using high spatial resolution imagery and LiDAR data. These data are acquired in the framework of the Spanish National Plan for Airborne Orthophotographs, being these data available for public Spanish administrations.

Two main approaches for automatic building detection and localization using high spatial resolution imagery and LiDAR data are adapted. The thresholding-based approach is founded on the establishment of two threshold values: one referred to the minimum height to be considered as building, defined using the LiDAR data, and the other referred to the presence of vegetation, which is defined according to the spectral response. The other approach follows the standard scheme of object-based image classification: segmentation, feature extraction and selection, and classification, here performed using decision trees. In addition, the effect of the inclusion in the building detection process of contextual relations with the shadows is evaluated. Quality assessment is performed at two different levels: area and object. Area-level evaluates the building delineation performance, whereas object-level assesses the accuracy in the spatial location of individual buildings.

Urban land-use classification is achieved by applying object-based classification techniques. Objects are defined using the cartographical limits of cadastral plots. The characterization of the plots to achieve the classification is performed by considering a descriptive feature set, specifically designed to describe urban environments. The

proposed descriptive features aim to emulate human cognition by numerically quantifying the properties of the image elements and so enable each to be distinguishable. These features describe each plot as a single entity based on several aspects that reflect the information typology used: spectral, three-dimensional, geometry. In addition, a set of contextual features were defined at two levels: internal and external. Internal context features describe an object with respect to the land cover types contained within the plots, in this case were buildings and vegetation. External context features characterise each object by considering the common properties of adjacent objects that when combined create an aggregation that is higher than plot level: urban blocks.

Results show that thresholding-based building detection approach performs better in the different scenarios analyzed. This method produces a more accurate building delineation and object detection than the object-based classification method. The building type appears as a key factor in the building detection performance. Thus, urban and industrial areas show better accuracies in detection metrics than suburban areas, due to the small size of suburban constructions, combined with the prominent presence of trees in suburban classes, that makes the building detection more difficult. The consideration relations between buildings and shadows improve the object-level detection, removing small objects erroneously detected as buildings that negatively affect to the quality indices.

Classification tests results show that internal and external context features suitably complement the image-derived features, improving the classification accuracy values of urban classes – especially between classes that show similarities in their image-based and three-dimensional features. Context features enable a superior discrimination of suburban building typologies, of planned urban areas and historical areas, and also of planned urban areas and isolated buildings.

These automatic methodologies are especially suitable to compute useful information for constructing and updating land-use/land-cover geo-spatial databases. Digital image processing based methodologies provides better results than visual interpretation based methods. Thus, automatic building detection techniques produce a superior estimation of built-up surface in a objective manner, independently of human operators. The combination of building detection and automatic classification of land uses in urban areas enable to exhaustively distinguish and describe different urban typologies, contributing with more accuracy and information than standard techniques based on visual interpretation. The proposed methodology, based on automated descriptive feature extraction from LiDAR data and images, is applicable for mapping cities, urban landscape characterisation and management, and updating geospatial databases, providing new tools to increase the frequency and efficiency of urban studies.

# Resum

Les àrees urbanes són entorns importants en els quals s'agrupa la meitat de la població mundial. A causa del poder d'atracció de les ciutats, aquestes constitueixen zones dinàmiques i canviants, en constant creixement. La urbanització descontrolada implica molts problemes d'índole mediambiental, posant en perill, i en ocasions envaint, els espais naturals circumdants a la ciutat. Es tracta, doncs, d'una de les causes principals en el canvi dels usos i cobertures en un territori. Com a solució als problemes derivats de la urbanització, es fa cada vegada més necessari implementar tecnologies que permeten visualitzar els possibles efectes associats a les diferents problemàtiques per a adoptar accions en el menor temps possible. Açò implica un coneixement precís de l'escenari urbà actual que possibilita el desenvolupament d'un planejament urbà i territorial més eficient. A causa de el seu gran dinamisme, la informació relativa a les àrees urbanes queda desfasada ràpidament. Per això, la disponibilitat d'informació cartogràfica detallada i actualitzada d'aquestes zones adquireix una gran rellevància. Tradicionalment aquesta informació s'ha realitzat mitjançant revisions de camp i tècniques clàssiques de fotointerpretació sobre imatges aèries, sent aquestes metodologies lentes, cares i subjectives. La utilització de tècniques de processat digital d'imatges permet a reduir el volum d'informació a interpretar de forma manual i s'adapta als ritmes i necessitats de la societat actual, que requereix contínuament de dades precises que reflectisquen fidelment la realitat del territori.

L'objectiu d'aquesta Tesi és establir una metodologia fiable de detecció automàtica d'edificacions per a la classificació automàtica dels usos del sòl en entorns urbans utilitzant imatges aèries d'alta resolució i dades LiDAR. Aquestes dades corresponen amb la informació adquirida en el marc del Pla Nacional d'Ortofotografia Aèria (PNOA), i es troben a la disposició de les administracions públiques espanyoles.

Per a realitzar la localització d'edificacions s'adapten i analitzen dues tècniques emprant imatges d'alta resolució i dades LiDAR: la primera es basa en l'establiment de valors llindar en l'altura i la vegetació, i la segona utilitza una aproximació mitjançant la classificació orientada a objectes. S'analitza, a més, l'efecte de la inclusió de les ombres en el procés de detecció i localització d'edificacions. El rendiment i la fiabilitat d'aquestes metodologies s'avalua estadísticament utilitzant dos enfocaments distints: d'una banda, s'avalua la qualitat en la detecció de les zones que contenen edificacions (avaluació per àrea o per píxel) i, per l'altre, es comprova l'eficàcia en la identificació de les edificacions com unitats independents (avaluació per objecte).

La classificació dels entorns urbans s'ha realitzat emprant un enfocament orientat a objectes, definits aquests a partir dels límits cartogràfics de les parcel·les cadastrals. La descripció qualitativa dels objectes per a la seua posterior classificació es realitza mitjançant un conjunt de característiques descriptives especialment dissenyades per a la caracterització d'entorns urbans. Les característiques descriptives proposades tracten d'emular la cognició humana i quantificar numèricament les propietats particulars per a la

discriminació dels diferents elements de la imatge. La informació que proporcionen aquestes característiques es refereix a la resposta espectral de cada objecte o parcel·la, la textura, l'altura i les seues característiques geomètriques i de forma. A més, es descriu el context de cada objecte considerant dos nivells: intern i extern. En el nivell intern s'extrauen característiques de les cobertures de les edificacions i de la vegetació continguda dins d'una parcel·la. En el nivell extern, per la seua banda, es calculen característiques globals de la illa urbana en la qual una parcel·la és emmarcada. S'analitza la contribució específica de les característiques descriptives en la descripció, així com la seua aportació a la classificació dels usos del sòl.

La detecció automàtica d'edificacions emprant tècniques basades en establiment de l·lindars proporciona resultats més precisos tant en la delineació com en la localització dels edificis. La precisió dels resultats és en gran mesura depenent de la tipologia d'edificació, de manera que les zones urbanes i industrials mostren indicadors de qualitat més favorables que les zones periurbanes. La utilització de les ombres en el procés de detecció de les edificacions té una major influència en els valors d'avaluació a nivell d'objectes, permetent eliminar objectes menuts detectats erròniament i que actuen com soroll, distorsionant els indicadors de qualitat.

Les característiques descriptives del context d'un objecte presenten una alta complementaritat i produeixen un efecte sinèrgic amb les característiques calculades a nivell del propi objecte en la descripció conjunta dels entorns urbans, incrementant notablement la fiabilitat de la classificació, arribant-se a valors de fiabilitat global elevats. És especialment rellevant l'aportació que fan les característiques referents a les edificacions, tant a nivell del context intern, com de l'extern. Les característiques del context permeten una millor discriminació de les diferents tipologies de construccions periurbanes, i de les àrees urbanes històriques enfront de les d'eixample, així com de les zones d'eixample davant de les construccions més recents de tipus aïllat.

Les metodologies automàtiques presentades estan especialment indicades per al càlcul de paràmetres útils per a la construcció/actualització de bases de dades d'ocupació del territori, ja que ofereixen resultats molt superiors als obtinguts emprant metodologies basades en mètodes de percepció visual. Així, emprant tècniques de detecció automàtiques d'edificacions s'obtenen uns resultats de gran qualitat en l'estimació del percentatge de superfície edificada, de forma objectiva i independent d'operadors humans. La combinació de la detecció d'edificacions i classificació automàtica dels usos del sòl permet distingir i descriure de manera més exhaustiva les diferents tipologies urbanes del territori, aportant major exactitud i informació que les tècniques clàssiques basades en l'estimació i interpretació visual.



# Índice

---

<b>1. INTRODUCCIÓN Y ANTECEDENTES .....</b>	<b>1</b>
1.1. Introducción .....	1
1.2. Antecedentes .....	7
1.2.1. Detección y localización de edificaciones .....	7
1.2.1.1. Localización de edificaciones empleando imágenes de alta resolución ..	8
1.2.1.2. Localización de edificaciones utilizando información tridimensional .....	11
1.2.1.3. Localización de edificaciones combinando imágenes de alta resolución e información tridimensional .....	13
1.2.1.4. Discusión de los antecedentes de detección de edificaciones.....	14
1.2.2. Clasificación contextual en entornos urbanos.....	15
1.2.2.1. Discusión de los antecedentes de clasificación contextual de entornos urbanos .....	17
<b>2. OBJETIVOS Y ESTRUCTURA DE LA TESIS .....</b>	<b>19</b>
2.1. Objetivos .....	19
2.2. Estructura de la Tesis .....	20
<b>3. MATERIAL Y DATOS .....</b>	<b>23</b>
3.1. Zonas de estudio .....	23
3.2. Datos .....	24
3.3. Preprocesado de los datos LiDAR: cálculo de los DTM .....	28
3.4. Programas informáticos empleados .....	30
<b>4. METODOLOGÍA .....</b>	<b>31</b>
4.1. Introducción .....	31
4.2. Métodos de detección de edificaciones .....	32

4.2.1. Detección de edificaciones basada en el establecimiento de umbrales.....	32
4.2.2. Detección de edificaciones basada en clasificación orientada a objetos.....	34
4.2.2.1. Segmentación de la imagen.....	36
4.2.2.1.1. Segmentación basada en la detección de bordes.....	36
4.2.2.1.2. Segmentación basada en el crecimiento de regiones.....	37
4.2.2.2. Extracción de características descriptivas .....	38
4.2.2.2.1. Características espectrales .....	38
4.2.2.2.2. Características de textura .....	39
4.2.2.2.3. Características de forma .....	42
4.2.2.2.4. Características de altura .....	43
4.2.2.3. Selección y análisis de las características descriptivas.....	44
4.2.2.4. Clasificación mediante árboles de decisión.....	46
4.2.2.5. Evaluación de la clasificación .....	47
4.2.2.6. Definición de edificaciones.....	47
4.2.3. Detección de las sombras y su inclusión en el proceso de detección de edificaciones.....	48
4.2.4. Evaluación de la detección de edificaciones .....	50
4.2.4.1. Evaluación a nivel de área.....	51
4.2.4.2. Evaluación a nivel de objeto .....	53
4.2.4.3. Comparación de metodologías automáticas y basadas en interpretación visual para la estimación de la superficie edificada. ....	53
4.3. Clasificación de usos del suelo en entornos urbanos .....	55
4.3.1. Introducción.....	55
4.3.2. Definición de objetos y clases .....	56
4.3.3. Extracción de características descriptivas .....	58
4.3.3.1. Características relativas al objeto .....	58
4.3.3.2. Características de contexto interno del objeto.....	59
4.3.3.2.1. Características relativas a las edificaciones.....	59
4.3.3.2.2. Características relativas a la vegetación .....	60
4.3.3.3. Características de contexto externo del objeto .....	61
4.3.3.3.1. Relaciones espaciales (Teoría de grafos) .....	61
4.3.3.3.2. Características relativas a las edificaciones.....	62
4.3.3.3.3. Características relativas a la vegetación .....	64
4.3.3.3.4. Características de forma .....	65
4.3.4. Selección de características y clasificación.....	66
4.3.5. Evaluación de la clasificación .....	68
<b>5. RESULTADOS .....</b>	<b>71</b>
5.1. Introducción.....	71
5.2. Análisis comparativo de los métodos de detección de edificaciones.....	72
5.2.1. Evaluación del procedimiento para la detección de edificaciones basado en el establecimiento de umbrales .....	72

5.2.2. Evaluación del procedimiento para la detección basado en clasificación orientada a objetos .....	75
5.2.3. Comparación de los métodos de detección de edificaciones .....	82
5.2.4. Análisis de la inclusión de las sombras en la detección de edificaciones.....	83
5.2.5. Análisis de la influencia de la densidad de los datos LiDAR en la detección de edificaciones .....	86
5.3. Clasificación contextual en entornos urbanos.....	88
5.3.1. Definición de clases.....	88
5.3.2. Análisis de las características descriptivas .....	88
5.3.3. Análisis de la clasificación .....	93
5.4. Aplicabilidad del cálculo de parámetros para su inclusión en bases de datos de ocupación del territorio .....	102
5.4.1. Aplicabilidad para la determinación de la superficie edificada .....	102
5.4.2. Aplicabilidad para la determinación de las tipologías de edificación.....	106
<b>6. CONCLUSIONES Y LÍNEAS FUTURAS DE INVESTIGACIÓN .....</b>	<b>115</b>
6.1. Conclusiones .....	115
6.2. Líneas futuras de investigación .....	118
<b>7. REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>121</b>
<b>Anejo I. PNOT Y SIOSE .....</b>	<b>139</b>
AI.1. Introducción .....	139
AI.2. Plan Nacional de Observación de la Tierra (PNOT).....	139
AI.2.1. Primera fase: obtención y tratamiento de las coberturas de imágenes.....	140
AI.2.1.1. Plan Nacional de Ortofotografía Aérea (PNOA) .....	141
AI.2.1.2. Plan Nacional de Teledetección (PNT) .....	141
AI.2.2. Segunda fase: extracción de la información .....	142
AI.2.3. Tercera fase: diseminación de la información .....	142
AI.3. Sistema de Información sobre Ocupación del Suelo en España (SIOSE).....	142
AI.3.1. Introducción .....	142
AI.3.2. Las zonas urbanas en el SIOSE .....	144
AI.4.Referencias.....	147
<b>Anejo II. RESULTADO DE LA CLASIFICACIÓN CONTEXTUAL DE ENTORNOS URBANOS .....</b>	<b>149</b>
<b>Anejo III. LISTADO DE PUBLICACIONES RELACIONADAS CON ESTA TESIS ....</b>	<b>157</b>
AIII.1. Artículos en revistas indexadas .....	157
AIII.2. Comunicaciones en congresos científico-técnicos.....	158
AIII.3. Otras publicaciones .....	159



# Índice de figuras

---

Figura 1. Crecimiento de la población urbana y rural en el mundo, 1950-2030 (Fuente: Organización de las Naciones Unidas, 2003). .....	2
Figura 2. Porcentaje de habitantes por tamaño municipal en España en los años 1900, 2001 y 2009 (Fuente: Fundación BBVA, 2010). .....	3
Figura 3. Localización de las zonas de estudio. ....	24
Figura 4. Mapas de densidades de los datos LiDAR.....	25
Figura 5. Detalles de los datos empleados en cada una de las zonas de estudio.....	27
Figura 6. Modelo digital de superficies, DSM (izquierda), modelo digital del terreno, DTM (centro) y modelo digital de superficies normalizado, nDSM (derecha) calculados a partir de los datos LiDAR. ....	28
Figura 7. Esquema del proceso cálculo del DTM (Fuente: Estornell et al., 2010). ....	29
Figura 8. Esquema del algoritmo de detección de edificaciones propuesto basado en la aproximación metodológica de establecimiento de umbrales. ....	33
Figura 9. Esquema gráfico del proceso de detección de edificaciones empleando el algoritmo basado en establecimiento de umbrales. ....	33
Figura 10. Esquema del algoritmo propuesto de detección de edificaciones basado en la aproximación metodológica de clasificación orientada a objetos.....	34
Figura 11. Esquema gráfico del proceso de detección de edificaciones empleando el algoritmo basado en clasificación orientada a objetos.....	35
Figura 12. Esquema gráfico del proceso de detección de sombras.....	48

Figura 13. Esquema del algoritmo de detección de edificaciones basado en establecimiento de umbrales y en la relación de adyacencia con las sombras. ....	49
Figura 14. Esquema del algoritmo de detección de edificaciones basado en clasificación orientada a objetos y en la relación de adyacencia con las sombras. ....	49
Figura 15. Ejemplos de las tipologías de edificación diferenciadas en las tres zonas de estudio. Nótese que Oliva no cuenta con áreas de tipo industrial. ....	50
Figura 16. Ejemplos de zonas excluidas de la evaluación debido a errores en el cálculo del DTM (izquierda) o por diferencias temporales entre los datos LiDAR y las imágenes (derecha). ....	51
Figura 17. Ejemplo de las categorías definidas para la comparación a nivel de área. ....	52
Figura 18. Ejemplos de las clases urbanas definidas. ....	57
Figura 19. Ejemplos de la distribución de los grafos para las clases definidas. ....	62
Figura 20. Ejemplos de las coberturas edificadas y de vegetación para las clases definidas. ....	63
Figura 21. Ejemplos de la distribución de las alturas en las edificaciones para las clases definidas. ....	63
Figura 22. Ejemplos de la forma y geometría de las manzanas de las clases urbanas definidas. ....	65
Figura 23. Ejemplos de la detección de edificaciones de tipología industrial en Moncada (izquierda) y Sagunto (centro y derecha). ....	74
Figura 24. Ejemplos de la detección de edificaciones de tipología urbana en Moncada (izquierda), Oliva (centro) y Sagunto (derecha). ....	74
Figura 25. Ejemplos de la detección de edificaciones de tipología periurbana en Moncada (izquierda), Oliva (centro) y Sagunto (derecha). Puede observarse las oclusiones debidas a la vegetación. ....	75
Figura 26. Detalles de la segmentación empleando ambos métodos sobre una zona industrial en Moncada (izquierda), una zona urbana en Oliva (centro) y una zona periurbana en Sagunto (derecha). ....	76
Figura 27. Gráficas de fiabilidad predicha mediante análisis discriminante lineal para las clasificaciones de las segmentaciones generadas con los métodos analizados. ....	78
Figura 28. Detalles de la segmentación empleando ambos métodos sobre una zona periurbana en Moncada (izquierda), una zona urbana en Oliva (centro) y una zona periurbana en Sagunto (derecha). ....	80
Figura 29. Detalles de la detección de edificaciones con y sin la información de las sombras en zonas periurbanas en Oliva (izquierda) y Moncada (derecha). ....	85

Figura 30. Detalles de la detección de edificaciones sin (izquierda) y con (derecha) la información de la sombras en una zona urbana en Sagunto. ....	85
Figura 31. Detalle de la detección de edificaciones empleando diferentes densidades en los datos LiDAR en un área de tipología periurbana en la zona de estudio de Oliva.....	87
Figura 32. Fiabilidades globales predichas mediante análisis discriminante lineal al incluir sucesivamente variables al modelo de clasificación para los diferentes grupos de características descriptivas. ....	90
Figura 33. Fiabilidad predicha mediante análisis discriminante lineal para las primeras 25 variables al combinar todos los grupos, frente a las obtenidas empleando grupos de variables independientes. Los nombres de las variables corresponden a las características incluidas al combinar todos los grupos. ....	91
Figura 34. Distribución de las clases urbanas con respecto a los intervalos de valores para dos características descriptivas del contexto interno. ....	92
Figura 35. Distribución de las clases urbanas con respecto a los intervalos de valores para dos características descriptivas del contexto externo. ....	93
Figura 36. Vistas generales de la clasificación empleando todos los grupos de características descriptivas para las zonas de estudio. ....	94
Figura 37. Fiabilidades del productor y del usuario de las clases definidas para los sucesivos conjuntos de características descriptivas incluidas en la clasificación. GI: características a nivel de objeto espectrales y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo. ....	96
Figura 38. Ejemplos de la clasificación empleando todos los grupos de características descriptivas en zonas con presencia de industria (a. Moncada, b. Sagunto). ....	97
Figura 39. Evolución del valor del índice de error mutuo para las clases <i>vivienda unifamiliar adosada</i> y <i>vivienda unifamiliar aislada</i> al emplear progresivamente los diferentes grupos de características descriptivas. GI: características a nivel de objeto espectrales y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo. ....	98
Figura 40. Ejemplos de la clasificación empleando todos los grupos de características descriptivas en zonas con predominio de viviendas unifamiliares (a. Moncada, b. Oliva). ....	99
Figura 41. Evolución del valor del índice de error mutuo para las clases <i>edificio aislado</i> y <i>ensanche</i> , al emplear progresivamente los diferentes grupos de características descriptivas. GI: características a nivel de objeto espectrales y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo. ....	99

Figura 42. Evolución del valor del índice de error mutuo para las clases <i>Casco histórico</i> y <i>Ensanche</i> al emplear progresivamente los diferentes grupos de características descriptivas. GI: características a nivel de objeto espectrales y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo. ....	100
Figura 43. Ejemplos de la clasificación empleando todos los grupos de características descriptivas en áreas de transición entre el casco histórico y el ensanche (a. Sagunto, b. Oliva), y en una zona de ensanche (c. Sagunto). ....	101
Figura 44. Relación entre el porcentaje de superficie edificada de referencia en cada polígono frente a la contenida en la base de datos del SIOSE y la detectada automáticamente en las tres áreas de estudio. ....	103
Figura 45. Relación entre el porcentaje de superficie edificada de referencia en cada polígono frente a la contenida en la base de datos del SIOSE y la detectada automáticamente para las tres tipologías de edificaciones consideradas. ....	104
Figura 46. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono de tipo <i>mosaico</i> , en el que se distinguen los usos urbano e industrial. ....	107
Figura 47. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono urbano de ensanche. ....	108
Figura 48. Ejemplo de zonas donde la clasificación automática puede ayudar en la definición de los polígonos SIOSE (cuyos límites están representados por líneas de color negro). ....	108
Figura 49. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono urbano de ensanche. ....	109
Figura 50. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono residencial periurbano con edificaciones de tipología unifamiliar. ....	110
Figura 51. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono industrial en el que aparecen edificaciones residenciales. ....	111
Figura 52. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono industrial con presencia de edificaciones comerciales de tipo <i>edificio aislado</i> . ....	112
Figura 53. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono residencial costero. ....	113



Figura 54. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono residencial costero. .... 113

Figura 55. Ejemplo de las clases de la cobertura *Urbano Mixto*. Ortofotografías en color natural. (Fuente: Instituto Geográfico Nacional, 2007). .... 147



## Índice de tablas

---

Tabla 1. Tabla resumen de los datos empleados para cada zona de estudio. ....	26
Tabla 2. Listado de las características descriptivas relativas al objeto. ....	67
Tabla 3. Listado de las características descriptivas del contexto interno y externo.....	68
Tabla 4. Resultados estadísticos de la evaluación de las zonas de estudio empleando el método de umbralización.....	73
Tabla 5. Resultados de la fiabilidad global de la clasificación para los objetos resultantes de cada método de segmentación.....	77
Tabla 6. Resultados estadísticos de la evaluación de las zonas de estudio empleando el método de clasificación orientada a objetos con la segmentación por detección de bordes. ....	79
Tabla 7. Resultados estadísticos de la evaluación de las zonas de estudio empleando el método de clasificación orientada a objetos con la segmentación por crecimiento de regiones. ....	80
Tabla 8. Comparación de los índices estadísticos de evaluación divididos por tipología de edificación para los métodos de clasificación orientada a objetos utilizando la segmentación por detección de bordes o por crecimiento de regiones. ....	82
Tabla 9. Comparación conjunta de los índices estadísticos de evaluación divididos por tipología de edificación para los métodos de detección de edificaciones de umbralización y de clasificación orientada a objetos. ....	83

Tabla 10. Comparación de los índices estadísticos de evaluación divididos por tipología de edificación para los el método de umbralización con y sin la información de las sombras. ....	84
Tabla 11. Comparación de los índices de evaluación divididos por tipología de edificación para los el método de clasificación orientada a objetos con y sin las información de las sombras. ....	84
Tabla 12. Resultados estadísticos de la evaluación de la zona de Oliva variando la densidad (ptos/m <sup>2</sup> ) de los datos LiDAR y empleando el método de umbralización. ....	86
Tabla 13. Número de muestras (objetos) seleccionadas por cada clase y zona de estudio. ....	88
Tabla 14. Valores de fiabilidad global al combinar progresivamente los diferentes grupos de características.....	95
Tabla 15. Valores del índice kappa al combinar progresivamente los diferentes grupos de características. ....	95
Tabla 16. Valores de error medio cuadrático (EMC) y sesgo, agrupados por zonas de estudio, en la estimación de la superficie edificada mediante técnicas de detección automáticas y mediante técnicas de estimación visual empleadas en el SIOSE. ....	104
Tabla 17. Valores de error medio cuadrático (EMC) y sesgo, agrupados por tipología de edificación, en la estimación de la superficie edificada mediante técnicas de detección automáticas y mediante técnicas de estimación visual empleadas en el SIOSE. ....	105
Tabla 18. Ejemplos de determinación del porcentaje de superficie edificada en la zona de Sagunto, en los que se presentan polígonos con importantes errores recogidos en la base de datos del SIOSE. ....	105
Tabla 19. Clasificación de las coberturas en el SIOSE. ....	144
Tabla 20. Clasificación de las coberturas Artificiales Compuestas en el SIOSE.....	146
Tabla 21. Matriz de confusión de la clasificación empleando las características a nivel de objeto de la imagen en Moncada. ....	150
Tabla 22. Matriz de confusión de la clasificación combinando las características a nivel de objeto de la imagen, altura y forma en Moncada. ....	150
Tabla 23. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, y del contexto interno en Moncada. ....	151
Tabla 24. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, del contexto interno y externo en Moncada....	151
Tabla 25. Matriz de confusión de la clasificación empleando las características a nivel de objeto de la imagen en Oliva.....	152
Tabla 26. Matriz de confusión de la clasificación combinando las características a nivel de objeto de la imagen, altura y forma en Oliva.....	152

Tabla 27. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, y del contexto interno en Oliva.....	153
Tabla 28. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, del contexto interno y externo en Oliva. ....	153
Tabla 29. Matriz de confusión de la clasificación empleando las características a nivel de objeto de la imagen en Sagunto. ....	154
Tabla 30. Matriz de confusión de la clasificación combinando las características a nivel de objeto de la imagen, altura y forma en Sagunto. ....	154
Tabla 31. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, y del contexto interno en Sagunto. ....	155
Tabla 32. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, del contexto interno y externo en Sagunto. ...	155



**Detección automática de edificios y  
clasificación de usos del suelo en entornos  
urbanos con imágenes de alta resolución y  
datos LiDAR**





# Capítulo I

---

## INTRODUCCIÓN Y ANTECEDENTES

---

### 1.1. Introducción

En torno a la mitad de la población mundial vive en áreas urbanas (Organización de las Naciones Unidas, 2007) y se espera que este porcentaje se siga incrementando fuertemente en los próximos años. El incremento de significación de la población urbana a nivel mundial es muy claro si atendemos a los datos publicados (28,8% en 1950) y a las estimaciones a medio-largo plazo (aproximadamente el 70% en 2050 conforme a las predicciones de la Organización de las Naciones Unidas, 2003) (ver Figura 1). Hoy en día las ciudades articulan el territorio y concentran la mayor parte de la vida socioeconómica, en detrimento de los espacios rurales, que constituyen cada día de forma más palpable en un mundo en crisis.

Las áreas urbanas ofrecen la mayor parte de los puestos de trabajo, básicamente dentro del sector servicios, y ofertan la mayoría de las actividades de ocio. En estas zonas urbanas es donde se produce un gran número de actividades económicas que favorecen el desarrollo de negocios y, por consiguiente, para el crecimiento económico. Estas mayores perspectivas de desarrollo actúan como foco de atracción sobre la población, y producen que las personas tiendan a preferir vivir en ciudades en pos de la búsqueda de un mayor bienestar. Esto supone un incremento demográfico causado principalmente por los movimientos migratorios. La emigración de la población a las ciudades afecta especialmente a la población más dinámica (gente joven en edad activa), lo que a su vez induce a unos mayores índices de crecimiento demográfico.




Figura 1. Crecimiento de la población urbana y rural en el mundo, 1950-2030 (Fuente: Organización de las Naciones Unidas, 2003).

El incremento de la población urbana a nivel mundial se ha debido básicamente al fenómeno de urbanización acelerado que han vivido los países desarrollados durante la segunda mitad del siglo XX. En los años venideros el crecimiento se producirá principalmente por los llamados países en vías de desarrollo, fundamentalmente asiáticos, africanos y latinoamericanos. En Europa, las áreas urbanas han experimentado un considerable y constante desarrollo de las zonas industriales, residenciales y comerciales, debido a los incrementos de población y a mayores demandas en la calidad de sus habitantes.

En España, el fenómeno de urbanización ha sido manifiesto desde la segunda mitad del siglo pasado (Figura 2). El éxodo rural propio de un país occidental, junto a la conformación de España como un importante destino turístico desde la década de 1960 ha supuesto un *boom* inmobiliario, que ha adquirido sus mayores dimensiones durante la primera década del siglo XXI (Fundación BBVA, 2010).

La urbanización descontrolada supone en la realidad un crecimiento acelerado de las ciudades en forma de mancha de aceite, lo que incide en una problemática asociada: problemas de movilidad, contaminación atmosférica, crecimiento urbanístico desordenado, aparición de bolsas de pobreza y de exclusión social, etc. A nivel medio ambiental el crecimiento incontrolado de las ciudades supone el aumento de la dependencia del automóvil, lo que implica un mayor consumo energético, la polución y los gases que provocan el efecto invernadero, por no mencionar las mayores infraestructuras viarias que requiere el transporte. La construcción y el sellado incontrolado del terreno provocan un aumento del riesgo de inundaciones y un descenso en la efectividad de absorción de las aguas por parte del terreno y de los acuíferos. Esto afecta tanto a la cantidad como a la calidad del agua y de las tierras.

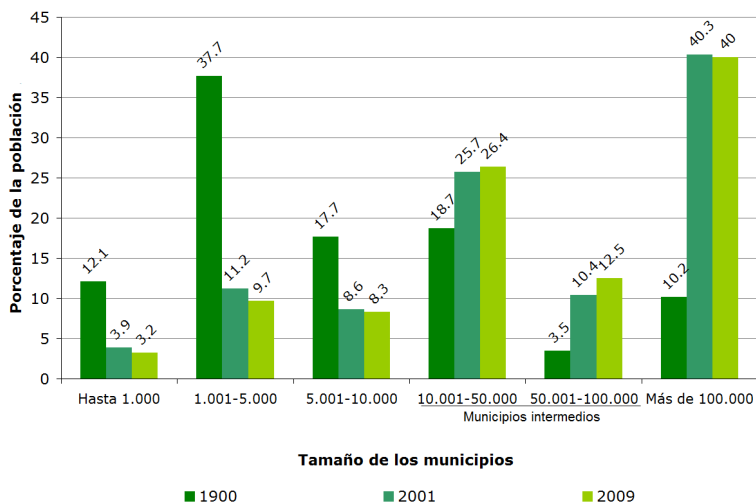


Figura 2. Porcentaje de habitantes por tamaño municipal en España en los años 1900, 2001 y 2009 (Fuente: Fundación BBVA, 2010).

El crecimiento urbano pone en peligro, y en ocasiones invade, los espacios naturales circundantes a la ciudad lo que, además de un problema de índole medioambiental, puede conllevar irregularidades urbanísticas de tipo legal. Hoy en día Juzgados de toda España se encuentran inmersos en investigaciones referentes a irregularidades urbanísticas, recalificaciones de terrenos, licencias para construir en zonas no urbanizables y posibles tratos de favor. Estos casos se han multiplicado allí donde hay un interés económico real en desarrollar promociones urbanísticas, especialmente en el litoral y en las afueras de las grandes ciudades.

Como solución a los problemas derivados de la urbanización, se hace cada vez más necesario implementar tecnologías que permitan visualizar los posibles efectos coaligados a las diferentes problemáticas para, a partir de ahí, adoptar en el menor tiempo posible decisiones políticas por parte de los diferentes niveles gubernamentales con objeto de minimizar la magnitud de dichos efectos y/o problemáticas. Por ello resulta fundamental el conocimiento preciso del escenario urbano actual que posibilite el desarrollo de un planeamiento urbano y territorial más eficiente.

Las áreas urbanas están construidas por materiales de muy variada naturaleza (asfalto, hormigón, metal, plástico, cristal, árboles, hierba, etc.) organizados en complejas estructuras como áreas residenciales, áreas industriales, áreas comerciales, sistemas de transporte, zonas de recreo, etc. (Welch, 1982). Análogamente a estos dos niveles: material y estructura, se definen los términos de cobertura y uso del suelo. La cobertura del suelo es un indicador biofísico que describe los materiales que cubren un territorio. El uso del suelo es un concepto abstracto que representa un criterio socioeconómico referido a la actividad dominante de un determinado lugar, incluyendo subdivisiones en categorías con distinto nivel de detalle. La urbanización es una de las causas principales en el cambio en estos usos y coberturas en un territorio, y su importancia crecerá a

medida que aumente la población agrupada alrededor de las áreas urbanas. (Breuste et al., 1998; Pickett et al., 2001; Whitford et al., 2001). Debido a su gran dinamismo, la información relativa a las áreas urbanas queda desfasada cada vez más rápidamente. Por ello, la disponibilidad de información cartográfica detallada y actualizada de estas zonas adquiere una gran importancia.

Actualmente, la disponibilidad de información geográfica es enorme si lo comparamos con los recursos a los que se podía acceder hace unos años. Las nuevas técnicas de recogida masiva de datos generan gran volumen de información con una periodicidad temporal cada vez más alta. Esta información no se limita únicamente a representar la respuesta espectral de las distintas coberturas terrestres, sino que incluye información referente a altimetría, medida a través de sensores de láser escáner, o sobre rugosidad de la superficie, tomada con sensores de radar. Sin embargo, este gran volumen de datos requiere de un procesamiento previo a su introducción como información útil en las bases de datos cartográficas.

El seguimiento y control de los usos del suelo propios de zonas urbanas necesita imágenes de alta resolución espacial, adquiridas mediante sensores aerotransportados o situados en satélites. Satélites como *Ikonos*, puesto en órbita en el año 1999, *QuickBird*, en el año 2001, o *WorldView-1* y *WorldView-2*, en los años 2007 y 2009, respectivamente, están provistos de sensores que proporcionan imágenes multispectrales de alta resolución espacial que detallan minuciosamente los fenómenos que se dan en el territorio de forma global con una elevada periodicidad.

En España, a mediados del año 2004 se estableció el Plan Nacional de Ortofotografía Aérea (PNOA), encuadrado dentro del marco del Plan Nacional de Observación del Territorio en España (PNOT) y cuya información está disponible para el uso por parte de las diferentes administraciones e instituciones del estado. El PNOT es un proyecto que responde a la necesidad, cada vez mayor, de disponer de una información del territorio adoptando un seguimiento continuo, el cual permita la interoperabilidad entre los distintos usuarios y esté adaptada a los estándares europeos (Directiva INSPIRE).

El objetivo del PNOA es disponer de una cobertura ortofotográfica continua a nivel nacional, basada en especificaciones técnicas comunes y consensuadas por los distintos organismos implicados (Arozarena et al., 2006). El proyecto básico consiste en la obtención, con una frecuencia de actualización de dos años, de ortofotos digitales con un tamaño de píxel de 50 cm (PNOA50). En función de las particularidades del territorio, el grado de consolidación de las edificaciones, densidad de población, dinámica urbanística, situación, etc., esta resolución puede no ser suficiente para cubrir las necesidades de los organismos participantes. Por ello, pueden proponerse vuelos complementarios para la generación de ortofotos con tamaños de píxel ente 10 y 25 cm (PNOA10 y PNOA25).

A partir del año 2009, en el marco del PNOA se comenzaron a capturar datos LiDAR de baja densidad (0,5 puntos/m<sup>2</sup>) con el objetivo de realizar modelos digitales del terreno (DTM) y modelos digitales de elevaciones (DEM) más precisos con los que dotar de una mayor exactitud planimétrica a las ortoimágenes. Por otro lado, estos datos posibilitan

múltiples nuevas aplicaciones: hidrológicas, control de líneas eléctricas, estudios de vegetación y ocupación del suelo, detección de cambios y edificaciones, etc. (Villa, 2008).

Asimismo, el PNOT y el Plan Nacional de Teledetección (PNT) han permitido el desarrollo del Sistema de Información sobre Ocupación del Suelo en España (SIOSE), cuya primera fase se presentó en 2009. El SIOSE configura un levantamiento de los usos y coberturas del suelo de España a escala 1:25.000, y pretende integrar las distintas Bases de Datos de ocupación de suelo de la Administración General del Estado y de las diferentes Comunidades Autónomas, para satisfacer los requerimientos de los organismos estatales y europeos (como la Agencia Europea de Medio Ambiente) en materia de conocimiento y de la ocupación del suelo, así como la actualización periódica del proyecto *Corine Land Cover*.

Tradicionalmente, la generación de información cartográfica sobre usos/coberturas del suelo en ámbitos urbanos se ha realizado mediante revisiones de campo y técnicas clásicas de fotointerpretación sobre imágenes aéreas de escalas grandes. Estas metodologías son lentas, caras y en cierta forma subjetivas. Además, requieren de operadores bien entrenados con conocimiento del entorno estudiado. La utilización de técnicas de procesado digital de imágenes ayuda a reducir el volumen de información a interpretar de forma manual y se adapta a los ritmos y necesidades de la sociedad actual, que requiere continuamente de datos precisos que reflejen fielmente la realidad del territorio. El desarrollo de metodologías efectivas para el procesado o la actualización automática de la información espacial en entornos urbanos se ha convertido en un objetivo de gran interés para la comunidad cartográfica internacional, siendo muy numerosas las investigaciones, publicaciones y grupos de trabajo dedicados a este fin.

Los primeros intentos para generar automáticamente, mediante técnicas de procesado digital de imágenes, información relativa al uso del suelo urbano no consiguieron los niveles de precisión y detalle necesarios para el planeamiento de las ciudades, debido principalmente a la baja resolución espacial de los sensores con tamaños de píxeles del orden de decenas de metros. La posterior llegada de nuevos satélites de alta resolución no consiguió satisfacer totalmente las perspectivas de aumento de la fiabilidad de la clasificación. Esto ha sido referido como un problema de incremento del "*ruido de la escena*" (Gastellu-Etchegorry, 1990), y está asociado a la gran heterogeneidad espacial en la respuesta espectral de las áreas urbanas. El análisis de las imágenes de alta resolución a nivel de píxel hace extremadamente difícil la extracción de características consistentes y representativas de los usos del suelo urbanos, puesto que estos se componen de diferentes tipos de cubiertas con diferentes respuestas espectrales (Barnsley et al. 1991). Esta variación espacial en la respuesta espectral viene condicionada, en parte, por el tamaño, forma y disposición de las edificaciones, así como de los espacios abiertos intra-urbanos. La heterogeneidad espectral puede convertirse en una característica útil al proporcionar una fuente potencial de información sobre las propiedades de la escena urbana (Barnsley y Barr, 2000).

El inconveniente central y fundamental de las técnicas de procesado digital de imágenes en el análisis de entornos urbanos es que, mientras que la relación entre la cobertura del suelo y la reflectancia espectral es relativamente simple, la relación entre esta y el uso del suelo no suele ser tan directa (Barnsley y Barr, 2000). Se han propuesto soluciones metodológicas en las que se analiza el entorno en varios niveles o escalas mediante la información auxiliar georreferenciada (Sadler et al., 1991). De esta forma se realiza una clasificación de coberturas e identificación de los elementos urbanos útiles, que permitan una correcta caracterización y clasificación del uso del suelo de las unidades cartográficas urbanas analizadas empleando técnicas de clasificación orientada a objetos.

En la clasificación de imágenes orientada a objetos, el análisis de la imagen no se realiza considerando el píxel como unidad, sino que la unidad de trabajo es el objeto-imagen o simplemente objeto. Un objeto es una agrupación de píxeles con características similares entre sí, creados mediante un determinado criterio de segmentación (Blaschke, T., 2010). El método empleado para realizar la segmentación tiene una importancia fundamental en las características de los objetos generados. Esta es la principal debilidad de la aplicación de metodologías de segmentación automática, ya que en función del algoritmo y los parámetros seleccionados los objetos generados serán distintos.

La clasificación de imágenes por parcelas es una variante de la clasificación orientada a objetos, donde la cartografía existente aporta límites para crear objetos. Estos límites permiten la definición de objetos con un mayor significado real que el que poseen las agrupaciones automáticas de píxeles. Esta metodología está especialmente indicada para paisajes artificiales como son los entornos urbanos, puesto que las unidades del paisaje están limitadas por bordes nítidos y relativamente estables en el tiempo.

La parcela catastral urbana (o simplemente parcela) representa la unidad administrativa de propiedad de suelo diferenciada en una zona urbana. Las edificaciones se configuran como los elementos primitivos propios de las zonas urbanas. El estudio de sus características particulares permite establecer una distinción morfológica de las áreas urbanas considerando un nivel de análisis interno de la parcela. Por otra parte, la agregación de parcelas contiguas produce entidades a un nivel superior: las manzanas urbanas (Thomson y Béra, 2008). Las manzanas urbanas son agrupaciones de parcelas rodeadas por viales públicos que combinan espacios abiertos y zonas edificadas, cuya geometría y relaciones topológicas producen la percepción de los entornos urbanos y definen las particularidades locales relacionadas con su función (Laskari et al., 2008). El análisis de las manzanas urbanas permite describir la morfología urbana a un nivel de agregación superior al de la parcela.

La caracterización de los diferentes niveles de agregación urbana requiere de información precisa sobre las edificaciones. Esta información puede extraerse fácil y directamente de cartografía o bases de datos topográficas existentes, pero éstas cuentan con la desventaja de la posible falta de actualización con respecto a la información adquirida por técnicas de teledetección. La solución que asegura la máxima vigencia de la información referente a las edificaciones consiste en su localización directa sobre los datos de trabajo empleados. Esto puede abordarse mediante técnicas de procesado digital de imágenes

que permiten la detección y localización automática de las edificaciones. Este es un campo altamente activo de investigación, tal y como se puede desprender del análisis del gran número de publicaciones relativas a este tema.

En esta Tesis se propone una metodología para la clasificación de usos del suelo en entornos urbanos empleando técnicas de clasificación orientadas a objetos. Los objetos, definidos a partir de los límites cartográficos de la parcela catastral son descritos de forma exhaustiva, incluyendo información sobre su contexto, que se define en dos niveles diferentes: externo e interno. En el nivel externo se describen las características globales de la manzana urbana a la que el objeto pertenece, mientras que en el nivel interno, se realiza una descripción de las características de las diferentes coberturas contenidas en la parcela. En ambos niveles de contextualización se describe un gran número de características, referidas muchas de ellas a las edificaciones. Las edificaciones son obtenidas empleando técnicas de detección automática basadas en métodos de procesado digital de imágenes. Con el fin de representar las edificaciones con la máxima precisión, se ha desarrollado una metodología adecuada a las zonas de trabajo cuando se dispone de información multispectral de alta resolución y datos tridimensionales.

## **1.2. Antecedentes**

### **1.2.1. Detección y localización de edificaciones**

La extracción automática de edificaciones a partir de información obtenida por técnicas de teledetección es un campo altamente activo de investigación. La detección y localización automática de edificaciones, así como de otros elementos propios de entornos urbanos y periurbanos, es una tarea compleja de realizar mediante técnicas de procesado digital de imágenes, lo que ha conllevado a que se haya propuesto un gran número de metodologías.

La problemática de las primeras metodologías propuestas para la detección de edificaciones fue analizada en profundidad por Mayer (1999), quien planteó los factores de principal relevancia a tener en cuenta al diseñar un modelo de detección de objetos: el rendimiento de la detección debe ser evaluado en la mayor parte de entornos posibles con medidas estadísticas; el conocimiento es importante, puesto que toda la información no se encuentra contenida en las imágenes; la detección debe realizarse en el espacio-objeto empleando información auxiliar disponible; es preferible la integración de diferentes metodologías al empleo de una única técnica para la resolución del problema. La utilización de la información espectral es un aspecto de especial importancia; la detección debe realizarse en un entorno dinámico: el contexto de la detección debe adaptarse tan pronto como se disponga de nueva información que permita simplificar el proceso.

En función de las fuentes de información utilizadas se distinguen tres tipologías principales de para la detección y localización de edificaciones. La primera utiliza únicamente imágenes aéreas o de satélite, combinando algoritmos de procesamiento de imágenes con distintos métodos de reconocimiento de formas o de clasificación. La segunda tipología de métodos son aquellos que emplean como única fuente información tridimensional. Por último, la tercera tipología para la detección de edificaciones es aquella que combina la información multispectral con la información tridimensional.

### **1.2.1.1. Localización de edificaciones empleando imágenes de alta resolución**

Durante décadas, se han utilizado imágenes aéreas de alta resolución para la extracción de edificaciones con finalidades cartográficas. Con el sucesivo auge de los satélites comerciales dotados de sensores de alta resolución, las imágenes de satélite se han presentado como una buena alternativa al coste de las fotografías aéreas para ciertas aplicaciones (Wei et al., 2004). La detección de edificaciones utilizando metodologías que emplean imágenes aéreas o de satélite supone, aún hoy en día, una tarea difícil, puesto que las edificaciones pueden presentarse como estructuras complejas con muchos detalles arquitectónicos, rodeadas por objetos que dificultan su detección, con una gran variabilidad de los materiales empleados en su construcción que provocan diferentes respuestas espectrales de los tejados. En función de las metodologías utilizadas, Kim y Muller (1999) dividen las técnicas de localización de edificaciones empleando únicamente imágenes en dos grandes grupos: de *bajo nivel* (*low-level*) y de *alto nivel* (*high-level*). Las técnicas de visión de *bajo nivel* consisten, fundamentalmente, en la detección y extracción de bordes y líneas de las imágenes y la posterior construcción de una serie de reglas o hipótesis que éstas han de cumplir para ser definidas como pertenecientes a edificaciones. Por su parte, las técnicas de visión de *alto nivel* tratan de imitar la cognición humana y la habilidad de tomar decisiones en función de la información contenida en la imagen. Así, metodologías propias de estas técnicas son la detección de objetos, el reconocimiento de formas y patrones y la clasificación de imágenes.

Debido a su sencillez metodológica, las técnicas de visión de *bajo nivel* fueron las primeras en emplearse para la localización de edificaciones. Muchas de las metodologías de visión de *bajo nivel* tienen, por lo general, una relativa sencillez en su diseño y un bajo coste computacional, pero se encuentran fuertemente limitadas al suponer consideraciones tales como que la forma de las edificaciones es rectangular, que los tejados son planos o con respuestas espectrales concretas, o que las edificaciones se disponen según una determinada orientación.

Uno de los primeros estudios fue llevado a cabo por Irvin y McKeown (1989), quienes empleando metodologías de detección de bordes, generan una serie de reglas que estos deben cumplir para poder ser definidos como edificaciones. Metodologías similares empleando técnicas más avanzadas tales como el detector de bordes de Canny (Canny, 1986) e hipótesis y reglas de pertenencia más complejas se describen en los trabajos de



Lin et al. (1994), Lin y Netavia (1998), Kim y Muller (1999) o Katartzis y Sahli (2008). Algunos autores proponen el uso de transformaciones entre espacios de representación, tales como la transformada de Hough (Kim et al., 2005; Cui et al., 2008) o de Fourier (Sohn y Dowman, 2001).

A medio camino entre las técnicas de *bajo* y *alto nivel* se encuentran las metodologías que utilizan sistemas activos, como metodología propuesta por Krishnamachari y Chellapa (1994). Estos realizan una extracción de líneas rectas trabajando con imágenes aéreas sobre las que construyen un modelo basado en campos aleatorios de Markov de manera que se obtiene la agrupación de las líneas en estructuras rectangulares que representan a las edificaciones. Mayunga et al. (2005) presentan un sistema semiautomático basado en el modelo de contornos activos para la detección de edificaciones en imágenes QuickBird. Este sistema requiere el marcado de un punto en el interior de cada edificación por parte del usuario, ajustándose el contorno activo a la forma de la edificación de manera automática. Posteriormente, Theng (2006) consigue la completa automatización de este sistema a partir de la inclusión de un detector de esquinas de edificaciones, que sirve como punto de marcado para la inicialización del contorno. Ahmady et al. (2008) y Ge et al. (2008) inicializan los contornos activos utilizando circunferencias regularmente repartidas que fusionan según aumenta el número de iteraciones. Ok (2008) emplea los contornos activos para analizar los bordes resultantes de una segmentación.

La mayor parte de las técnicas de visión de *alto nivel* empleadas para la detección automática de edificaciones a partir de imágenes se basan en la clasificación. Esta metodología encuentra mayores dificultades en zonas urbanas puesto que, en ellas, valores de idéntica reflectancia espectral pueden corresponder a objetos distintos y con funciones totalmente diferentes. Su compleja estructura y la disposición espacial de los diferentes tipos de cubiertas, tanto artificiales como naturales, implica que en muchos casos los valores de intensidad de los píxeles muestren la reflectancia de distintos materiales combinados (Donnay et al., 2001).

Pese a que algunos autores proponen localizar edificaciones utilizando técnicas de clasificación a nivel de píxel (Olsen et al., 2002; Shan y Lee, 2002; Lee et al., 2003; Lefèvre et al., 2007), la mayor parte de los trabajos abordan la detección de edificaciones utilizando la clasificación orientada a objetos. Los métodos de segmentación automáticos empleados para generar los objetos imágenes están principalmente basados en la homogeneidad de los datos. Los objetos-imagen son caracterizados con parámetros descriptores de su respuesta espectral, textura, forma (Stassopoulou y Caelli, 2000; Kundsén y Nielsen, 2004; Duan et al., 2004; Marangoz et al., 2004; Wei et al., 2004; Müller y Zaum, 2005; Liu y Prinnet, 2005; Lari y Ebadi, 2007; Sumer y Turker, 2008), derivadas del uso de la transformada *wavelet*, (Bellman y Shortis, 2003; Lin et al., 2008). Algunos trabajos (Vu et al. 2004a; Hofmann et al., 2006) tratan de establecer un mayor número de relaciones contextuales al utilizar técnicas de segmentación multiescala o multinivel, o cartografía auxiliar, referente a carreteras (Strassopoulou y Caelli, 2000) o límites catastrales (Hermosilla et al., 2008). Como último paso, se suele

recurrir a técnicas estándar de filtrado morfológico o la transformada de Hough para realizar una generalización y suavizado en las formas de los objetos clasificados como edificaciones (Tian et al., 2003; Wei et al., 2004; Liu et al., 2005; Li et al., 2006).

Otras técnicas descritas que emplean metodologías distintas a la clasificación ofrecen por lo general resultados menos satisfactorios, centrándose en la solución de casos muy particulares o fuertemente condicionados. Este es el caso del trabajo presentado por Croitoru y Doytsher (2003), donde proponen un sistema de detección de edificaciones iguales a los definidos por una forma patrón, utilizando el sistema de *pose clustering* de acumulación de votos. También se encuentra fuertemente condicionada la metodología presentada en Shackelford y Davis (2004), Jin y Davis (2005), Klaric et al. (2005) y Shyu et al. (2005), pues se presupone que las edificaciones se disponen de forma regular en la imagen, siempre según una misma orientación, y que los valores de intensidad de su respuesta espectral es mayor en las edificaciones que los de los demás elementos. Cabe destacar por su sencillez metodológica la técnica presentada por L'Homme et al. (2004), basada en la localización de las posiciones centrales de edificaciones de entornos periurbanos a partir de la obtención del parámetro de varianza de la matriz de co-ocurrencias de los niveles de gris a nivel de píxel.

Las metodologías de visión de *alto nivel* que emplean la clasificación de la imagen, y especialmente la técnica de clasificación orientada a objetos, ofrecen una respuesta aceptable en la detección de edificaciones. Esta respuesta se ve por lo general mejorada con la inclusión de información del entorno mediante la detección de las sombras. Uno de los principales problemas que se plantean en la detección de las sombras es que estas no tienen una misma naturaleza ni presentan las mismas características. Así, según Scanlan et al., (1990) pueden diferenciarse tres tipos básicos de sombras: proyectadas por objetos sobre el fondo, proyectadas por objetos sobre si mismos, y proyectadas por objetos sobre otros objetos. Pese a que la correcta detección y el análisis de las sombras no es una tarea fácil, su extracción es normalmente más sencilla que realizar directamente el análisis de las edificaciones que las proyectan (Irvin y McKeon, 1989). Además, se cuenta con la ventaja de que las sombras proyectadas por los objetos construidos por el hombre son normalmente homogéneas (Tsai, 2003), lo cual facilita su estudio y análisis.

De acuerdo con Dare (2005), los procesos de detección de sombras pueden dividirse en cuatro tipos, suponiendo que todos se encuentran estrechamente interrelacionados. Estas tipologías son: clasificación, segmentación, umbralización y modelado tridimensional o geométrico. Pese a la variedad, la mayor parte de los autores utilizan la umbralización como método principal para aislar las sombras, a partir de la banda pancromática (Irvin y McKeown, 1989; Madhavan et al., 2004; Dare, 2005; Liu y Prinet, 2005), la banda intensidad del espacio HSI (Müller y Zaum, 2005) o el primer componente principal de las bandas espectrales (Hermosilla et al., 2008). Algunas metodologías de umbralización tratan de localizar de manera automática el valor por el que realizar la umbralización de la imagen. Así, en Scanlan et al. (1990) se propone la detección de sombras aplicando un valor de umbralización obtenido a partir de la

zonificación de la imagen y de la comparación de la media de intensidad de cada una de estas zonas con el valor de la mediana de la imagen. Posteriormente, Lavigne et al. (2007) utilizan una modificación de este método para segmentar la imagen en 4 niveles de iluminación. En la misma línea de realizar un estudio zonal de la imagen se encuentra el trabajo presentado por Tsai (2003) quien divide recursivamente las imágenes hasta que cada una de las sub-imágenes presente una distribución bimodal, con las que encontrar un umbral adaptativo en función de las varianzas de ambos clústeres.

Algunos trabajos han presentado metodologías más complejas, sin que ello suponga necesariamente una mejora en la detección. Destaca el método presentado en los trabajos Shackelford y Davis (2004), Jin y Davis (2005), Klaric et al. (2005) y Shyu et al. (2005) dónde se utilizan operaciones de aperturas y cierres geodésicos con los que construir un perfil morfológico diferencial de cuyo análisis de la derivada se extraen las sombras. Por su parte Ambrosio et al. (2006) explotan las componentes invariantes de las sombras en el espacio del color  $c_1c_2c_3$  y la información de bordes para segmentar regiones sombreadas. Li et al. (2004) detecta las sombras de imágenes aéreas utilizando el modelo digital de superficies (DSM) obtenido por técnicas fotogramétricas. Vu et al, (2004) emplean clasificación por píxel convencional. Como paso final, la mayor parte de los autores emplean filtros morfológicos y condiciones de tamaño mínimo con el fin de suavizar y limpiar las sombras resultantes. Massalabi et al. (2004) van más allá y realizan un estudio de cada objeto detectado como sombra de su entorno y características para definirlos finalmente como tales.

La utilización de las sombras para la contextualización de entornos juega un importante papel en la identificación de elementos urbanos al trabajar únicamente con imágenes de alta resolución. Según Jin y Davis (2005) las sombras son un gran apoyo para la definición de un contexto para la detección de edificaciones, puesto que una característica común de las edificaciones es que estos tienen cierta altura sobre la superficie y consecuentemente proyectan sombras. La gran mayoría de los autores condicionan la existencia de las edificaciones a la proximidad o contigüidad de una sombra para detectar las edificaciones, considerando generalmente la dirección del ángulo de incidencia solar. Destacan dentro de este grupo los trabajos presentados por Irvin y McKeown (1989), Kim y Netavia (1999), Stassopoulou y Caelli (2000), Wei et al. (2004), Shackelford y Davis (2004), Jin y Davis (2005), Klaric et al. (2005), Müller y Zaum (2005), Shyu et al. (2005) y Hermosilla et al. (2008). En el artículo presentado por Liu y Prinnet (2005) la cercanía de una sombra se utiliza como una característica descriptiva más para realizar la clasificación.

### **1.2.1.2. Localización de edificaciones utilizando información tridimensional**

El estudio de la detección y localización de edificaciones utilizando únicamente fuentes de información tridimensional ha generado gran número de trabajos e investigaciones. Por lo general, se trata de metodologías menos elaboradas que las empleadas al trabajar con

imágenes aéreas o de satélite. Normalmente, al trabajar únicamente información altimétrica, la localización de edificaciones se utiliza como paso intermedio para la su extracción y su representación en entornos virtuales 3D, lo que explica por qué la mayoría de estas metodologías no son sometidas a evaluación estadística. La información tridimensional utilizada proviene de dos fuentes distintas: restitución fotogramétrica y más recientemente de tecnología LiDAR.

Al utilizar únicamente información altimétrica para la localización de edificaciones, se observan grandes diferencias entre los propuestos según sea la fuente de información utilizada. Así, la mayor parte de los estudios llevados a cabo empleando como fuente de información DSM obtenidos por técnicas fotogramétricas se basan en la umbralización del modelo digital de superficies normalizadas (nDSM), obtenido como la diferencia entre el DSM y el DTM, por un valor de altura que permita separar a las edificaciones de la vegetación. A los objetos resultantes de esta umbralización se les suele realizar un refinamiento de sus formas mediante la aplicación de filtros morfológicos, la transformada de Hough o la imposición de condiciones de tamaño o forma. Trabajos tales como Weidner y Forstner (1995), Vestri y Deveray (2001), Jordan et al. (2002), Champion (2007) o Karsli y Kahya (2008) utilizan esta metodología. La técnica presentada por Cord y Declercq (2001) aplica una segmentación sobre el DSM basándose en el criterio de diferencia de altitud, utilizando el método de crecimiento por regiones. Con los objetos resultantes de la segmentación aplican una umbralización simple de alturas con la que localizar las edificaciones.

Al realizar la detección de edificaciones utilizando datos LiDAR, la mayor parte de los autores (Tan y Shibasaki, 2002; Hofmann et al., 2002; Cho et al., 2004; Miliareisis y Kokkas, 2007) coinciden en aplicar una metodología de segmentación automática del DSM o nDSM, clasificando posteriormente los objetos en función de sus características de tamaño, forma, altura o rugosidad. Gran parte de los errores que se producen al utilizar esta metodología son debidos a la incorrecta clasificación de vegetación arbórea como edificaciones, que suele paliarse *a posteriori* con la aplicación de umbrales de altura y filtros en función del tamaño y la forma. La misma metodología, pero evitando la segmentación, es la utilizada por Vosselman et al. (2004), Ekhtari et al. (2008) y Xudong et al. (2008), estos últimos realizan una clasificación del nDMS, distinguiendo las edificaciones por sus características de forma, área y altura.

Tse et al. (2005) proponen una solución difícilmente aplicable a grandes superficies, pues trabajan a un nivel de detalle muy alto a partir de la nube de puntos LiDAR, con los que realizan una triangulación de Delaunay. Tras calcular para cada vértice los polígonos de Voronoi proceden a la detección de los saltos verticales utilizando el Análisis de Componentes Principales. Los saltos son representados por líneas que se generalizan creando polígonos cerrados. Un enfoque similar, pero aplicable en serie es el empleado en Wan y Hsu (2006) y Wan y Hsu (2008), quienes realizan un análisis *wavelet* a distintas escalas, en las que aplica el detector de bordes de Canny. Sobre estos bordes realiza un post-proceso con el que se cierran, rellenan y filtran los objetos detectados como edificaciones. Especialmente interesante resulta el método basado en *marked point*

*processes* propuesto en Lafarge et al. (2008), en el que las edificaciones son detectadas mediante la aproximación de manera iterativa de agrupaciones de paralelogramos regulares a la forma de las edificaciones. De esta forma, las edificaciones detectadas pueden ser sencillamente representados en tres dimensiones. Este método está limitado a un correcto funcionamiento exclusivo para zonas urbanas densas.

### **1.2.1.3. Localización de edificaciones combinando imágenes de alta resolución e información tridimensional**

La detección y localización de edificaciones utilizando, además de las imágenes de satélite, información altimétrica, conlleva generalmente una menor dificultad y unos mejores resultados que los obtenidos empleando únicamente imágenes. Al igual que en el caso de la detección de edificaciones trabajando únicamente con imágenes, pese a que algún trabajo utilice la clasificación a nivel de píxel (Olsen 2004), la mayor parte de los autores recurren a la clasificación a nivel de objetos-imagen generados mediante segmentación automática en función de criterios de homogeneidad. Los objetos son caracterizados, además de por sus respuestas espectrales, de textura, tamaño y forma, a través de la información tridimensional. (Kokubu y Mohiyama, 2001; Chen et al., 2004; Matikainen et al., 2004; Teo y Chen, 2004; Koc San y Tucker, 2007; Matikainen et al., 2007; Li et al., 2007; Oczipka et al., 2008).

Otros autores optan por la obtención de unas primeras edificaciones candidatas a partir de umbralizaciones del nDSM y el enmascaramiento de la vegetación utilizando la información multispectral, principalmente el índice NDVI (*normalized difference vegetation index* – Índice de vegetación de la diferencia normalizada). Las edificaciones detectadas pueden ser aceptadas o rechazadas en función de: su rugosidad (Rottensteiner et al., 2003; Rottensteiner et al., 2004), intensidad láser y espectral (Vu et al., 2004a), textura (Vozikis y Jansa; 2008), o tamaño (Vögtle y Steinle, 2000; Ferreira y Bernardino, 2006; Yu et al., 2010). Cheng et al. (2008) proponen una metodología mediante la que detectan las edificaciones a partir de la umbralización simple del nDSM, y posteriormente corrigen la forma del objeto detectado en función de las alineaciones extraídas de una ortofoto. Entre el resto de metodologías cabe destacar la propuesta realizada por Paparoditis et al. (1998), quienes ofrecen una solución que podría catalogarse de visión de *bajo nivel*, con la que integran la información bidimensional con la tridimensional analizando los bordes detectados en ambas fuentes de datos. Por su parte, Guo y Yasuoka (2002) combinan ambas fuentes de información mediante la utilización de contornos activos, que son iniciados con los bordes extraídos utilizando el nDSM, empleando la información espectral de la imagen para filtrar edificaciones.

#### **1.2.1.4. Discusión de los antecedentes de detección de edificaciones**

El análisis del estado del arte de los métodos de detección y localización de edificaciones pone de manifiesto la dificultad que entraña el problema. Así, pese al gran número de trabajos realizados en este sentido, todavía no se ha conseguido una metodología eficiente que solucione por completo la detección automática de las edificaciones.

La utilización de un mayor número de fuentes de información proporciona unos resultados más satisfactorios. Por ello, la combinación de datos de distinta naturaleza, tales como imágenes aéreas o de satélite, información altimétrica proveniente de técnicas fotogramétricas o sensores LiDAR y cartografía auxiliar, facilitará una metodología más robusta para su detección.

Las técnicas propuestas en la literatura se adaptan a las fuentes de información disponibles. Así, trabajando únicamente con imágenes, las metodologías basadas en la clasificación orientada a objetos son las más comúnmente empleadas. Debido a la ausencia de información tridimensional explícita, es frecuente el análisis de las relaciones de los objetos con las sombras detectadas, con el fin de refinar las metodologías de detección. Por otro lado, cuando se emplea exclusivamente información altimétrica, la detección de edificaciones se solventa principalmente mediante la aplicación de umbrales referentes a la altura de los elementos.

Al considerar ambos tipos de datos, las metodologías propuestas se basan en una combinación de las empleadas al trabajar con imágenes o DSM por separado. Así, la mayor parte de los autores utilizan técnicas basadas en la clasificación orientada a objetos, especialmente cuando se trabaja empleando datos LiDAR, debido a las características descriptivas que este tipo de información permite calcular. También es de uso frecuente la aplicación de valores de umbralización sobre el modelo digital, junto con el enmascaramiento de la vegetación utilizando información multiespectral proporcionada por las imágenes. Ningún trabajo realizado hasta el momento que combine el empleo de imágenes con datos tridimensionales propone la utilización de la información auxiliar de las sombras para el establecimiento de unas relaciones contextuales que permitan mejorar la detección de las edificaciones.

En lo referente a la aplicabilidad, cabe destacar que las metodologías analizadas no tratan de resolver la detección de las edificaciones en todo tipo de entornos, sino que se centran en un caso concreto. Esta parece la estrategia más coherente para abordar el problema, puesto que no parece lógico pensar que una misma metodología pueda funcionar correctamente en cualquier escenario. Por el contrario, existen también algunos métodos que están enfocados a detección de un caso particular de construcción o en un entorno demasiado concreto, donde cualquier intento de exportación a otro entorno resultaría totalmente ineficaz. Así, queda patente que las metodologías con una aplicabilidad óptima deben estar dotadas de cierta flexibilidad con respecto a los escenarios en las que son empleadas, sin pretender un funcionamiento perfecto en todos ellos.

Se ha podido comprobar cómo una parte de los trabajos referidos ignoran el proceso de evaluación estadística de los resultados, conformándose únicamente con un análisis visual de la detección. Sin embargo, la evaluación estadística es la herramienta fundamental con la que conocer la bondad del método propuesto. El análisis de la metodología de la detección de edificaciones debe analizarse no sólo de forma global, sino examinando por separado el rendimiento en los diferentes entornos. Además, resulta conveniente la estimación de la fiabilidad de los pasos intermedios del proceso.

### **1.2.2. Clasificación contextual en entornos urbanos**

La identificación, por parte de un operador humano, de los elementos de un mapa o una imagen de satélite se realiza mediante el estudio intuitivo de sus características individuales, así como del contexto espacial y topológico con respecto al territorio completo (Hussain et al., 2007). La interpretación y el análisis de los fenómenos espaciales es una tarea difícil y laboriosa. Según Almeida et al. (2007), esta consiste en la recolección de información que permita ser traducida en regiones con mayor significado y homogeneidad a partir de un conjunto de información carente de estructura. Puede llevarse a cabo mediante la identificación de las estructuras más significativas dentro de la colección de objetos aleatorios inicial, y mediante la comprensión de las relaciones topológicas de las estructuras identificadas.

En función de la categorización, las relaciones, las funciones y los atributos de los diferentes elementos que las componen, las zonas urbanas pueden descomponerse en varios niveles de agregación (Thomson y Béra; 2008). Mediante la agregación de los elementos primitivos, tales como edificaciones, zonas verdes, calles, etc., se constituyen composiciones a nivel de parcela, donde se definen estructuras tales como edificaciones aisladas o adosadas. La agrupación de las parcelas genera un nivel superior, en este caso nivel de manzanas urbanas, de cuya agregación se constituirían los barrios, los que a su vez agrupados conformarían los distritos.

El proceso de clasificación de la información espacial para determinar las coberturas del suelo puede ser considerado sencillo y directo en comparación con el proceso de derivar información relativa al uso del suelo urbano. Este proceso es más problemático debido a que el uso del suelo es un concepto complejo, que depende de una amalgama de factores económicos, sociales y culturales definidos en términos de funciones, en lugar de formas físicas. (Eyton, 1993). La caracterización precisa de los complejos patrones intra-urbanos es un proceso difícil (Bauer y Steinnocher; 2001), siendo habitual dividir el problema empleando métodos de aproximación en dos pasos. En el primer paso, se identifican las coberturas del suelo o los elementos característicos de especial relevancia. En un segundo paso, esta información se analiza en un contexto espacial que permita distinguir entre los usos del suelo presentes en la zona de estudio.

Principalmente, son dos los métodos empleados para la definición de relaciones contextuales para representar patrones y primitivas en problemas geográficos. Por un lado, los descriptores métricos de fragmentación (Alberti y Waddell, 2000; Zhang et al., 2004; Vanderhaegen y Canters, 2010), frecuentemente utilizados en análisis paisajísticos y ecológicos (McGarigal et al., 2002). Por otro, la teoría de grafos, que extiende el concepto de gráfico relacional de forma que permiten representar conjuntos de características intrínsecas, así como relaciones extrínsecas. (Barnsley y Barr, 1997; Barr and Barnsley, 1998; Barnsley y Barr, 2000; Zhan et al., 2002a; Almeida et al., 2007).

Dependiendo de los objetivos definidos, la caracterización urbana se centra en dos unidades: las edificaciones –especialmente en trabajos de generalización cartográfica- y las manzanas urbanas –al trabajar con datos adquiridos mediante técnicas de teledetección-. La caracterización y clasificación de edificaciones enmarcada en proceso de generalización cartográfica cuenta con el principal inconveniente de la ausencia de información multispectral y, en la mayoría de los casos, tridimensional. Por eso las edificaciones son generalmente descritas a través de sus características geométricas, relativas a las dimensiones, orientación principal o por índices que parametrizan la complejidad de su forma. Las relaciones contextuales establecidas son variadas, y se basan en características como adyacencia (Hussain et al., 2007), disposición de los espacial de las edificaciones (Boffet y Rocca-Serra, 2001; Burghardt y Steiniger, 2005), información temática auxiliar (Boffet y Coquerel, 2000), densidad de edificación (Boffet y Coquerel, 2000; Steiniger et al., 2009), o información sobre las zonas no edificadas (Boffet y Rocca-Sierra, 2001). La delimitación espacial del área para la contextualización de la edificación analizada se realiza empleando la información de las manzanas urbanas o estableciendo búferes o áreas de influencia alrededor de las edificaciones. El uso de la técnica de las áreas de influencia genera errores en la clasificación e identificación de zonas limítrofes entre dos tipologías urbanas diferentes, o en edificaciones aisladas rodeadas por otras tipologías.

La caracterización y clasificación de manzanas urbanas empleando información adquirida mediante técnicas de teledetección aplica generalmente el método descrito de aproximación de dos pasos. Así, a partir de la clasificación de las coberturas o la identificación de elementos significativos, principalmente las edificaciones, se asigna un uso a las parcelas (Zhan et al., 2000) o a las manzanas urbanas empleando diferentes técnicas de análisis contextual (Bauer y Steinnocher, 2001; Zhan et al., 2002b; Herold et al., 2003; Zhang et al., 2004; Wijnant y Steenberghen, 2004; Herold et al., 2005; Laskari et al., 2008; Novack et al., 2010).

Una de las características descriptivas comunes a la mayor parte de los trabajos, y que cuenta con una acreditada eficacia (Van de Voorde et al., 2009), es el ratio de superficie edificada. Esta se ve complementada con características volumétricas en el caso de que se cuente con información tridimensional. En esta línea, Yoshida y Omae (2005) y Yu et al. (2010) presentan una serie de descriptores con una interpretación cuantitativa para el análisis de entornos urbanos empleando datos LiDAR. Vanderhaegen y Canters (2010) define descriptores métricos para la clasificación de zonas urbanas, pero a través de un



análisis indirecto basado en la generación de perfiles para cada manzana urbana analizada de forma radial o paralela a los límites exteriores.

### **1.2.2.1. Discusión de los antecedentes de clasificación contextual de entornos urbanos**

Debido a su naturaleza antrópica, las áreas urbanas pueden descomponerse en diferentes niveles de agregación: edificios, parcelas, manzanas, barrios, etc. El estudio de los antecedentes referentes a la clasificación de usos del suelo en entornos urbanos pone de manifiesto la necesidad de un análisis de estos niveles que permitan la contextualización de los objetos analizados.

Las unidades de análisis más frecuentemente utilizadas son las edificaciones y las manzanas. La clasificación de edificaciones se realiza, principalmente, en problemas de clasificación con la finalidad de generalización cartográfica. En este caso, el contexto se define considerando las edificaciones próximas situados en un entorno definido empleando la cartografía vial o búferes de distancia. Se trata pues, de la definición y caracterización del contexto externo al elemento analizado.

Por su parte, las manzanas urbanas son el objeto de la clasificación cuando se trabaja con imágenes de alta resolución, empleándose, por lo general métodos de aproximación en dos pasos. En un primer paso se realiza una clasificación de las coberturas, cuyas características son empleadas para definir el contexto que permite una posterior clasificación del uso del suelo. Esta definición hace referencia al contexto interno del objeto.

En un nivel intermedio entre las edificaciones y las manzanas se encuentra la parcela catastral. Su empleo como unidad básica para la clasificación del uso del suelo en entornos urbanos aporta una división del territorio con un significado administrativo. Además, al situarse en un nivel intermedio, la parcela puede ser caracterizada en función de su contexto externo, definido por los límites de la manzana urbana, y su contexto interno, definido por las distintas coberturas que lo forman, y principalmente por las edificaciones.

Por otra parte, de la bibliografía disponible se desprende que el uso de datos LiDAR permite realizar una descripción más completa de las edificaciones que al considerar únicamente imágenes.



## Capítulo II

---

# OBJETIVOS Y ESTRUCTURA DE LA TESIS

---

### 2.1. Objetivos

El objetivo general de esta Tesis es **establecer una metodología fiable y robusta de detección automática de edificaciones y su incorporación a la clasificación automática de los usos del suelo en entornos urbanos mediante técnicas de análisis de imágenes orientadas a objeto**, empleando imágenes aéreas de alta resolución y datos LiDAR. Se han utilizado datos adquiridos en el marco del Plan Nacional de Ortofotografía Aérea (PNOA), a disposición de las administraciones públicas españolas. De esta forma, se pretende dar respuesta a la creciente necesidad de metodologías automatizadas que permitan la explotación masiva de este tipo de datos en los entornos más dinámicos del territorio.

Para afrontar el objetivo general, el trabajo se ha dividido mediante el planteamiento de los siguientes objetivos específicos:

- **Desarrollar una metodología semiautomatizada, basada en la combinación de imágenes de alta resolución y datos LiDAR, para la detección y localización de edificaciones.** Este procedimiento debe ser robusto, pero a su vez extrapolable y fácilmente aplicable a diversos entornos y escenarios.
- **Evaluar estadísticamente la eficacia de las metodologías propuestas para la detección y localización de edificaciones,** analizando conjuntamente el

rendimiento en la delimitación de las edificaciones, así como la calidad en la determinación espacial del emplazamiento de éstas. La potencialidad de los métodos propuestos debe considerarse y analizarse independientemente para diferentes tipologías estructurales de edificaciones en varias zonas de trabajo.

- **Definir características descriptivas que permitan cuantificar, además de las propiedades particulares de los objetos, el contexto de los elementos propios de entornos urbanos.** Se pretende que estas características tiendan a incorporar aspectos propios del proceso de cognición humana permitiendo describir numéricamente las propiedades del entorno, tanto interno como externo, de los objetos para su incorporación en los procesos de clasificación automática.
- **Analizar estadísticamente la contribución y el rendimiento de las características descriptivas del contexto en la clasificación de usos del suelo en diferentes tipos de entornos urbanos.** Esto implica un estudio pormenorizado de la relevancia de los descriptores de manera independiente, además del análisis del efecto del empleo conjunto de estas características en la calidad de la clasificación.
- **Estudiar la aplicabilidad de las técnicas basadas en la detección de edificaciones y clasificación automática de entornos urbanos para la determinación de parámetros necesarios en la creación/actualización de bases de datos de ocupación del territorio.** Se analizará en un caso concreto de bases de datos geo-espacial con vistas a su potencial transferencia en entornos de producción cartográfica.

## 2.2. Estructura de la Tesis

Esta Tesis está dividida en 6 capítulos y 3 anejos:

En el **Capítulo I** se realiza una presentación y justificación del problema de la clasificación automática de usos del suelo en entornos urbanos. A continuación se realiza una completa revisión y análisis crítico del estado del arte de las técnicas automática de detección y localización de edificaciones, así como de las metodologías de clasificación contextual de usos del suelo en entornos urbanos.

En el **Capítulo II** se definen los objetivos y la estructura de la Tesis.

En el **Capítulo III** se presentan las zonas de estudio en las que se han realizado los experimentos, mostrándose los materiales y datos empleados, sus características, así como las tareas de preprocesado necesarias.

En el **Capítulo IV** se describe y desarrolla la metodología experimental propuesta para la obtención de los objetivos. En primer lugar, se presentan las metodologías automáticas de detección de edificaciones adaptadas. Estas se basan en dos principios: el

establecimiento de umbrales y la clasificación orientada objetos. Se explica, además, el método de detección de sombras seguido y la metodología empleada para la inclusión de estas dentro del proceso de detección de edificaciones. Por último, se describen los métodos empleados para la evaluación estadística del proceso de detección y localización automática de edificaciones. Además, se presenta la metodología de evaluación seguida para valorar la aplicabilidad del empleo de técnicas basadas en la detección automáticas de edificaciones para la estimación del porcentaje de superficie edificada para la creación/actualización de bases de datos de ocupación de usos del suelo, frente al uso de métodos clásicos basados en percepción visual.

En la segunda parte de este capítulo, se desarrolla la metodología orientada a objetos propuesta para la clasificación de usos del suelo en entornos urbanos. Se presentan características descriptivas de las parcelas que tratan de imitar el proceso de cognición humano. Estas se basan en la información multispectral, tridimensional, y su geometría. Además, se analiza el contexto atendiendo a dos niveles diferentes: interno y externo. Las características del contexto interno describen las diferentes coberturas internas del objeto analizado. Las características del contexto externo del objeto describen en un nivel de agregación superior al de la parcela, que en entornos urbanos corresponde con la manzana urbana. Buena parte de las características descriptivas del contexto están relacionadas con las edificaciones, que son detectadas mediante técnicas automáticas.

En el **Capítulo V** se recogen y analizan críticamente los resultados de los ensayos realizados descritos en el capítulo anterior. En una primera sección se presentan los resultados de la evaluación estadística de las metodologías de detección de edificios analizadas, tanto a nivel de áreas como de objetos, así como el efecto que produce el empleo de las sombras en la detección.

En el segundo apartado se presenta el análisis del poder de discriminación de las características descriptivas propuestas, así como su efecto y utilidad en la clasificación de usos del suelo de entornos urbanos.

En el tercer apartado se presentan los resultados de la comparación de la aplicación de las metodologías automáticas frente a las estimaciones mediante técnicas de percepción visual, para el cálculo de la superficie edificada y de las tipologías de edificación, y la aplicabilidad de su utilización para la construcción o actualización de bases de datos geoespaciales de ocupación del territorio.

En el **Capítulo VI** se presentan las conclusiones extraídas y se definen las posibles futuras líneas de investigación a seguir.

En el **Anejo I** se recogen los fundamentos del Plan Nacional de Observación del Territorio (PNOT), del que es parte el Plan Nacional de Ortofotografía Aérea (PNOA), de donde proviene una gran parte de los datos utilizados. Este Anejo incluye, además, una descripción del Sistema de Información sobre Ocupación del Suelo de España (SIOSE), así como una explicación de cómo se clasifican las edificaciones y las zonas urbanas en esta base de datos cartográfica.

En el **Anejo II** se presentan de forma completa las matrices de confusión de la clasificación de los entornos urbanos para las diferentes zonas de estudio consideradas.

En el **Anejo III** se listan las publicaciones científicas relacionadas con esta Tesis realizadas por el autor, divulgadas a través de revistas internacionales con sistema de revisión por pares, congresos científico-técnicos, o a través de publicaciones de otro tipo.

## Capítulo III

---

### MATERIAL Y DATOS

---

#### 3.1. Zonas de estudio

Se ha trabajado sobre tres zonas de estudio situadas en diferentes municipios de la provincia de Valencia: Moncada, Oliva y Sagunto (ver localización en el mapa de la Figura 3). Moncada es un municipio del área metropolitana con un área urbana densa consolidada de tamaño medio, grandes áreas de urbanizaciones unifamiliares, y varios polígonos industriales de mediano tamaño. La actividad agrícola sigue teniendo una relativa incidencia en el municipio al centrarse en cultivos muy competitivos tales como productos cítricos y hortofrutícolas. Oliva tradicionalmente ha sido una población eminentemente agrícola –con el predominio del cultivo del naranjo–, aunque desde los inicios de los años 90 ha comenzado a manifestarse un notable crecimiento industrial y turístico. Así, además de contar con un núcleo urbano consolidado de importancia, cuenta con grandes zonas residenciales con apartamentos en la zona litoral y nuevas urbanizaciones residenciales unifamiliares, rodeadas en muchos casos de campos de golf. Pese a la existencia de áreas industriales en la zona, ningún polígono de suficiente importancia ha sido capturado en el vuelo LiDAR. Sagunto tiene dos núcleos urbanos principales: el casco histórico o Sagunto-Ciudad y Puerto de Sagunto. En esta zona se mezclan zonas puramente urbanas, con grandes extensiones de zonas industriales con una especialización sidero-metalúrgica. Además, existen áreas residenciales unifamiliares de reciente construcción y cultivos de agrios.

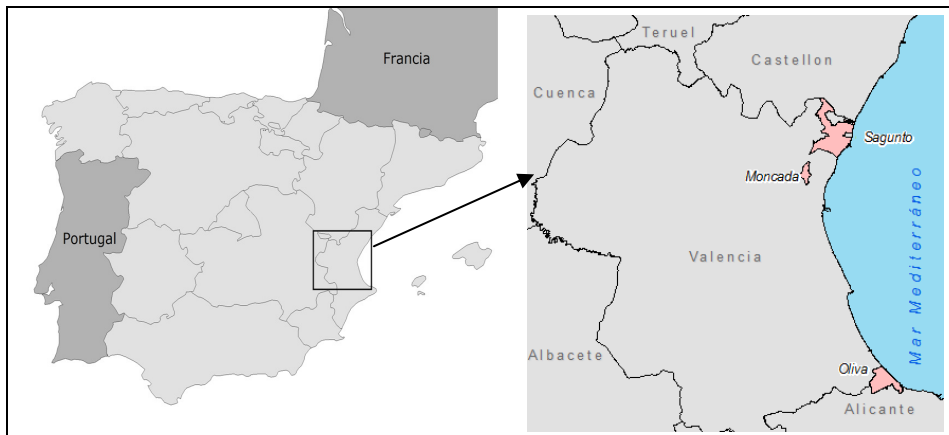


Figura 3. Localización de las zonas de estudio.

## 3.2. Datos

Para cada zona de trabajo se ha contado con datos de tres naturalezas diferentes: imágenes multiespectrales de alta resolución, datos tridimensionales LiDAR y cartografía derivada del SIOSE y catastro en formato vectorial. La Tabla 1 se recoge un resumen de las características principales de la información empleada en este estudio, mientras que en la Figura 5 se muestran ejemplos representativos de estos datos de forma gráfica.

La cartografía catastral utilizada presenta el formato vectorial *ESRI shapefile*. Se ha contado con información tanto de urbana como de rústica, en sus divisiones a nivel de subparcelas y parcelas, respectivamente. La escala nominal es de 1:2.000 para la cartografía catastral rústica y 1:1.000 para la urbana.

Se han utilizado dos tipos de imágenes diferentes: adquiridas mediante sensores multiespectrales aerotransportados o mediante sensores situados en plataformas satelitales. Así, en Moncada se ha trabajado con una ortoimagen generada a partir de una imagen adquirida con el sensor *QuickBird*, en febrero de 2004. La resolución espacial de esta imagen es de 0,6 metros/píxel en las cuatro bandas (IR, R, G y B) y ha sido obtenida al realizar un procedimiento de fusión por el método de componentes principales, que consiste en la sustitución del primer componente principal por la imagen pancromática. El resultado se ha remuestreado empleando el método de interpolación bilineal. La resolución radiométrica es de 11 bits y las bandas multiespectrales tienen los siguientes intervalos de longitud de onda: 0.45 - 0.52  $\mu\text{m}$  (B), 0.52 - 0.60  $\mu\text{m}$  (G), 0.63 - 0.69  $\mu\text{m}$  (R), y 0.76 - 0.90  $\mu\text{m}$  (IR).

En las zonas de Sagunto y Oliva se utilizaron imágenes digitales pertenecientes al PNOA del año 2006. Cuentan con una resolución espacial de 0,5 metros/píxel, y tres bandas espectrales (IR, R, G).



Los datos LiDAR fueron adquiridos con diferentes sensores para las distintas zonas de estudio. En Moncada, los datos LiDAR fueron tomados en diciembre de 2003 por encargo de la Confederación Hidrográfica del Júcar empleando un escáner láser aerotransportado modelo Optech ALTM 2033 (*Airborne Laserscanner Terrain Mapper*). Estos datos presentaban un alto grado de procesado, con los puntos distribuidos en una malla regular  $1 \times 1$  (densidad de 1 punto/m<sup>2</sup>). De esta zona se dispuso también de un DTM en el que se habían corregido los errores mediante técnicas de edición manual. En la zona de estudio de Oliva, los datos LiDAR fueron adquiridos empleando un sistema LiDAR Optech ALTM 3025 en agosto de 2009 por el Instituto Cartográfico de Cataluña, con una densidad nominal de 2 puntos/m<sup>2</sup> y una densidad real media de 3,1 puntos/m<sup>2</sup>, presentando una gran variabilidad en su distribución espacial sobre el terreno, tal y como se observa en la Figura 4.a. En Sagunto los datos LiDAR fueron adquiridos en el marco del PNOA durante el mes de agosto de 2009 con un sensor RIEGL LMS-Q680. Cuentan con una densidad de puntos nominal de 0,5 puntos/m<sup>2</sup>, pero una densidad real media de 0,8 puntos/m<sup>2</sup> y una gran homogeneidad en su distribución sobre el terreno (Figura 4.b). Los DTM para estas zonas de estudio se generaron siguiendo la metodología iterativa descrita en la Sección 3.3.

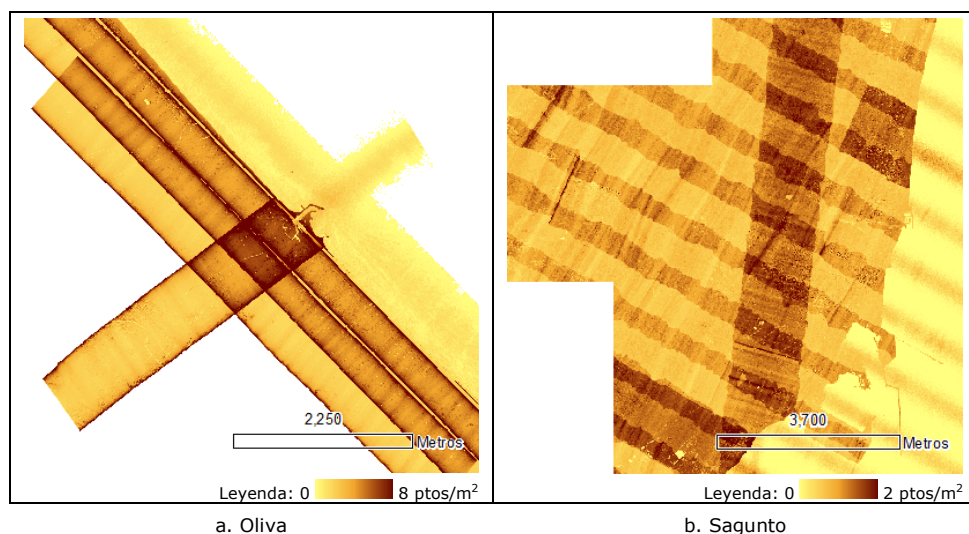


Figura 4. Mapas de densidades de los datos LiDAR.

Como puede observarse, para cada zona de estudio se trabaja con diferentes densidades en los datos LiDAR. Es de esperar que los modelos generados con mayores densidades tengan una mayor definición que con densidades más bajas, lo que puede afectar negativamente en el proceso de detección de las edificaciones. Se ha realizado un ensayo con el fin de analizar este efecto. Para ello se ha trabajado con los datos de mayor densidad, pertenecientes a la zona de estudio de Oliva. Se ha descartado trabajar con los datos de la zona de estudio de Moncada puesto que estos presentan un alto nivel de pretratamiento al aparecer distribuidos en una malla regular. Para analizar el efecto del valor de la densidad de los datos LiDAR en la precisión de la detección y localización de

edificaciones, se ha procedido a reducir esta de manera controlada. Así, para conseguir una densidad homogénea y uniforme a lo largo de la zona de estudio se ha fraccionado el territorio en teselas regulares de 10×10 metros, en las que se han eliminado puntos de manera aleatoria hasta conseguir, para cada una de esas teselas, la densidad deseada. Se ha partido de una densidad nominal original de 2 puntos/m<sup>2</sup>, reduciéndose a valores controlados de 1 y 0,5 puntos/m<sup>2</sup>, simulando de esta forma las densidades del resto de conjuntos de datos LiDAR empleados en Moncada y Sagunto.

Tabla 1. Tabla resumen de los datos empleados para cada zona de estudio.

Zona	Datos	Descripción
<b>Moncada</b>	Imagen QuickBird	Fecha de adquisición: Febrero 2004 Resolución espacial: 0,6 m/píxel Resolución radiométrica: 11 bits Bandas: IR, R, G, B
	Datos LiDAR	Fecha de adquisición: Diciembre 2003 Sensor Optech ALTM 2033 Densidad nominal: 1 punto/m <sup>2</sup>
	Cartografía	Catastro de rústica (1:2.000) Catastro de urbana (1:1.000) Recintos SIOSE (1:5.000)
<b>Oliva</b>	Ortofotos	PNOA 2006 Resolución espacial: 0,5 m/píxel Resolución radiométrica: 8 bits Bandas IR, R, G.
	Datos LiDAR	Fecha de adquisición: Septiembre 2009 Sensor Optech ALTM 3025 Densidad nominal: 2 puntos/m <sup>2</sup>
	Cartografía	Catastro de rústica (1:2.000) Catastro de urbana (1:1.000) Recintos SIOSE (1:5.000)
<b>Sagunto</b>	Ortofotos	PNOA 2006 Resolución espacial: 0,5 m/píxel Resolución radiométrica: 8 bits Bandas: IR, R, G
	Datos LiDAR	PNOA 2009 Sensor RIEGL LMS-Q680 Fecha de adquisición: Agosto 2009 Densidad nominal: 0,5 puntos/m <sup>2</sup> Densidad real media: 0,8 puntos/m <sup>2</sup>
	Cartografía	Catastro de rústica (1:2.000) Catastro de urbana (1:1.000) Recintos SIOSE (1:5.000)

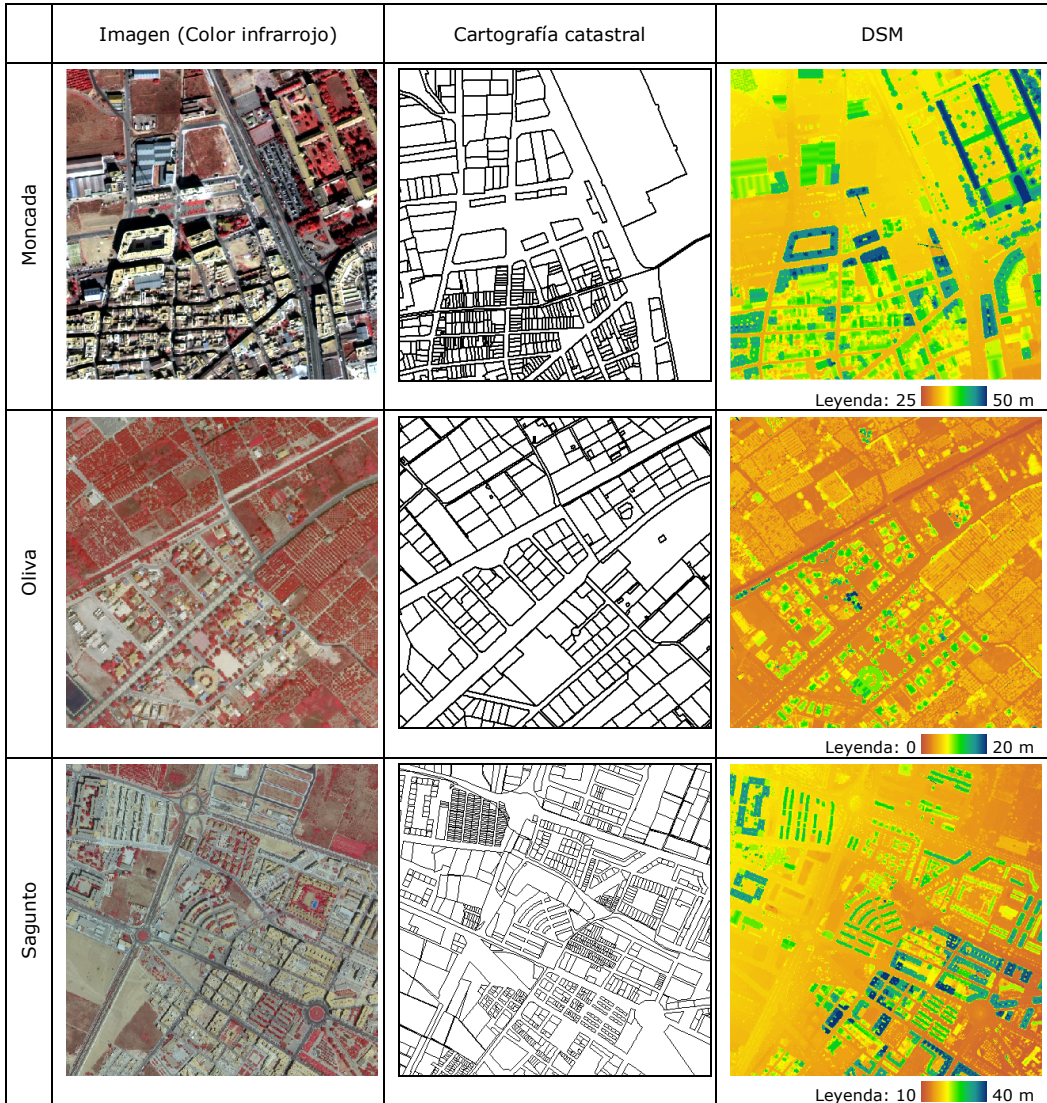


Figura 5. Detalles de los datos empleados en cada una de las zonas de estudio.

### 3.3. Preprocesado de los datos LiDAR: cálculo de los DTM

Un DTM es una estructura numérica de datos que representa la distribución espacial de la altitud de la superficie del terreno (Felicísimo, 1994). Por su parte, un DSM representa la superficie topográfica del terreno que incluye edificaciones, vegetación, carreteras y demás elementos naturales del terreno y se calcula a partir de la selección de los puntos con elevación máxima en un vecindario determinado. La diferencia entre un DSM y un DTM produce el nDSM, que es un modelo en el que se ha eliminado la influencia del terreno sobre las alturas, de tal manera que representa las alturas físicas de los elementos del terreno (ver Figura 6).




Figura 6. Modelo digital de superficies, DSM (izquierda), modelo digital del terreno, DTM (centro) y modelo digital de superficies normalizado, nDSM (derecha) calculados a partir de los datos LiDAR.

El cálculo del DTM depende de varios factores entre los que destaca la densidad de elementos geográficos con altura presentes en la zona de estudio. Éstos impiden, en la mayoría de los casos, que los haces de energía láser emitidos lleguen al suelo. Otro de los factores a tener en cuenta son la variación de la pendiente del terreno y el tamaño de los objetos. La selección de los puntos candidatos para obtener el DTM es el problema fundamental a resolver, y su definición mediante un proceso completamente automático es una tarea compleja (Baltsavias, 1999).

La metodología empleada para la generación de los DTM se basa en un algoritmo iterativo, descrito completamente en Estornell et al. (2010), consistente en la selección de puntos con cota mínima en un área de búsqueda determinada, estableciendo un DTM inicial. Posteriormente se realiza en los datos iniciales una nueva búsqueda de puntos mínimos aplicando áreas de búsqueda menores. Los nuevos puntos seleccionados se comparan con el DTM obtenido en el paso anterior. Se define un umbral en la diferencia de la cota de un determinado punto seleccionado con respecto a la asociada a ese punto en el DTM de comparación, eliminándose los puntos seleccionados cuya cota supere el valor umbral. Utilizando este método iterativo se consigue generar un DTM más preciso

ya que se eliminan puntos asociados a objetos situados sobre la superficie terrestre como la vegetación.

El algoritmo empleado se divide en cinco pasos principales (ver Figura 7). En primer lugar, se realiza una división la zona de estudio en ventanas de estudio cuadradas, fijando un tamaño de ventana inicial ( $v1$ ). En cada una de ellas, se selecciona el punto que presente la cota mínima. Con los puntos de cota mínima de cada una de las ventanas se realiza el cálculo un primer DTM aproximado ( $DTM1$ ), aplicando una interpolación lineal sobre la triangulación realizada mediante el método de Delaunay (Delaunay, 1934). A continuación, se selecciona un segundo tamaño de ventana ( $v2$ ), de tamaño inferior que  $v1$ , con el que se efectúa una nueva búsqueda de puntos mínimos a partir de los datos originales, de forma que se evite la pérdida de información original en los procesos de interpolación (Axelsson, 1999). De entre todos los puntos seleccionados en el paso anterior, se mantienen aquellos cuya diferencia respecto al  $DTM1$ , es inferior a un umbral de altura determinado ( $u1$ ). Los puntos cuyas diferencias absolutas son superiores a este umbral son eliminados del análisis. Con los puntos mínimos no eliminados se genera un nuevo modelo  $DTM2$ . Seguidamente, se elige un tercer tamaño de ventana de estudio ( $v3$ ), menor a  $v2$ , seleccionándose de nuevo los puntos mínimos en cada ventana de análisis. Por último, se eliminan los puntos seleccionados cuya diferencia respecto al  $DTM2$  supera un umbral determinado ( $u2$ ), que no tiene por que coincidir con el valor  $u1$ . Con los puntos seleccionados que no han sido eliminados por la umbralización se realiza el cálculo del DTM final.

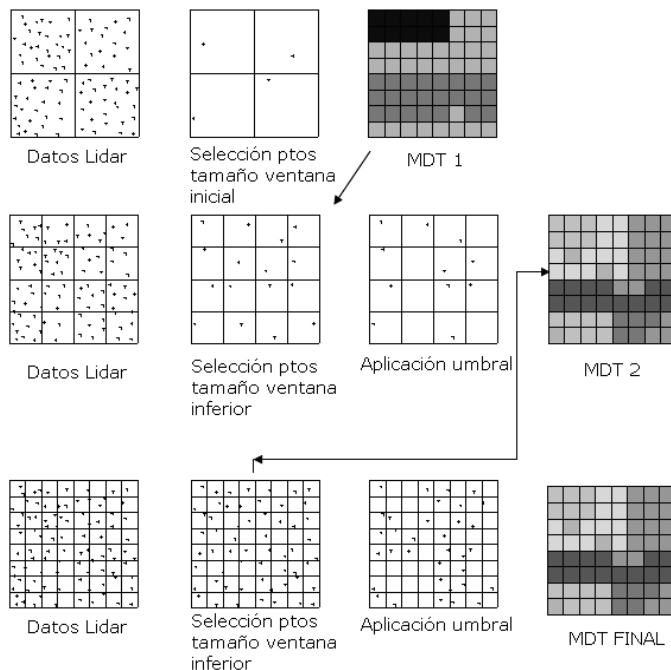


Figura 7. Esquema del proceso cálculo del DTM (Fuente: Estornell et al., 2010).

### 3.4. Programas informáticos empleados

La programación específica de los métodos de detección de edificaciones, extracción de características contextuales y cualquier procesado digital de las imágenes se ha realizado a través de desarrollos propios de software, combinando el lenguaje de programación *IDL (Interactive Data Language)* con *ENVI*. Ambos programas son propiedad de la compañía *ITT Visual Information Solutions*. Estos desarrollos han contribuido a mejorar los programas informáticos de extracción de características que desarrollados en el Grupo de Investigación de Cartografía GeoAmbiental y Teledetección (CGAT) en el marco de los proyectos de clasificación del territorio y actualización de bases de datos cartográficas realizados. Estos programas son: FETEX 2.0 y LIDEX. El software FETEX 2.0 (Ruiz et al., en prensa) ha sido utilizado para llevar a cabo la extracción de características descriptivas a nivel de objetos cartográficos. La gestión de los datos LiDAR, y cálculo de modelos digitales DTM, DSM y nDSM, aplicando el algoritmo descrito en Estornell et al. (2010), así como la extracción de características descriptivas tridimensionales se ha efectuado mediante el software LIDEX.

La manipulación de los ficheros vectoriales *shapefiles* y el proceso de edición y maquetación cartográfica se ha realizado con el programa *ArcGIS*, de *ESRI*.

Para la aplicación del método de segmentación de imágenes basado en la detección de bordes se ha empleado el módulo *Feature Extraction* del programa *ENVI (ITT Visual Information Solutions)*.

La segmentación por el método de crecimiento de regiones se ha realizado mediante el algoritmo incluido en el software *Definiens Professional*, propiedad de la compañía *Definiens*.

La generación de los árboles de clasificación se ha realizado utilizando el algoritmo C5.0, implementado en el programa comercial *See5*, desarrollado por *Rulequest Research*.

El análisis discriminante lineal se ha realizado empleando el programa *Statistica*, de la empresa *StatSoft*.

## **Capítulo IV**

---

### **METODOLOGÍA**

---

#### **4.1. Introducción**

En este capítulo se detallan las técnicas empleadas para la clasificación de usos del suelo en entornos urbanos. En primer lugar, se presentan las metodologías automáticas de detección de edificaciones adaptadas y evaluadas, que se basan en dos principios: el establecimiento de umbrales y la clasificación orientada objetos. Se trata de las técnicas más comúnmente empleadas para detectar edificaciones. Se describe además, el método de detección de sombras empleado y su inclusión dentro del proceso de detección de edificaciones.

En la segunda parte de este capítulo se explica la metodología orientada a objetos para la clasificación de usos del suelo en entornos urbanos. Los objetos-imagen son caracterizados a través de la información multiespectral y tridimensional, combinada con otras variables descriptivas, calculadas principalmente a partir de las edificaciones, que permiten caracterizar morfológicamente las diferentes áreas urbanas mediante el análisis del contexto interno y externo de los objetos.

## **4.2. Métodos de detección de edificaciones**

Al abordar la detección de edificaciones al combinar imágenes de alta resolución con información tridimensional LiDAR, las aproximaciones metodológicas más comúnmente empleadas pueden categorizarse en dos grupos principales: las que se basan en el establecimiento de umbrales, y las que utilizan un enfoque basado en la clasificación orientada a objetos. Se han adaptado ambos métodos para su optimización en los entornos urbanos de las zonas de trabajo analizadas. En esta sección se describen completamente estas metodologías.

Se analiza también el efecto de la inclusión de las sombras en el proceso de detección y localización de las edificaciones, por lo que se propone método de detección de sombras que se ha empleado y la metodología para la consideración de esta información en el proceso de detección de edificaciones.

Para finalizar esta sección, se detallan los métodos de evaluación estadística de la detección de edificaciones empleados para conocer el rendimiento y la fiabilidad de las metodologías analizadas. La evaluación estadística se realiza utilizando dos enfoques distintos: por un lado, se evalúa la calidad en la detección de las zonas que contienen edificaciones (evaluación por área o por píxel) y, por el otro, se comprueba la eficacia en la identificación de las edificaciones como unidades independientes (evaluación por objeto).

### **4.2.1. Detección de edificaciones basada en el establecimiento de umbrales**

Las edificaciones se caracterizan y diferencian del resto de elementos de su entorno principalmente por la altura. Además de las edificaciones, la altura es también una característica significativa en los árboles. El análisis de la información altimétrica ofrece la posibilidad de distinguir las edificaciones, mientras que la inclusión de información multiespectral, referida principalmente a la banda del infrarrojo, permite acometer una discriminación entre edificaciones y árboles. Así, la detección de edificaciones basada en el establecimiento de umbrales consiste en la definición de dos valores de umbralización, uno en altura y otro con respecto a la presencia o densidad de vegetación, tal y como se muestra en el esquema de la Figura 8.

El umbral con respecto a las alturas de las edificaciones se establece con respecto al nDSM. Para aislar y enmascarar la vegetación se establece un umbral sobre la imagen del NDVI. El procedimiento para el cálculo de los valores umbral puede realizarse mediante el método de ensayo y error, o de forma más empírica y semiautomática, de modo similar en ambos casos tomándose muestras de entrenamiento de las áreas que se



desea diferenciar: el suelo de las zonas con edificaciones, y las áreas sin vegetación de las zonas arboladas.

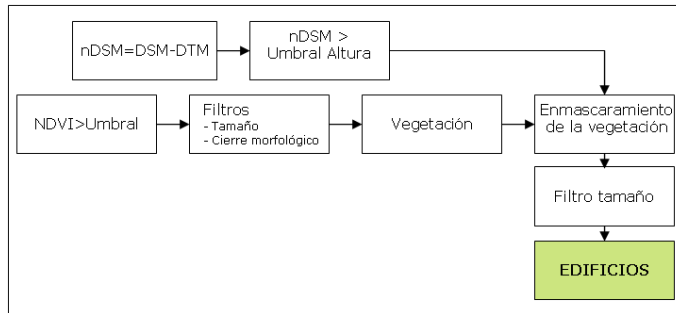


Figura 8. Esquema del algoritmo de detección de edificaciones propuesto basado en la aproximación metodológica de establecimiento de umbrales.

Una vez tomadas las muestras se calculan ambos histogramas, aproximándolos a curvas gaussianas para simplificar su forma y facilitar el cálculo del punto en el que se produce su intersección. El valor umbral que se aplica a cada imagen es el correspondiente a la intersección de ambas curvas. A la máscara resultante de la umbralización de la vegetación se le aplica un filtro morfológico de cierre, para suavizar las formas resultantes, y se descartan los objetos muy pequeños, para eliminar el ruido.

El último paso es la combinación de las máscaras de vegetación y de alturas. Al producto de esta combinación se le aplican de nuevo operaciones morfológicas de cierre para refinar sus formas. Además, los elementos de menor tamaño son eliminados. Los objetos resultantes de estas operaciones representan las edificaciones detectadas. En la Figura 9 se muestra gráficamente el proceso de detección de edificaciones basado en el establecimiento de umbrales.




Figura 9. Esquema gráfico del proceso de detección de edificaciones empleando el algoritmo basado en establecimiento de umbrales.

## 4.2.2. Detección de edificaciones basada en clasificación orientada a objetos

Según Hay y Castilla (2006) el análisis de imágenes basado en objetos se fundamenta en la división de las imágenes en objetos con significado propio, de los que se puedan obtener sus características descriptivas desde diversos puntos de vista (espacial, espectral, etc.). Las aproximaciones metodológicas de detección de edificaciones basadas en la clasificación orientada a objetos sigue la metodología de una clasificación de este tipo. En la Figura 10 se muestra el esquema de la metodología específica propuesta, que comienza con la segmentación la segmentación de la imagen para generar los objetos que serán posteriormente clasificados.

La segmentación se ha realizado utilizando la información del nDSM. De esta forma, se espera que los objetos resultantes tengan un mayor significado para el propósito de detectar edificaciones que al utilizar información espectral. Las respuestas espectrales presentes en un mismo edificio pueden llegar a ser muy diferentes entre sí, lo que produciría una *sobre-segmentación* de la imagen, dificultando así la clasificación.

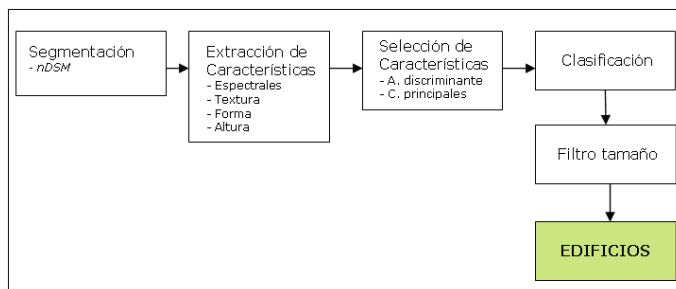


Figura 10. Esquema del algoritmo propuesto de detección de edificaciones basado en la aproximación metodológica de clasificación orientada a objetos.

Tras la definición de los objetos, se procede a la extracción de características descriptivas que permitan su clasificación. Se han calculado características de cuatro tipos diferentes: espectrales, de textura, de forma y de altura. Las características espectrales proporcionan información sobre la respuesta espectral de los objetos. Las características de textura aportan información acerca de la distribución espacial de los valores de intensidad en la imagen. Las características de forma describen la complejidad del contorno de los objetos. Las características de altura son aquellas derivadas de los datos LiDAR, más concretamente del nDSM.

Debido al alto número de características resultantes, algunas de ellas pueden presentar información redundante. Su inclusión puede actuar como ruido y dificultar una eficiente clasificación de los objetos. Se ha aplicado el método de análisis discriminante lineal para analizar la significancia de las características descriptivas.

Con las características seleccionadas y utilizando el método de los árboles de decisión se ha realizado la clasificación de los objetos. Un árbol de decisión es un conjunto de condiciones organizadas en una estructura jerárquica, de tal manera que la clase a asignar a un objeto se puede determinar siguiendo las condiciones que se cumplen desde la raíz del árbol hasta alguna de sus hojas. El algoritmo utilizado para la creación de los árboles de clasificación es el C5.0. Para aumentar la precisión de las clasificaciones se ha empleado el método multclasificador *boosting* (Friedman et. al., 2000). Se han definido en diferentes clases enfocadas a la discriminación de la mayor variedad de edificaciones. Por ello se definen además del resto de clases, clases correspondientes a las distintas tipologías de edificaciones presentes en el área analizada.

El paso final para la definición de las edificaciones detectadas es la selección y el agrupamiento de aquellos objetos que han sido clasificados en cualquiera de las clases de edificaciones definidas. A estos se les aplica un filtrado en función del tamaño con el fin de eliminar objetos muy pequeños. En la Figura 11 se muestra gráficamente el esquema del proceso de detección de edificaciones basado en clasificación orientada a objetos.

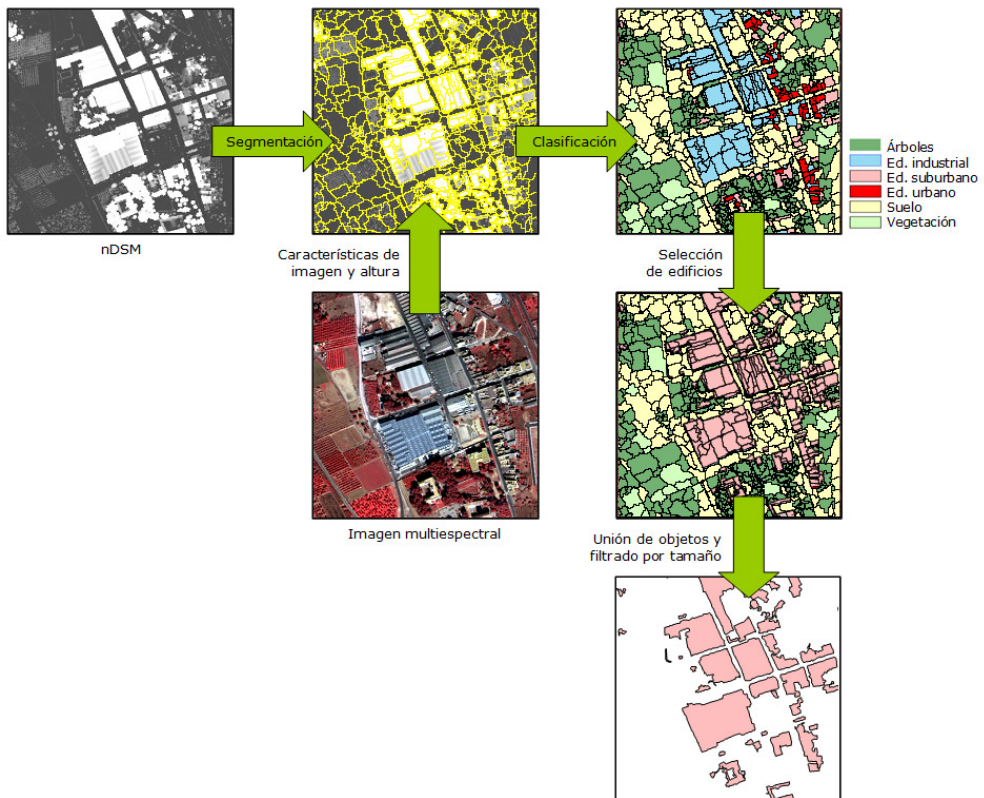


Figura 11. Esquema gráfico del proceso de detección de edificaciones empleando el algoritmo basado en clasificación orientada a objetos.

#### 4.2.2.1. Segmentación de la imagen

La segmentación es el proceso de división de una imagen en segmentos u objetos mediante el agrupamiento de píxeles vecinos con características comunes de acuerdo con un criterio previamente establecido. Idealmente, estos objetos corresponderían con objetos del mundo real (Schneider y Steinwendner, 1999).

Los algoritmos de segmentación se basan, por lo general, en una de las dos propiedades básicas de los valores del nivel de gris: la discontinuidad y la similitud entre los valores de intensidad de píxeles vecinos. Los algoritmos de discontinuidad dividen la imagen basándose en cambios bruscos de nivel de gris (detección de puntos aislados, detección de líneas, detección de bordes). Los algoritmos de similitud dividen a la imagen basándose en la búsqueda de zonas que tengan valores similares, conforme a unos criterios prefijados (umbralización, crecimiento de regiones, *watershed*).

Una imagen puede segmentarse en objetos de mayor o menor tamaño. Este tamaño de segmentación produce una considerable influencia en las características descriptivas derivadas de los objetos de la imagen. En función del objetivo de la clasificación, el tamaño de los objetos a delimitar y la resolución de la imagen se determinarán la o las escalas en las que se segmentará la imagen.

El hecho de segmentar una imagen varias veces con distintas escalas permite a que surja una estructura jerárquica entre los objetos de los distintos niveles, ya que un objeto puede incluir objetos de niveles inferiores y estos a su vez abarcar la superficie ocupada por polígonos de otro nivel inferior. Esta jerarquía entre los objetos es especialmente útil para caracterizar paisajes que también tienen una estructura jerárquica.

Además de los algoritmos de segmentación automática de imágenes, la información cartográfica puede emplearse para generar objetos en las imágenes. Los límites de la cartografía agrícola o catastral proporcionan límites con los que crear objetos con mayor significado geográfico que los creados mediante algoritmos de segmentación.

En esta Tesis se ha comparado el funcionamiento para la detección de edificaciones de dos métodos de segmentación automática de imágenes, basados en las propiedades de discontinuidad y de similitud: el método basado en la detección de bordes y el de crecimiento por regiones.

##### 4.2.2.1.1. Segmentación basada en la detección de bordes

La detección de bordes es un campo ampliamente conocido dentro del procesado digital de imágenes. Los límites de los objetos de una imagen y los bordes están muy relacionados, por lo que las técnicas de detección de bordes han sido empleadas como base para desarrollar metodologías de segmentación de imágenes.

Se ha empleado un algoritmo de segmentación basado en la detección de bordes que tan sólo requiere un parámetro de entrada denominado *nivel de escala* (Jin, 2009). El

proceso comienza con el cálculo de los gradientes mediante la aplicación de máscaras de convolución en las direcciones vertical y horizontal. El parámetro *nivel de escala* está directamente relacionado con los valores de gradiente de la imagen. Mediante su definición se pueden suprimir los bordes más *débiles* a diferentes niveles, con lo que el algoritmo es capaz de efectuar una segmentación multi-escala que produce polígonos con niveles de detalle. Así, la umbralización de la imagen de gradientes por un valor bajo generará múltiples objetos de pequeño tamaño. Por el contrario, la definición de un valor umbral alto generará un menor número de objetos con unas dimensiones mayores.

Por lo general, no existe una continuidad entre los bordes detectados, tendiendo éstos a aparecer desconectados entre si. Una correcta segmentación de una imagen requiere la definición de bordes conectados y cerrados. Aplicando metodologías como la definida en Pathegama and Göl (2004) se consiguen eliminar estas discontinuidades, uniéndose los bordes si la distancia entre ellos se encuentra dentro de un umbral predeterminado.

Tras la creación de los segmentos, el algoritmo ofrece un paso opcional, mediante la definición de un parámetro de *agregación*, para la unión de pequeños polígonos a polígonos mayores, con el fin de corregir posibles problemas de sobre-segmentación. El parámetro de *agregación* representa el valor de umbralización y varía entre 0 y 100. Se calcula empleando el algoritmo definido por Robinson et al. (2002) para la agregación iterativa de segmentos adyacentes basada en la combinación de la información espacial y espectral. La agregación se produce cuando el algoritmo encuentra un par de regiones adyacentes,  $i$  y  $j$ , si el coste de agregación  $t_{i,j}$ , calculado según la fórmula de la ecuación (1), es menor que el valor de umbralización definido.

$$t_{i,j} = \frac{|O_i| \cdot |O_j|}{|O_i| + |O_j|} \cdot \|u_i - u_j\|^2 \quad (1)$$

$$\text{perimetro}(\partial(O_i, O_j))$$

donde  $O_i$  es la región  $i$  de la imagen,  $|O_i|$  es el área de la región  $i$ ,  $u_i$  y  $u_j$  son los valores medios de la regiones  $i$  y  $j$ , respectivamente,  $\|u_i - u_j\|$  es la distancia euclídea entre los valores espectrales de las regiones  $i$  y  $j$ , y  $\text{perimetro}(\partial(O_i, O_j))$  es el perímetro del contorno común entre  $O_i$  y  $O_j$ .

#### 4.2.2.1.2. Segmentación basada en el crecimiento de regiones

El método de segmentación basado en el crecimiento por regiones sigue el criterio de minimización de la heterogeneidad de los píxeles. La segmentación se inicia con un píxel que forma un objeto o una región en la imagen y continúa hasta que se alcanza el criterio especificado por el usuario. La primera decisión se basa en el criterio de homogeneidad local. El algoritmo garantiza una distribución espacial regular de los objetos de la imagen. El algoritmo subyacente es esencialmente un procedimiento de optimización heurístico que minimiza la heterogeneidad media de los objetos de la imagen para una resolución dada para toda la escena. La propia heterogeneidad no sólo

está basada en la desviación típica de los objetos de la imagen sino también en su forma (Antunes et al., 2003). La relación entre heterogeneidad espectral y forma hace que se logre un ajuste en los resultados de la segmentación (Baatz y Schäpe, 2000; Leukert et al., 2003)

El criterio de parada en el proceso de la fusión de regiones se produce gracias al parámetro denominado *escala*, que es definido por el usuario. Determina el máximo permitido en la heterogeneidad global de los segmentos. Cuanto más grandes son los parámetros de la escala para una base de datos, más grandes son los objetos de la imagen, y puesto que el parámetro de la escala puede modificarse, podemos obtener diferentes tipos de imágenes segmentadas. Así, los objetos generados en una segmentación más grosera heredarán la información de los objetos más pequeños generados con unos parámetros de escala más finos (Antunes et al., 2003).

#### **4.2.2.2. Extracción de características descriptivas**

La extracción automática de características descriptivas trata de simular el reconocimiento de un territorio por parte de un fotointérprete de las características propias de los objetos analizados, como son la forma, la textura, el tono, el tamaño, su disposición espacial, etc. Por ello, es necesario dotar al sistema, en la medida de lo posible, de las herramientas de análisis y de la información de la que dispone el intérprete. El conocimiento de las distintas clases es provisto al sistema por medio de la selección de muestras de entrenamiento por parte de un intérprete conocedor del medio analizado y de las características de los objetos que allí se ubican.

Con el fin de que el sistema pueda asignar el resto de objetos a las clases definidas por el intérprete, es necesario que disponga de las características descriptivas que ha percibido el intérprete, por esto, es necesario cuantificar de forma numérica estas propiedades de forma que pueda utilizarlas para la asignación de los objetos a una clase temática. La extracción de características descriptivas se basa en la obtención de información derivada de los datos originales, de modo que las características a nivel de píxel son remplazadas por otras que representan al objeto completo. En esta sección se describen las características extraídas de los objetos resultantes de la segmentación.

##### **4.2.2.2.1. Características espectrales**

Las características espectrales proporcionan información sobre la respuesta espectral de las parcelas, que viene dada en función de los tipos de cobertura, estados fisiológicos de las plantas, materiales de construcción, etc. Para cada objeto se han calculado las siguientes características: media aritmética y la desviación típica del valor de intensidad en las bandas espectrales disponibles y del índice NDVI.

El NDVI es un índice usado para estimar la cantidad, calidad y desarrollo de la vegetación. Se calcula a partir de las medidas de la banda del infrarrojo cercano ( $IR$ ) y del rojo ( $R$ ) utilizando la expresión (2):

$$NDVI = \frac{IR - R}{IR + R} \quad (2)$$

La media aritmética de los niveles digitales de los píxeles de un objeto en una banda tiene una mayor importancia como variable descriptora cuanto más homogénea sea la respuesta espectral de la superficie que el objeto representa. La media de los niveles digitales de un objeto se calcula utilizando la expresión (3):

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3)$$

donde  $n$  es el número total de píxeles que componen el objeto y  $x_i$  es el valor de intensidad del píxel  $i$ .

En casos de objetos espectralmente heterogéneos, el valor medio corresponde a un promedio de los valores de reflectancia de elementos diversos. Por su parte, la desviación típica de los niveles digitales de los píxeles de un objeto es proporcional a su heterogeneidad espectral, y se calcula empleando la fórmula (4):

$$\sigma = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (4)$$

#### 4.2.2.2.2. Características de textura

En una imagen digital, la textura hace referencia a un conjunto de propiedades o características que describen la distribución espacial de los niveles de gris correspondientes a los píxeles de una determinada región. Su caracterización tiene especial relevancia en ciertos procesos de clasificación del territorio a partir de imágenes aéreas y de satélite. En particular en aquellas zonas espectralmente heterogéneas, en donde la asignación de una clase a cada objeto analizando únicamente su respuesta espectral no es suficiente, siendo preciso tener en consideración la distribución espacial en su interior (Ruiz et al., 2004).

Existe un amplio conjunto de técnicas de análisis de texturas que han sido utilizadas para extracción de características: métodos estadísticos, como la matriz de coocurrencias de niveles de gris (MCNG) (Haralick et al., 1973), técnicas de filtrado como los filtros de energía (Laws, 1985), o los filtros Gabor (Jain y Farrokhnia, 1991), métodos basados en la descomposición wavelets (Mallat, 1989), etc.

Las características descriptivas de textura calculadas para cada objeto son: media de la intensidad de bordes, desviación típica de la intensidad de bordes, coeficientes de

curtosis y asimetría del histograma, y las variables extraídas de la MCNG. A continuación se describe cada una de ellas.

La textura puede caracterizarse en términos de la cuantía e intensidad de bordes por unidad de área. Una transición brusca en los niveles de gris de una imagen alrededor de un píxel dado puede detectarse comparando por pares los valores de los vecindarios del píxel. Para obtener la densidad de bordes de un objeto se ha calculado la expresión propuesta por Sutton y Hall (1972), en la que para cada distancia  $d$ , en la imagen  $f$ , con un vecindario  $N$ , se calcula para cada píxel según la expresión (5):

$$g(d) = \sum_{(x,y) \in N} \{ |f(x,y) - f(x+d,y)| + |f(x,y) - f(x-d,y)| + |f(x,y) - f(x,y+d)| + |f(x,y) - f(x,y-d)| \} \quad (5)$$

A partir de la imagen de intensidad de bordes para una distancia de 1 píxel se ha caracterizado a los objetos calculado el valor medio y la desviación típica de esta textura.

Los estadísticos de primer orden skewness y curtosis son características descriptivas de la textura de la imagen relacionadas directamente con la forma del histograma. La skewness, tercer momento o coeficiente de asimetría determina si una distribución del histograma es simétrica alrededor del nivel digital de máxima frecuencia. Valores positivos indican que la distribución está desplazada hacia la derecha con una mayor cola hacia la derecha del máximo. Valores negativos indican que la distribución está desplazada hacia la izquierda, con una forma más prolongada hacia ese lado del máximo. Su cálculo se realiza empleando la fórmula descrita en la expresión (6):

$$Skewness = \frac{1}{n} \sum_{i=1}^n \left( \frac{(x_i - \bar{x})}{\sigma} \right)^3 \quad (6)$$

La curtosis o apuntamiento se define como el grado en el que una distribución estadística de frecuencias es puntiaguda y se determina por la expresión (7):

$$Curtosis = \frac{1}{n} \sum_{i=1}^n \left( \frac{(x_i - \bar{x})}{\sigma} \right)^4 - 3 \quad (7)$$

El método estadístico de características de texturas derivadas de la Matriz de Coocurrencias de Niveles de Gris han sido tradicionalmente la que resultados más óptimos ha proporcionado y ha sido ampliamente utilizado en problemas de clasificación (Chang y Kuo, 1993; Ruiz et al., 2002, 2004). Los elementos la matriz  $p(i,j)$  representan las frecuencias relativas de los niveles de gris  $i$  y  $j$ , tomando los píxeles dos a dos y separados una distancia  $d$  según una dirección dada. Cuanto mayores sean los valores de su diagonal principal más homogénea será la textura que representa la matriz, mientras que cuanto más repartidos estén los valores fuera de la diagonal más heterogénea será. Es una matriz simétrica cuyos elementos se obtienen con la expresión (8):



$$p(i, j) = \frac{P(i, j)}{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j)} \quad (8)$$

La MCNG permite caracterizar la organización espacial de los niveles de gris de un patrón de textura, si bien, no puede recoger los aspectos de forma de las primitivas de nivel de gris, por lo que no es adecuada para texturas formadas por patrones de grandes dimensiones o primitivas extensas. Una vez formada la MCNG de una imagen, la caracterización de los niveles de gris y de sus patrones se consigue mediante la extracción de 7 variables estadísticas de segundo orden, propuestas por Haralick et al. (1973), que describen las propiedades: varianza, contraste, uniformidad, entropía, momento diferencia inverso, momento producto y correlación.

La varianza mide la heterogeneidad, es decir, la variabilidad de las intensidades en la imagen y aumenta su valor cuando los niveles de gris difieren de la media:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu)^2 \cdot p(i, j) \quad (9)$$

donde  $N_g$  son los niveles de gris o niveles de intensidad en la imagen.

El contraste establece la diferencia de la frecuencia entre valores altos y bajos del nivel de gris. Está directamente relacionado con la frecuencia espacial de la imagen. Valores altos del contraste son indicativos de la existencia de muchos valores fuera de la diagonal principal de la matriz:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - j)^2 \cdot p(i, j) \quad (10)$$

La uniformidad mide la homogeneidad de la textura de la imagen. Los valores más altos corresponden a distribuciones espaciales de los niveles de gris casi constantes:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j)^2 \quad (11)$$

La entropía mide la aleatoriedad, complejidad o desorden en la distribución de la intensidad en una imagen:

$$- \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \cdot \log[p(i, j)] \quad (12)$$

El momento de diferencia inverso está inversamente relacionado con el contraste. Valores altos indican que la frecuencia de ocurrencia en la imagen de niveles de intensidad similares es elevada, discriminando zonas de variación de niveles de gris entre píxeles:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (13)$$

El momento producto o covarianza es una medida de homogeneidad local. Valores positivos altos indican una mayor probabilidad de que se den juntos en la imagen valores de intensidad similar. Por el contrario, valores negativos son propios de imágenes donde los píxeles vecinos difieren mucho en su nivel de gris:

$$- \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu) \cdot (j - \mu) \cdot p(i, j) \quad (14)$$

La correlación equivale al momento producto normalizado con respecto a la varianza:

$$\frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu)(j - \mu) \cdot p(i, j)}{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu)^2 \cdot p(i, j)} \quad (15)$$

Desde el punto de vista práctico, uno de los problemas que presenta la clasificación de imágenes mediante información o variables de textura es la presencia de errores significativos en las zonas frontera entre clases, debido precisamente a que el valor de cada píxel depende de la distribución de valores de su vecindario, tal y como se recoge en otros trabajos (Ruiz et al., 2002; Ferro y Warner, 2002). La utilización del enfoque por objeto elimina el error que se produce al obtener la MCNG para cada píxel en un vecindario ya que, en su cálculo, sólo se consideran aquellos píxeles pertenecientes al objeto. Con lo que se evita la inclusión de píxeles exteriores al mismo.

En lugar de calcular una MCNG para cada uno de los píxeles pertenecientes a un objeto y posteriormente obtener la media aritmética de las 7 variables explicadas y así obtener las 7 características correspondientes al polígono, se ha calculado una única MCNG para cada polígono (Balaguer et al., 2010) considerando la frecuencia relativa entre cada par de píxeles separados una distancia de 1 píxel y en las cuatro direcciones siguientes: 0°, 45°, 90° y 135°. Los resultados obtenidos confirman que la descripción de la textura existente en un objeto se consigue con la misma calidad que mediante el promediado de los valores independientes de todos los píxeles, pero con un significativo ahorro en el tiempo de procesado.

#### 4.2.2.2.3. Características de forma

Las características descriptivas de forma proporcionan información sobre la las dimensiones de un objeto y la complejidad de su contorno. Estos descriptores se basan generalmente en ratios entre el área y el perímetro de un objeto. Para caracterizar la

forma de los objetos se han empleado, además del área y del perímetro, tres índices descriptivos: índice de compacidad, índice de forma e índice de dimensión fractal.

La compacidad de un objeto se suele medir con el ratio superficie/perímetro que es adimensional (Bogaert et al., 2000):

$$\gamma_1 = \frac{\text{Área}}{\text{Perímetro}^2} \quad (16)$$

Dado que el círculo es el objeto más compacto, se puede modificar el índice anterior de modo que el resultado sea la unidad para formas circulares, resultando la expresión (17):

$$\text{Compacidad} = \frac{2\sqrt{\pi \cdot \text{Área}}}{\text{Perímetro}} \quad (17)$$

Este índice varía entre 0 y 1, siendo 0 el valor correspondiente a un objeto lineal y 1 el de un objeto circular.

El índice de forma describe la similitud de la forma un objeto con un cuadrado y se obtiene de acuerdo al cociente adimensional expresado en (18):

$$\text{Índice de forma} = \frac{\text{Perímetro}}{4\sqrt{\text{Área}}} \quad (18)$$

El valor del índice de forma varía entre 1 e infinito, donde 1 es el valor correspondiente a un objeto ideal cuadrado. Cuanto más fractal sea la forma del objeto, mayor será el valor del índice de forma.

La dimensión fractal expresa la complejidad de los polígonos a partir de un cociente entre perímetro y superficie (Krummel et al., 1987) de acuerdo con la expresión (19):

$$\text{Dimensión fractal} = 2 \frac{\log\left(\frac{\text{Perímetro}}{4}\right)}{\log(\text{Área})} \quad (19)$$

#### 4.2.2.2.4. Características de altura

Las características de altura son útiles para distinguir entre coberturas con similar respuesta espectral, pero distinta altura, tales como vegetación arbolada y arbustiva, o edificaciones y suelo asfaltado. Empleando la imagen del nDSM, calculada a partir de los datos LiDAR, se caracteriza cada objeto a partir de los valores contenidos en esta imagen. Así, se calculan características descriptivas que permitan reflejar la distribución espacial de las alturas: media, desviación típica, rango, *skewness* y *curtosis*.

La media aritmética refleja la tendencia mostrada por las alturas, y constituye un valor representativo del conjunto de las mismas. El valor de la desviación típica expresa la

dispersión de las respecto de su media aritmética, reflejando la variabilidad en la altura de los elementos internos al objeto analizado. Por su parte, el rango define el intervalo de alturas de los elementos contenidos en el objeto y proporciona una idea de la dispersión de los datos. Se obtiene calculando la diferencia entre el valor máximo y el mínimo en cada polígono.

Se calculan del nDSM los estadísticos de primer orden skewness y curtosis, que respectivamente caracterizan la simetría en la forma del histograma de distribución de las alturas, y el grado en que este tiene una forma puntiaguda. Estos descriptores estadísticos se calculan aplicando las fórmulas descritas en la ecuación (6) y en la ecuación (7).

#### **4.2.2.3. Selección y análisis de las características descriptivas**

Debido al alto número de características descriptivas extraídas es muy probable que no todas las variables originales sean útiles para discriminar entre las clases. Es necesario analizar la influencia de las distintas características generadas sobre la fiabilidad global de la clasificación, de forma que únicamente se incluyan aquellas que más contribuyen a separar los grupos, con respecto a un cierto criterio, y desestimándose las variables cuya contribución sea escasa, bien porque no son relevantes o porque la información que aportan ya esté recogida por alguna (o varias) de las variables ya incluidas en el modelo, resultando redundantes.

La selección de las características más significativas se ha realizado utilizando la técnica de análisis discriminante lineal paso a paso. El análisis discriminante es una técnica estadística multivariante, que puede ser considerada como un análisis de regresión donde la variable dependiente es categórica, mientras que las variables independientes son continuas y determinan a qué grupos pertenecen los objetos (Huberty, 1994; Everitt y Dunn, 2001). El objetivo es encontrar relaciones lineales entre las variables continuas que mejor discriminen en los grupos dados a los objetos. Empleando la técnica de análisis discriminante descriptivo se analizan las variables explicativas con la finalidad de determinar cuáles de esas variables son las que más permiten diferenciar a los grupos, cuales son importantes y cuales no a efectos de clasificación.

El criterio para decidir qué variables entran o no en la definición de la función discriminante es el de minimizar el valor del estadístico *Lambda* de Wilks. Este estadístico se define como un cociente entre la varianza *dentro de grupos* y la varianza *total*, y se basa en la descomposición de la variabilidad total de una variable como una suma de dos términos:

$$\text{Varianza Total} = \text{Varianza "dentro de grupos"} + \text{Varianza "entre grupos"} \quad (20)$$

De esta forma, el valor del cociente definido por el estadístico *Lambda* de Wilks representa la proporción de la variabilidad total de las puntuaciones discriminantes

debida a la diferencia *dentro de grupos* o, dicho de otra forma, la proporción de la variabilidad no explicada por las diferencias *entre grupos*.

Teniendo en cuenta esta interpretación, el criterio para seleccionar una variable es el de minimizar este estadístico, esto es, conseguir que la variabilidad no explicada por las diferencias *entre grupos* sea mínima, o lo que es lo mismo, que las diferencias observadas entre los valores de las funciones discriminantes se deben fundamentalmente a diferencias existentes entre los grupos y no a diferencias internas. Esto implica que los grupos son muy diferentes entre sí, consiguiéndose, simultáneamente, que los grupos sean internamente muy homogéneos.

Tras establecerse el criterio de aceptación en el modelo, se realiza la selección paso a paso. En primer lugar se selecciona la variable que proporciona la máxima discriminación entre los grupos con el criterio elegido. Esta selección se hace contrastando, para cada variable, la hipótesis de igualdad de medias en todos los grupos, para lo cual se utiliza un test de la  $F$  que, en este caso, es una función del estadístico  $\Lambda$  de Wilks de la forma descrita en la expresión (21):

$$F = \frac{(n-g)}{g-1} \cdot \left( \frac{1-\Lambda}{\Lambda} \right) \quad (21)$$

donde  $n$  es el número de individuos y  $g$  es el número de grupos. La primera variable seleccionada es la que minimiza el  $\Lambda$  de Wilks, o equivalentemente, la que proporcione un valor del estadístico  $F$  mayor y significativo.

En el segundo paso, la variable seleccionada se empareja con cada una de las variables restantes, escogiéndose aquella pareja que produce la mayor discriminación (el mayor valor estadísticamente significativo del correspondiente estadístico  $F$ ). En este caso, en que una variable se añade a un modelo que ya contiene otra(s) variable(s), el valor de  $F$  responde a la expresión (22):

$$F = \frac{(n-g-s)}{g-1} \cdot \left( \frac{1 - \frac{\Lambda_{s+1}}{\Lambda_s}}{\frac{\Lambda_{s+1}}{\Lambda_s}} \right) \quad (22)$$

donde  $s$  es el número de variables previamente incluidas y  $\Lambda_s$  y  $\Lambda_{s+1}$  son los valores de la *Lambda* de Wilks antes y después de añadir la nueva variable, respectivamente. El estadístico  $F$  representa el incremento producido en la discriminación tras la incorporación de la nueva variable con respecto al total alcanzado con la(s) variable(s) ya incluida(s) previamente. Por tanto, la variable elegida será la que tenga un mayor valor de  $F$ , es decir, la que más incrementa la capacidad discriminante.

La tercera y posteriores variables se seleccionan de forma similar. El proceso de inclusión de variables termina cuando ninguna de las que están fuera del modelo cumple el criterio de entrada.

#### 4.2.2.4. Clasificación mediante árboles de decisión

Los objetos han sido clasificados en una de las clases definidas mediante el empleo de árboles de decisión creados utilizando muestras de entrenamiento. Un árbol de decisión es un conjunto organizado de condiciones con una estructura jerárquica en forma de árbol, de modo que la clase que se asigna a un objeto se determina siguiendo las ramas (condiciones satisfechas) desde el tronco (el conjunto de datos inicial), hasta cualquiera de sus hojas (la clase asignada a un objeto). El algoritmo específico empleado es el C5.0, que constituye la versión moderna de los algoritmos ID3 y C4.5 desarrollados por Quinlan (1993). Este algoritmo es el más comúnmente empleado para generar árboles de decisión en problemas de clasificación de imágenes (Zhang and Liu, 2004). El algoritmo C5.0 tiene la capacidad para tratar con diferentes tipos de datos, continuos o discretos, lo que incrementa sustancialmente la posibilidad de incluir características descriptivas de diversas fuentes de información para realizar la clasificación.

El proceso de construcción de un árbol de decisión comienza dividiendo la colección de muestras de entrenamiento mediante condiciones excluyentes entre sí. Cada uno de los subgrupos de muestras se divide iterativamente hasta producir subgrupos homogéneos. Estos algoritmos se fundamentan en la búsqueda de particiones con las que obtener subgrupos más puros, en los que se produce una menor mezcla entre las clases que los grupos de muestras previos de los que han sido derivados. Se realiza un proceso iterativo hasta que se divide el grupo de muestras original en subgrupos homogéneos utilizando índice de ganancia como criterio de división hasta que todos los elementos de un subgrupo pertenecen a una misma clase o se haya satisfecho una condición de parada establecida por el usuario (Quinlan, 1993).

Las clasificaciones se han realizado utilizando diez árboles de decisión en cada caso, mediante el empleo del método de multi-clasificación *boosting*, que permite aumentar la precisión del clasificador (Freund, 1995). Este método se basa en la asignación de pesos a las muestras de entrenamiento. Cuanto mayor sea el peso de una muestra, mayor será su influencia en la clasificación (Freund and Shapire, 1997). Tras cada iteración, esto es, tras la construcción de un árbol de decisión, el vector de pesos se ajusta para reflejar el rendimiento del modelo, de modo que las muestras erróneamente clasificadas ven incrementados sus pesos, mientras que se reducen los pesos de los ejemplos clasificados correctamente. Así se consigue que el modelo que se obtendrá en la iteración siguiente dé más relevancia a las muestras erróneamente clasificadas previamente, tratando de corregir los fallos de los modelos anteriores (Hernández-Orallo et al., 2004). Tras la construcción del conjunto de árboles de decisión, a cada objeto se le asigna una clase considerando los errores estimados en la construcción de cada uno de los árboles.

#### 4.2.2.5. Evaluación de la clasificación

La clasificación se evalúa mediante la matriz de errores o de confusión (Aronoff, 1982; Story y Congalton, 1986) en la que se recogen las discordancias entre los datos clasificados y los de referencia, éstos últimos obtenidos mediante técnicas de fotointerpretación. En la matriz de confusión, las filas representan las clases asignadas en el proceso de clasificación y las columnas las clases reales.

De la matriz pueden deducirse varios índices. En primer lugar, la fiabilidad global, que se obtiene dividiendo el total de objetos correctamente clasificados (suma de la diagonal principal) entre el número total de elementos en la muestra de evaluación. Además, pueden estudiarse las precisiones individuales de cada clase mediante dos índices complementarios. El primero de ellos se conoce como fiabilidad del productor y se obtiene dividiendo el número de objetos de una clase correctamente clasificados entre el número total de objetos de esa clase obtenido a partir de los datos de referencia. Este valor expresa la proporción de objetos pertenecientes a una clase que han sido correctamente clasificados, dando una idea de los errores por defecto. Por otra parte, dividiendo el número de objetos de una clase correctamente clasificados entre el total de objetos que fueron clasificados en esa clase se obtiene información sobre los errores por exceso. Este índice se conoce como fiabilidad del usuario.

Debido a que la tarea de selección de muestras, bien de entrenamiento o de evaluación, es costosa, estas pueden ser aprovechadas al máximo utilizando la metodología de validación cruzada *leave-one-out*. Este método consiste en utilizar una muestra del conjunto de datos original como muestra de evaluación y el resto de observaciones como muestra de entrenamiento. Esta acción se repite hasta que cada una de las observaciones del conjunto de datos es utilizada como muestra de evaluación, permitiendo obtenerse el rendimiento global y la matriz de confusión.

#### 4.2.2.6. Definición de edificaciones

Una vez realizada la clasificación de los objetos, y como paso final en la metodología se agrupan todos los objetos contiguos clasificados como alguna de las clases de edificaciones definidas. De esta forma, los objetos contiguos clasificados como edificaciones disolverán los límites existentes entre ellos, quedando agrupados en objetos de mayor tamaño.

Por último, y mediante un proceso de filtrado en función del área de los objetos resultantes del agrupamiento, se eliminan los objetos con área menor a un umbral definido. De esta forma se pretende eliminar el ruido que provocan objetos de dimensiones muy reducidas.

### 4.2.3. Detección de las sombras y su inclusión en el proceso de detección de edificaciones

Al afrontar el proceso de detección de sombras, muchos autores presuponen la bimodalidad de aquellas imágenes en las que estas existen, por lo que tratan de localizar automáticamente el valle en el histograma con el que se puedan separar las zonas en sombra de las iluminadas. Pese a ello, es importante tener en cuenta que la cantidad de sombras presentes en una imagen de alta resolución dependerá del azimut y del ángulo de elevación solar, del ángulo de adquisición del sensor (Shackelford et al., 2004), el tamaño de la escena analizada y el número de elementos que pueden generarlas. Por ello, pese a que existan sombras en una imagen, la bimodalidad puede no estar reflejada en el histograma, lo que hace imposible su detección mediante el análisis de éste.

La metodología de detección de sombras utilizada está basada en la presentada en Hermosilla et al. (2008). Se trata de un método semiautomático que requiere del análisis de componentes principales de las bandas originales de la imagen. Trabajando sobre el primer componente principal, se busca el valor de intensidad que mejor permite aislar las sombras mediante la aplicación de una umbralización. Para esto, se requiere de la interacción del usuario, quien debe seleccionar muestras de píxeles que se encuentren en zonas cubiertas por sombras por un lado, y de píxeles libres de estas por otro.

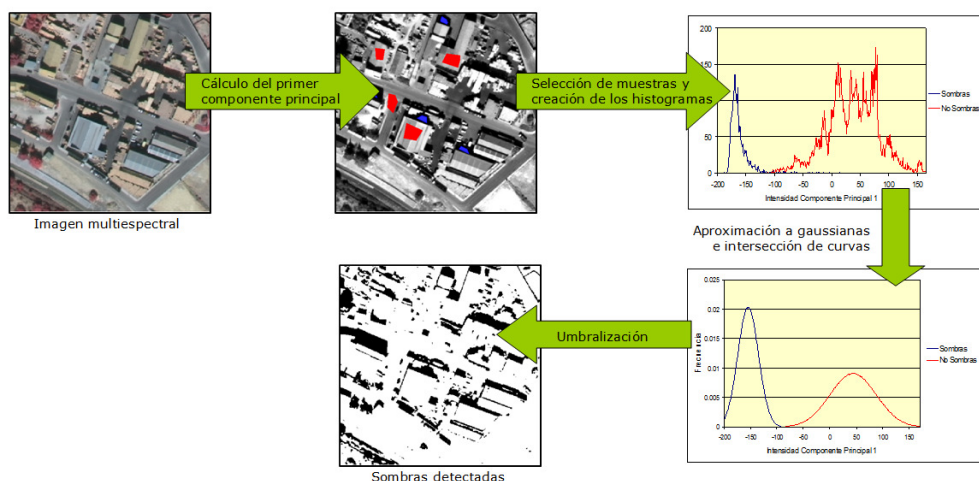


Figura 12. Esquema gráfico del proceso de detección de sombras.

A diferencia del método expuesto en Hermosilla et al. (2008), se ha modificado la definición del valor de umbralización. Esta consistía en la intersección directa de los histogramas dibujados con las muestras. Ahora, los histogramas son aproximados a figuras gaussianas utilizando los valores de media y desviación estándar de los grupos de muestras. En el punto donde se produce la intersección de ambas curvas es el valor de intensidad con el que se aislarán las sombras. La definición de este umbral es una tarea



que puede automatizarse con facilidad, requiriendo únicamente por parte del usuario la selección de muestras de zonas con y sin sombras. Se realiza un filtrado a la imagen resultante para eliminar las sombras de menor tamaño. Por último, se aplica un filtro de cierre morfológico con el fin de suavizar y simplificar las formas de los objetos detectados. En la Figura 12 se muestra un esquema gráfico del proceso de detección de sombras.

Las sombras han sido incluidas en el proceso de detección de edificaciones empleando la condición de adyacencia según la dirección del ángulo de incidencia solar para esa imagen. Así, toda edificación requerirá necesariamente la contigüidad a una sombra en la dirección de incidencia solar, implicando que todo aquel objeto detectado como edificación que carezca de sombra en esta dirección será descartado. Se trata de una condición restrictiva para la definición de las edificaciones que se aplica al final del proceso de detección, con lo que los resultados se verán modificados en función de las sombras. La Figura 13 y la Figura 14 muestran el aspecto final de los esquemas de los algoritmos de detección de edificaciones al añadirse la relación de adyacencia con las sombras.

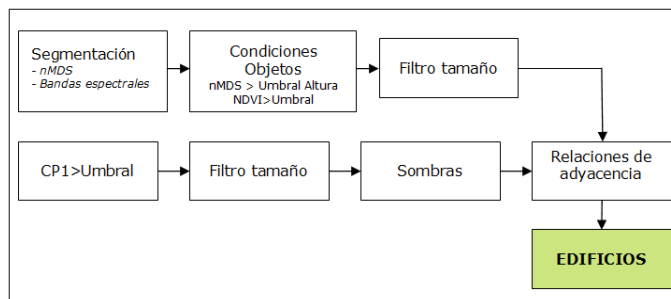


Figura 13. Esquema del algoritmo de detección de edificaciones basado en establecimiento de umbrales y en la relación de adyacencia con las sombras.

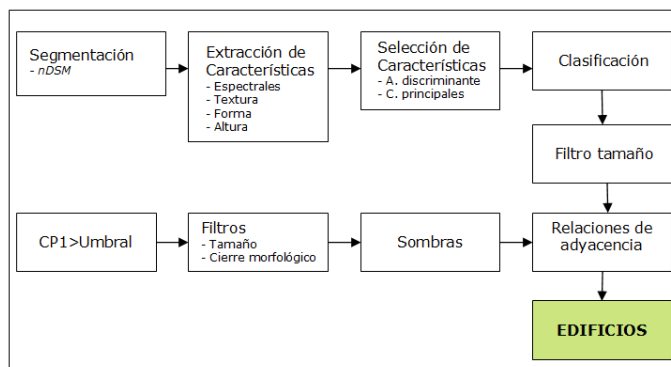


Figura 14. Esquema del algoritmo de detección de edificaciones basado en clasificación orientada a objetos y en la relación de adyacencia con las sombras.

### 4.2.4. Evaluación de la detección de edificaciones


La evaluación del rendimiento de una metodología de detección desde un punto estadístico es necesaria y fundamental para el conocimiento preciso de su funcionamiento y capacidades. Se ha efectuado la evaluación de la detección y localización de edificaciones atendiendo a dos niveles diferentes: a nivel de área o píxel, y a nivel de objeto. La definición gráfica de las edificaciones utilizadas como referencia para la evaluación estadística se ha efectuado mediante fotointerpretación de las imágenes, delineados manualmente.

Debido a que en los ámbitos urbanos coexisten edificaciones de diferente naturaleza y con características propias, se ha diferenciado en este proceso entre zonas que contienen edificaciones pertenecientes a tipologías constructivas diferentes (urbanas, periurbanas y zonas industriales), con el fin de estudiar sus respuestas específicas a la metodología de detección de edificaciones analizada (ver Figura 15).

	Tipología		
	Urbano	Periurbano	Industrial
Moncada			
Oliva			
Sagunto			

Figura 15. Ejemplos de las tipologías de edificación diferenciadas en las tres zonas de estudio. Nótese que Oliva no cuenta con áreas de tipo industrial.

Se han excluido de la evaluación aquellas zonas en las que se producen errores en la generación del DTM que afectan al nDSM, así como las áreas que presentaban discordancias entre los datos LiDAR y las imágenes debido a las diferentes fechas de adquisición de la información (Figura 16). Este último caso ha sido más frecuente en las zonas de estudio de Sagunto y Oliva, debido a la mayor diferencia temporal entre la adquisición de las imágenes y los datos LiDAR.



Legenda: 25  50 m

Figura 16. Ejemplos de zonas excluidas de la evaluación debido a errores en el cálculo del DTM (izquierda) o por diferencias temporales entre los datos LiDAR y las imágenes (derecha).

La detección automática de edificaciones se compara con los métodos tradicionales empleados para la confección de bases de datos de ocupación del territorio, basados en técnicas de percepción visual. La metodología empleada para la evaluación de ambas técnicas se presenta en el último apartado de esta Sección.

#### 4.2.4.1. Evaluación a nivel de área

La evaluación analítica a nivel de área valora la exactitud con la que las edificaciones son delineadas. Esta se ha realizado utilizando una colección de parámetros estadísticos definidos por McGlone y Shufelt (1994) y que han sido ampliamente empleados por otros muchos autores (Lin y Netavia, 1998; Kim y Muller, 1999; Shan y Lee, 2002; Lee et al., 2003; Jin y Davis, 2005; Müller y Zaum, 2005; Shyu et al., 2005; Lari y Ebadi, 2007; Koc San y Tucker, 2007). Las edificaciones detectadas y las de referencia son comparadas geográficamente, de forma que las áreas quedan categorizadas en cuatro tipologías distintas (Figura 17):

- Positivo Verdadero (*True Positive*, TP): Áreas que contienen edificaciones automáticamente detectadas y de referencia.
- Negativo Verdadero (*True Negative*, TN): Áreas que no contienen edificaciones detectadas ni de referencia.

- Falso Positivo (*False Positive*, FP): Áreas detectadas como edificaciones pero que no lo son.
- Falso Negativo (*False Negative*, FN): Áreas edificadas que no son detectadas como tales.



Leyenda: ■ Edificio real ■ Edificio detectado ■ Categoría

Figura 17. Ejemplo de las categorías definidas para la comparación a nivel de área.

Utilizando los valores definidos se calculan los parámetros estadísticos de evaluación a nivel de área. El factor de exceso (*Branching factor*) constituye una medida del error por exceso, en el que el sistema detecta incorrectamente como edificaciones elementos que no lo son. Este factor viene definido por la expresión (23):

$$FE = \frac{FP}{TP} \tag{23}$$

El factor de defecto (*Miss factor*) es un ratio que indica el error de omisión cometido, esto es, zonas edificadas que no son detectados automáticamente como tales, aplicando la expresión (24):

$$FD = \frac{FN}{TP} \tag{24}$$

El porcentaje de detección denota el porcentaje de superficie de edificaciones reales correctamente detectado por el proceso automático y es prácticamente complementario al factor de defecto, y se calcula empleando la fórmula descrita en la expresión (25):

$$PD = 100 \cdot \frac{TP}{TP + FN} \tag{25}$$

El porcentaje de calidad informa sobre la calidad absoluta de la detección y localización de edificaciones. Se trata de la medida más estricta (Jin y Davis, 2005), puesto que para la obtención de un 100% de calidad, el algoritmo debería detectar correctamente toda superficie edificada (FN = 0), sin incluir ningún elemento que no lo sea (FP = 0). Para su cálculo se emplea la expresión (26):

$$PC = 100 \cdot \frac{TP}{TP + FP + FN} \tag{26}$$

#### 4.2.4.2. Evaluación a nivel de objeto

La evaluación a nivel de objeto estima la correspondencia espacial entre el edificio detectado y el real. Así, metodologías de detección de edificaciones con bajas fiabilidades a nivel de área o píxel pero altas a nivel de objeto no serían apropiadas para la delineación automática de las edificaciones, pero sí para la localización espacial de estos y una posterior delineación por parte de un fotointérprete. Este método ha sido empleado para evaluar la detección de edificaciones en trabajos tales como Olsen et al., 2002; Hofmann et al, 2002; Liu y Prinnet, 2005; Matikainen et al, 2007, Hermosilla et al., 2008; o Hermosilla y Ruiz, 2009).

Se emplean en esta evaluación dos índices: de corrección y completión, que hacen referencia al exceso y defecto en la detección de las edificaciones respectivamente. El índice de corrección (*correctness*) es un factor del exceso de detección e indica el porcentaje de edificaciones detectadas que se solapan, al menos en parte, con la posición de un edificio real presente en la imagen, de acuerdo con la expresión (27):

$$Cr = \frac{E'_{Det}}{E_{Det}} \quad (27)$$

donde  $E'_{Det}$  son las edificaciones detectadas que se solapan con las reales y  $E_{Det}$  es el número total de edificaciones detectadas.

El índice de completión (*completeness*) hace referencia al factor de defecto de la detección y explica el porcentaje de edificaciones reales que son solapadas por edificaciones automáticamente detectadas, mediante la aplicación de la fórmula (28).

$$Cm = \frac{E'_{Ref}}{E_{Ref}} \quad (28)$$

donde  $E'_{Ref}$  son las edificaciones de referencia que se solapan con las detectadas automáticamente y  $E_{Ref}$  es el número total de edificaciones de referencia.

#### 4.2.4.3. Comparación de metodologías automáticas y basadas en interpretación visual para la estimación de la superficie edificada.

Para realizar esta evaluación se emplean los límites de los polígonos SIOSE y la información relativa al porcentaje de superficie edificada de estos contenidos en la base de datos del SIOSE. El porcentaje de superficie edificada detectada mediante métodos automáticos se ha obtenido calculando el ratio de la superficie edificada y la superficie del polígono SIOSE. La información de referencia se ha obtenido delineando manualmente las edificaciones presentes en los polígonos SIOSE. Se han eliminado del estudio aquellos polígonos en los que se han dado fuertes cambios entre la fecha de

adquisición de las imágenes y la fecha a la que está referenciada la información del SIOSE.

La precisión es el promedio del grado de correspondencia entre pares individuales de valores pronosticados y valores observados. Por valores observados se entiende la superficie obtenida mediante delineación manual de las edificaciones. Se ha analizado la relación lineal entre los porcentajes de superficie pronosticados por ambos métodos (detección automática y SIOSE) frente a los valores de referencia empleando el coeficiente de correlación  $R^2$ , calculado como el cuadrado del coeficiente de correlación del momento producto de Pearson, descrito por la fórmula de la expresión (29):

$$R = \frac{\sum_{i=1}^N (\phi_i - \bar{\phi}_i) \cdot (\phi_{iobs} - \bar{\phi}_{iobs})}{\sqrt{\sum_{i=1}^N (\phi_i - \bar{\phi}_i)^2 \cdot \sum_{i=1}^N (\phi_{iobs} - \bar{\phi}_{iobs})^2}} \quad (29)$$

donde  $\phi$  es el valor pronosticado para el polígono SIOSE  $i$ ,  $\phi_{iobs}$  es el valor observado para ese polígono, y  $N$  es el número de polígonos analizados.

Se ha empleado también el error medio cuadrático para el cálculo de la precisión. Este indicador ofrece la media de las diferencias en promedio entre los valores pronosticados y observados, y viene definido según se describe en la expresión (30):

$$EMC = \sqrt{\frac{\sum_{i=1}^N (\phi_i - \phi_{iobs})^2}{N}} \quad (30)$$

Para analizar la tendencia de un modelo a sobreestimar o subestimar una variable se ha empleado el sesgo, que cuantifica el error sistemático del modelo. Pielke (1984) define el sesgo por la expresión (31):

$$Sesgo = \sum_{i=1}^N \frac{(\phi_i - \phi_{iobs})}{N} \quad (31)$$

Un sesgo de signo positivo implica que el modelo analizado tiende a estimar por exceso el área edificada.

La precisión de la determinación de la superficie edificada se ha analizado por zonas de estudio, por un lado, y en función de las tipologías de edificación urbana, periurbana e industrial, por otro. Para ello, se han seleccionado polígonos SIOSE en los que claramente predominan estas tipologías.

## 4.3. Clasificación de usos del suelo en entornos urbanos

### 4.3.1. Introducción

La clasificación automática emula en la medida de lo posible las tareas realizadas por un fotointérprete para la determinación de los usos del suelo. Éstas consisten en el reconocimiento y análisis de características propias de los elementos representados en las imágenes a través de la información derivada de la imagen y otra información auxiliar de las que se dispone.

La clasificación de los usos del suelo en entornos urbanos se ha llevado a cabo siguiendo la metodología tradicional de clasificación orientada a objetos, que consta de los siguientes pasos: segmentación, definición de clases, extracción y selección de características descriptivas, clasificación y evaluación de la clasificación.

La segmentación de la imagen se realizó empleando límites cartográficos. Los objetos-imagen fueron creados a partir de los contornos contenidos en la cartografía catastral de rústica y de urbana. Las clases definidas se basaron en la leyenda descrita en el SIOSE. Las muestras de entrenamiento fueron seleccionadas mediante fotointerpretación.

Cada objeto-imagen fue analizado independientemente, extrayéndose características descriptivas que proporcionan al sistema el conocimiento necesario para la correcta interpretación de los usos del suelo. Para cada objeto se calcularon características relativas a la información proporcionada por la imagen (características espectrales y de textura), por los datos LiDAR (características de altura) y por la propia geometría del objeto-imagen (características de forma).

Además de las características propias del objeto-imagen, se calcularon características que proporcionan información sobre su contexto. Se distinguieron dos niveles de contexto: interno y externo. Las características del contexto interno del objeto describen las diferentes coberturas internas del objeto, centrándose principalmente en la vegetación y las edificaciones. Las edificaciones fueron detectadas empleando técnicas automáticas de detección de edificaciones descritas en la Sección 4.2.1. Las características del contexto externo del objeto describen en un nivel de agregación superior al del objeto –que en entornos urbanos corresponde con la manzana urbana– las relaciones espaciales, las propiedades de las diferentes cubiertas (especialmente las edificaciones) y su geometría.

A continuación se realizó un proceso de selección y análisis de las características más discriminantes para evitar redundancias y para reducir el volumen de información no significativa. Para ello se emplearon las muestras de aprendizaje junto con sus características descriptivas. Como resultado se obtuvieron las características con mayor

poder separador de las clases definidas en la leyenda según las muestras proporcionadas, que fueron empleadas en la clasificación del resto de objetos.

La clasificación se realizó empleando el método de los árboles de decisión, aplicando la técnica de multclasificación *boosting*. El entrenamiento del clasificador se realizó con las muestras de aprendizaje y las características seleccionadas. Tras la aplicación de la clasificación, a cada objeto le fue asignada una clase, junto con un estimador de confianza con la que se efectuó la asignación de la clase.

La evaluación estadística de la clasificación se realizó mediante matrices de confusión, empleando validación cruzada *leave-one-out*, de forma que se aumenta la eficiencia en la adquisición de muestras, evitándose la adquisición de muestras independientes de evaluación.

### **4.3.2. Definición de objetos y clases**

La unidad elemental empleada en este trabajo se ha definido combinando las subparcelas catastrales rústicas y las parcelas catastrales urbanas. Las subparcelas rústicas son las divisiones internas a las parcelas catastrales, consecuencia de los diferentes cultivos y aprovechamientos del terreno. La parcela catastral urbana es la unidad básica y diferenciada de suelo, con o sin construcción, tal y como se define en el Artículo 62, apartado a) de la *Ley Reguladora de las Haciendas Locales, 39/1988 de 28 de diciembre*.

La definición de las clases se ha realizado empleando técnicas de fotointerpretación tomando como referencia las tipologías de edificación definidas en el la leyenda del SIOSE (Instituto Geográfico Nacional, 2007) diferenciadas según su uso y morfología: *edificio aislado, edificio entre medianeras, vivienda unifamiliar adosada, vivienda unifamiliar aislada y nave*. Con el objeto de realizar una descripción más exhaustiva, la tipología *edificio entre medianeras* se ha subdividido en *casco histórico* y *ensanche*, correspondiendo con dos subdivisiones de la clase *Urbano Mixto* del SIOSE (véase la Figura 18 para ejemplos gráficos de las clases).

De acuerdo con las directrices del SIOSE (Instituto Geográfico Nacional; 2007) la clase *edificio aislado* hace referencia a aquellas edificaciones destinadas a alojar personas, diseñadas para estar separadas unas de las otras. Su uso podrá ser residencial o comercial. La clase *vivienda unifamiliar adosada* se refiere a las edificaciones destinadas a alojar personas para su uso como vivienda de una sola familia, limitadas por medianeras que la separan de las viviendas adyacentes. La clase *vivienda unifamiliar aislada* representa las edificaciones aisladas destinadas a alojar personas para su uso como vivienda de una sola familia.

Las *naves* son edificaciones aisladas o adosadas, destinadas a alojar animales, vehículos, maquinaria, materiales, etc., para uso industrial o comercial. Normalmente tendrán



techos altos y grandes puertas para permitir el acceso a su interior de elementos de gran tamaño.

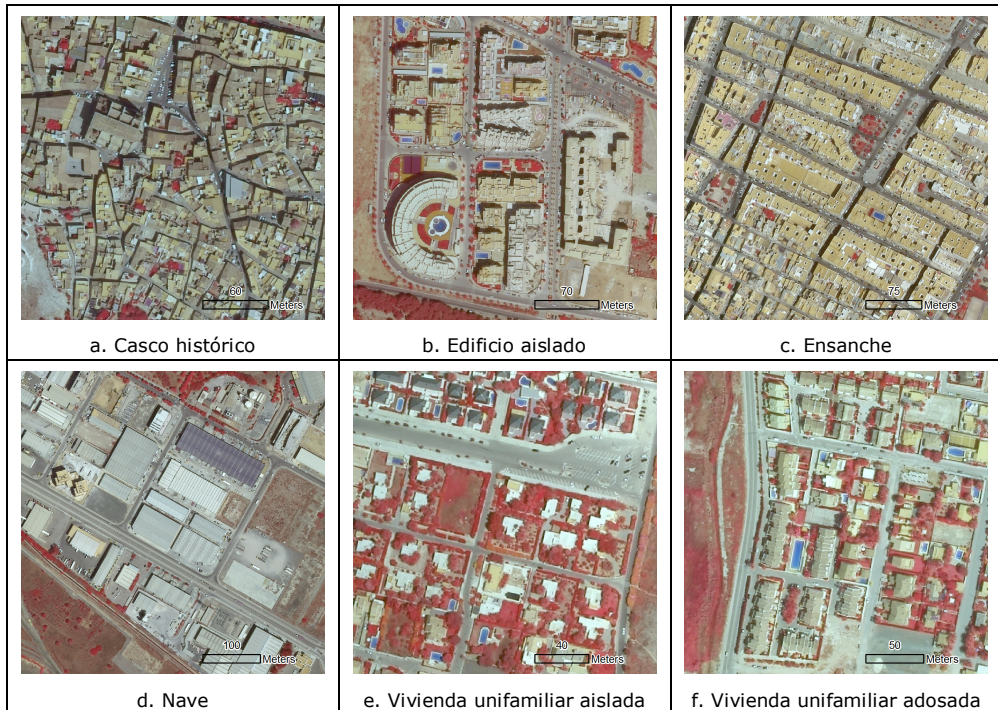


Figura 18. Ejemplos de las clases urbanas definidas.

Los *edificios entre medianeras* representan aquellas edificaciones diseñadas para estar unas al lado de otras separadas por medianeras (pared lateral de contacto entre dos edificaciones que se levanta desde los cimientos hasta la cubierta). Su uso podrá ser residencial o comercial. Las dos subclases de *Edificios entre medianeras* diferenciadas son *casco histórico* y *ensanche*. La clase *casco histórico* se caracteriza por tener una trama irregular en ocasiones con parcelación *gótica* (parcelas muy estrechas y con mucho fondo), viales muy estrechos y pocas zonas verdes. Generalmente responde a la topografía del terreno, con crecimientos sobre las vías preexistentes y limitados por los sucesivos perímetros defensivos. La tipología de las edificaciones que lo forman suele ser de edificios entre medianeras formando normalmente manzanas compactas. Por su parte, al hablar de *ensanche* se define una zona urbana que puede estar o no ya consolidada, producida basándose en un planeamiento urbano definido, que, generalmente, se desarrolla ordenando áreas en torno al casco existente. Se caracteriza por tener trama más regular, viales más anchos y mayor superficie de zonas verdes que el *casco*.

Además, se han definido las clases necesarias para realizar una completa clasificación de las zonas de estudio: *terrenos agrícolas y cultivados* y *cultivos arbóreos* (Citrícolas, Almendros).

### 4.3.3. Extracción de características descriptivas

Las técnicas de interpretación visual utilizadas por los fotointérpretes se basan en el reconocimiento de los elementos presentes en la imagen y en la identificación de sus características particulares. Estas están relacionadas con su forma, color o textura, pero además con el contexto espacial de sus atributos topológicos relativos a sus componentes internos (patrones, distribución de coberturas), y externos, con respecto al resto de elementos de su entorno. Las características descriptivas propuestas en esta sección tratan de emular la cognición humana y cuantificar numéricamente las propiedades particulares que permitan la discriminación y clasificación de los diferentes elementos de la imagen.

La caracterización de los entornos urbanos requiere de la contextualización de sus elementos, y no sólo de características derivadas exclusivamente de los límites de la parcela (objeto). Esto supone un paso adicional en la clasificación orientada a objetos, de forma que las descripciones de los elementos se aproximen a los procesos de percepción y razonamiento humano.

La contextualización se ha efectuado mediante la descripción de las características de cada objeto atendiendo a varios de sus niveles de agregación. Así, se han definido tres niveles distintos de características referidas a: el objeto, las coberturas internas del objeto y al contexto externo del objeto.

- Las características relativas al objeto describen diferentes aspectos en función de la información considerada: multiespectral, tridimensional, geometría, etc., considerando al objeto como una entidad única.
- Las características de contexto interno del objeto lo definen a partir de las diferentes coberturas contenidas en él. Las coberturas consideradas distinguen elementos característicos propios de zonas urbanas, tales como edificaciones y vegetación.
- Las características descriptivas del contexto externo caracterizan cada objeto en función de propiedades comunes a todos los objetos adyacentes (de cuya fusión se obtiene el super-objeto), considerando información relativa a las edificaciones y vegetación interna, las características geométricas, y a la conectividad de los objetos que lo componen. En zonas urbanas este super-objeto se corresponde con las manzanas urbanas.

#### 4.3.3.1. Características relativas al objeto

Los objetos-imagen son descritos empleando características relativas a tres aspectos: multiespectral, tridimensional y geométrico. La información multiespectral se extrae derivando información de las imágenes de alta resolución. Para ello, se han calculado las características espectrales de media aritmética, desviación típica, mínimo y máximo de

los valores de intensidad de cada una de las bandas espectrales disponibles, así como del NDVI (ver Sección 4.2.2.2.1.).

La distribución espacial de los niveles de gris de cada objeto se ha caracterizado empleando los descriptores de textura derivados de la banda del espectro electromagnético correspondiente a la zona del rojo en el rango visible. Estos valores se obtienen de la intensidad de bordes (media y desviación típica), los estadísticos de primer orden (curtosis y skewness) y la MCNG (véase la Sección 4.2.2.2.2. para una completa descripción de las características de textura utilizadas).

Las características descriptivas de la altura del objeto se han calculado trabajando sobre la imagen del nDSM generado a partir de los datos LiDAR. Cada objeto ha sido caracterizado empleando los valores de media, desviación típica y el máximo de las alturas.

Las características de forma describen las propiedades geométricas de un objeto, así como la complejidad de su contorno. Los descriptores utilizados han sido: área, perímetro, índice de compacidad, dimensión fractal e índice de forma (para una descripción más profunda de las características de forma empleadas véase la Sección 4.2.2.2.3.).

#### **4.3.3.2. Características de contexto interno del objeto**

Las propiedades y distribución de las diferentes coberturas y elementos presentes dentro de una parcela están estrechamente ligadas con el uso de ésta. Las características del contexto interno describen al objeto a partir de la identificación de las diferentes coberturas y elementos contenidos en él, denominados sub-objetos.

Se han considerado dos coberturas diferentes: las edificaciones y las zonas cubiertas por vegetación. Las edificaciones han sido obtenidas aplicando metodologías basadas en el establecimiento de umbrales. La cubierta vegetal del objeto se ha extraído aplicando el método descrito en la Sección 4.2.1.

##### **4.3.3.2.1. Características relativas a las edificaciones**

Las edificaciones son el elemento primitivo propio de las zonas urbanas. Sus características configuran la percepción de las diferentes zonas y tipologías. A partir de las edificaciones detectadas mediante técnicas automáticas se han definido valores para la caracterización de las dimensiones de las edificaciones contenidas en los objetos.

Las características calculadas que describen las edificaciones se dividen en dos grupos: bidimensionales y tridimensionales. Las características bidimensionales comprenden la superficie edificada y el porcentaje de superficie edificada dentro del objeto. La superficie edificada de una parcela se calcula según la expresión (32):

$$A_{edificada} = n_{edificación} \cdot r^2 \quad (32)$$

donde  $n_{edificación}$  representa al número de píxeles detectados como edificación dentro de un objeto, y  $r$  representa la resolución espacial de la imagen.

Al porcentaje de superficie edificada dentro de un objeto se define habitualmente como ratio de la cobertura edificada (*building coverage ratio*, BCR) o superficie de sellado, y ha sido frecuentemente empleada en la literatura (Yoshida y Omae, 2005; Van de Voorde et al., 2009; Yu et al., 2010). Para su cálculo se emplea la fórmula de la expresión (33):

$$BCR = \frac{A_{edificada}}{A_{objeto}} \cdot 100 \quad (33)$$

donde  $A_{objeto}$  es la superficie del objeto analizado, y  $A_{edificada}$  corresponde a la superficie ocupada por edificaciones dentro de dicho objeto.

Las edificaciones han sido descritas, además, por sus características tridimensionales, basadas en la información proporcionada por la imagen del nDSM. Se han calculado los valores de la media aritmética, la desviación típica y el valor máximo de las alturas de las edificaciones detectadas dentro de una parcela. La media aritmética refleja la tendencia mostrada por las alturas de un edificio y proporciona una idea del volumen edificado. El valor de la desviación típica está ligado a la variabilidad de las alturas de los elementos que componen una edificación, e informa acerca de la complejidad de la construcción. Por su parte el valor máximo del nDSM informa sobre la altura de una edificación.

#### 4.3.3.2.2. Características relativas a la vegetación

La presencia y las dimensiones de la vegetación permiten la identificación de diferentes tipologías urbanas, estando normalmente asociadas a las clases periurbanas o de más reciente construcción. La vegetación presente en un objeto (parcela) se ha caracterizado utilizando el porcentaje de superficie cubierta, la media aritmética y la desviación típica de su altura, y el valor medio y la desviación típica del NDVI de la masa vegetal. Así, de manera análoga a la fórmula de la expresión (33), el porcentaje de superficie cubierta por la vegetación se calcula según la expresión (34):

$$\text{Porcentaje Vegetación} = \frac{A_{vegetación}}{A_{objeto}} \cdot 100 \quad (34)$$

donde  $A_{objeto}$  es la superficie del objeto analizado, y  $A_{vegetación}$  corresponde a la superficie ocupada por la vegetación dentro de dicho objeto.

#### 4.3.3.3. Características de contexto externo del objeto

Las características descriptivas del contexto externo del objeto describen cada objeto en función de las propiedades comunes de los objetos adyacentes. La fusión de los objetos produce nuevas entidades con un nivel de agregación superior, que en el caso de entornos urbanos, viene a corresponder con las manzanas urbanas.

De acuerdo con Yoshida y Omae (2005), la forma, la dimensión y el número de edificaciones son representativos generalmente de las funciones socio-económicas de una manzana urbana. Esto implica la posibilidad de que el uso del suelo esté indicado por la superficie y volumen de sus edificaciones.

La descripción del contexto externo del objeto se realiza considerando varios grupos de características: las relaciones espaciales entre los objetos, analizadas a través de la aplicación de la teoría de grafos; las características morfológicas urbanas —que hacen referencia a las edificaciones—; las características de vegetación; y las características geométricas del super-objeto analizado.

##### 4.3.3.3.1. Relaciones espaciales (Teoría de grafos)

La caracterización de las relaciones espaciales se ha realizado aplicando la teoría de grafos, que estudia las propiedades espaciales. Un grafo es una estructura matemática formada por un conjunto de objetos, llamados vértices, y una selección de pares de vértices, llamados aristas que pueden ser orientados o no. Un grafo se representa mediante una serie de puntos (los vértices) conectados por líneas (las aristas). Se ha descrito la teoría de grafos como una herramienta extremadamente útil y eficiente para almacenar y describir la estructura espacial de unidades geográficas y su disposición espacial (Laurini y Thompson, 1992; Almeida et al, 2007).

Barnsley y Barr (1997), introdujeron esta teoría para la clasificación de entornos urbanos empleando imágenes, con el fin de describir las relaciones espaciales de adyacencia (que corresponden con las aristas en el grafo) entre las diferentes coberturas del terreno (representadas por los vértices). La relación de adyacencia es cuantificada a través de la media y la desviación típica de las aristas para coberturas concretas, aunque centrándose principalmente en las edificaciones.

La caracterización y cuantificación de las relaciones de adyacencia entre objetos se ha realizado mediante la definición de tres índices: el número de adyacencias de una parcela con respecto a las parcelas contiguas, el valor medio y la desviación típica de las distancias con respecto a los objetos adyacentes. Estas características están fuertemente relacionadas con las dimensiones de los objetos y super-objetos (Figura 19), y proporcionan información sobre la distribución espacial de los objetos (parcelas) dentro de la manzana urbana mediante el análisis de las distancias y la variabilidad de las aristas.

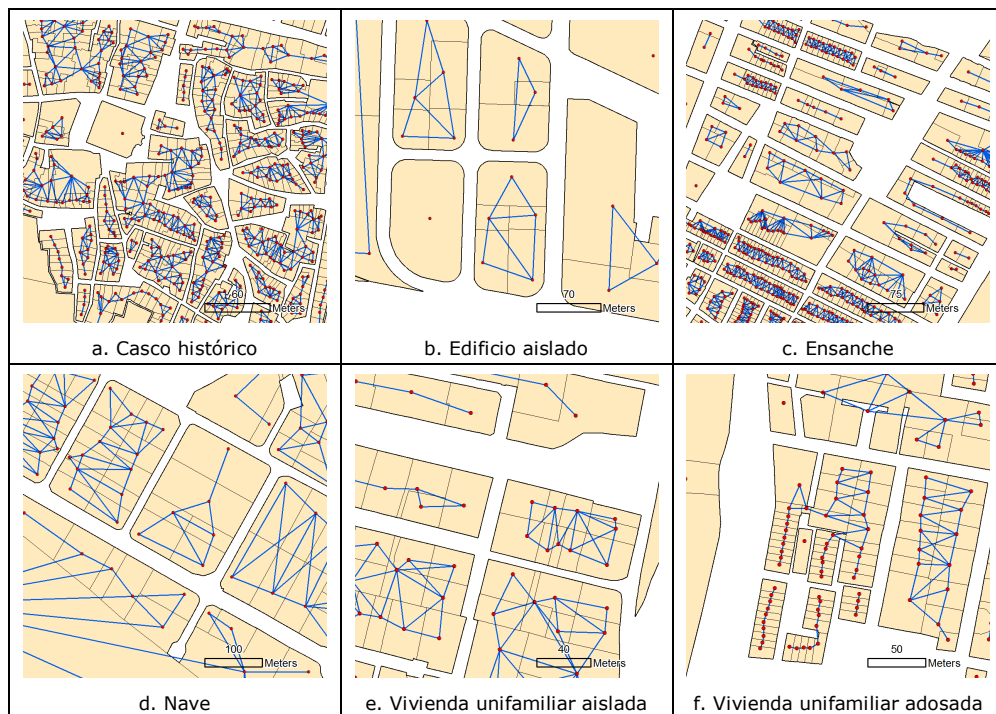


Figura 19. Ejemplos de la distribución de los grafos para las clases definidas.

#### 4.3.3.3.2. Características relativas a las edificaciones

En cuanto a las propiedades relativas a la superficie de las edificaciones, cada manzana urbana ha sido caracterizada por su valor de superficie edificada y por su porcentaje de superficie edificada (BCR). En la Figura 20 se muestran ejemplos de la superficie ocupada por edificaciones en manzanas urbanas para las clases urbanas definidas. Las clases *casco histórico* y *ensanche* muestran prácticamente toda la superficie edificada, quedando libres pequeños patios internos. La clase *edificio aislado* suele presentar sólo parte de la manzana urbana cubierta por edificaciones, apareciendo amplias zonas libres. En la clase *nave* aparece una mayor variabilidad de la superficie cubierta por edificaciones con respecto a la superficie total de la manzana. La clase *vivienda unifamiliar aislada* presenta un gran número de pequeñas edificaciones distribuidas en manzanas urbanas de gran superficie. La clase *vivienda unifamiliar adosada*, por su parte, presenta super-objetos de un tamaño inferior, por lo que la superficie de la edificación en términos relativos presenta valores mayores.

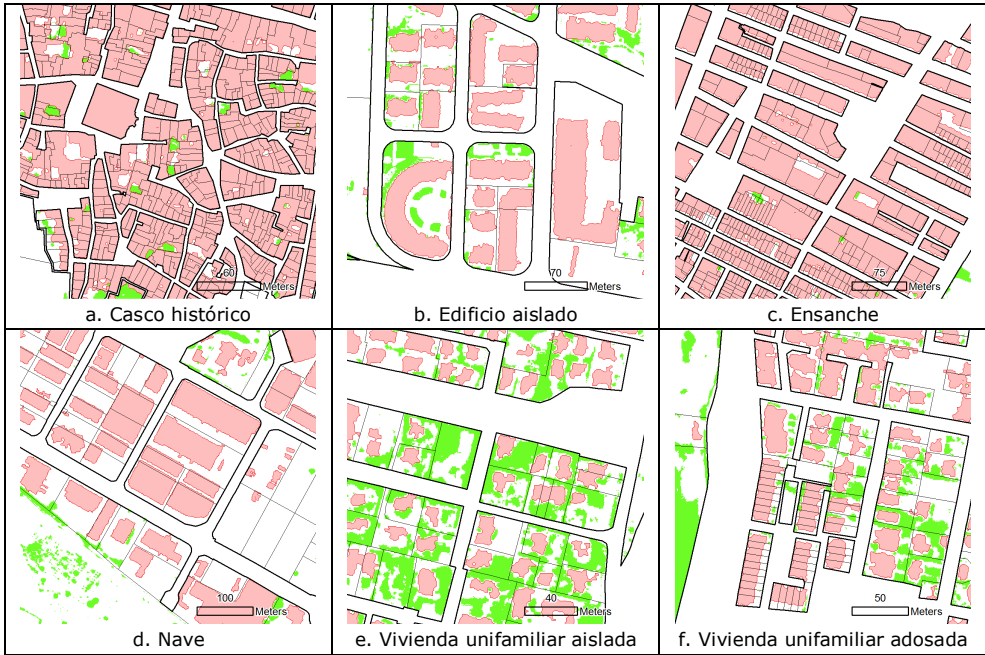


Figura 20. Ejemplos de las coberturas edificadas y de vegetación para las clases definidas.

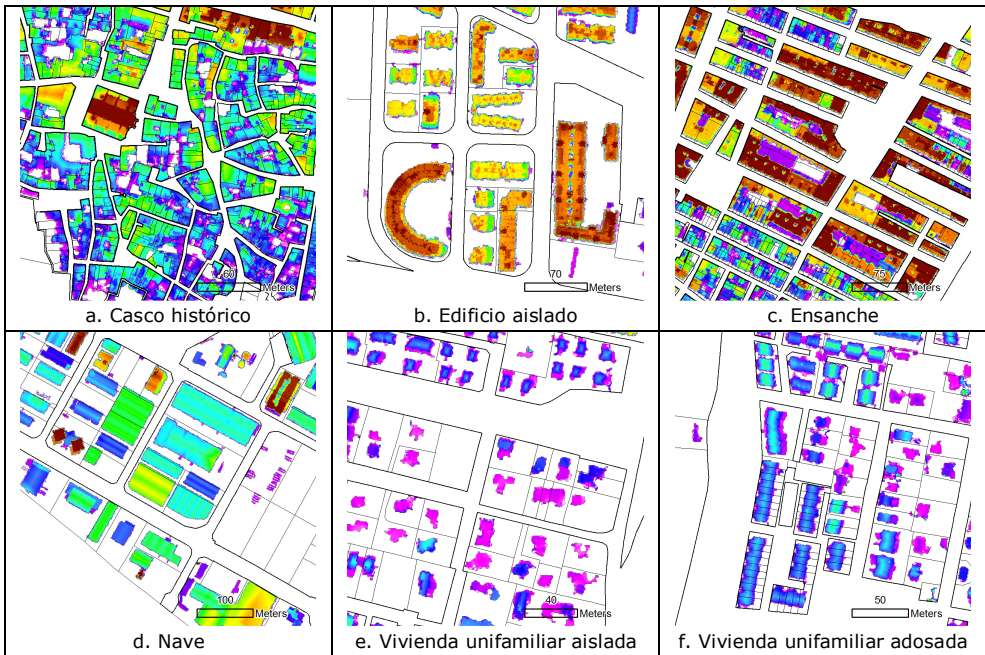


Figura 21. Ejemplos de la distribución de las alturas en las edificaciones para las clases definidas.



Tridimensionalmente, las edificaciones se han caracterizado a través de los valores de media aritmética y desviación típica de la altura de la superficie edificada. En la Figura 21 se muestran ejemplos característicos de la distribución de las alturas de las edificaciones para las distintas clases, pudiéndose observar diferencias. Así, en la clase *casco histórico* destaca principalmente la gran variabilidad en las alturas de las edificaciones. Por su parte, las edificaciones de la clase *ensanche* presentan también una gran variedad de alturas que tienden a ser superiores a las del casco histórico. Los objetos de la clase *edificio aislado* suelen presentar grandes edificaciones con alturas uniformes. La clase *Nave* muestran edificaciones amplias con alturas uniformes. Las clases de tipo suburbano presentan las menores alturas de las clases analizadas. Si bien las *viviendas unifamiliares adosadas* tienen un menor tamaño que las *viviendas unifamiliares aisladas*, pero presentan mayor altura de sus edificaciones.

El volumen de una edificación viene dado por la fórmula (35):

$$V = \sum_{i=1}^n h_i r^2 \quad (35)$$

donde  $r$  es la resolución espacial y  $h_i$  es el valor altura relativa obtenida del nDSM para la celda  $i$  de una superficie detectada como edificación, compuesta por  $n$  píxeles.

A partir del volumen de cada edificio, Yoshida y Omae (2005) proponen caracterizar las manzanas urbanas utilizando el volumen medio de las edificaciones, mediante el ratio entre el volumen total de las edificaciones y el número de edificaciones contenidas en una manzana, tal y como expresa la ecuación (36):

$$V_m = \frac{\sum_{i=1}^n V_i}{n} \quad (36)$$

donde  $V_i$  es el volumen de la edificación  $i$  y  $n$  el número total de edificaciones contenidas en la manzana urbana analizada.

#### 4.3.3.3. Características relativas a la vegetación

Las características referentes a la vegetación a nivel de manzana urbana definidas son el porcentaje de superficie cubierta, la media aritmética y la desviación típica de la altura, y el valor medio y la desviación típica del NDVI de las masas vegetales. En la Figura 20 se muestran varios ejemplos de la presencia de vegetación en las diferentes clases urbanas consideradas. Las áreas urbanas residenciales, generalmente de construcción más reciente, cuentan con una abundante presencia de vegetación. Las clases características de estas áreas son las *viviendas unifamiliares aisladas*, *viviendas unifamiliares adosadas*, y *edificio aislado*. En la clase *casco histórico* se da una cierta presencia de vegetación, localizada en los patios interiores de las edificaciones, mientras que en las zonas de



*ensanche* y en las áreas industriales la cantidad de vegetación se ve fuertemente reducida.

#### 4.3.3.3.4. Características de forma

Además de por la morfología interna, descrita por las relaciones contextuales, y por las características de las edificaciones, las manzanas urbanas presentan diferentes cualidades geométricas y de forma dependiendo de sus usos principales (Figura 22).



Figura 22. Ejemplos de la forma y geometría de las manzanas de las clases urbanas definidas.

Las áreas históricas se caracterizan por sus reducidas dimensiones y por la extrema irregularidad en el contorno de sus manzanas, fruto de un crecimiento no planificado de la ciudad. Las zonas de crecimiento de las ciudades, compuestas por las clases *edificio aislado* y *ensanche*, presentan manzanas urbanas de mayor tamaño con formas regulares, en las que abundan las intersecciones en ángulo recto. Las manzanas urbanas de las áreas industriales también presentan contornos con formas regulares, pero con unas dimensiones superiores. Las manzanas urbanas características de la clase *viviendas unifamiliares aisladas* son regulares, pero presentan unas dimensiones menores a las características de las zonas de mayor densidad urbana. Las manzanas urbanas de los

*viviendas unifamiliares adosadas* se caracterizan por sus formas rectangulares alargadas, donde la base del rectángulo tiene una longitud mucho mayor que la altura.

Las características que describen las propiedades geométricas y la complejidad del contorno de las manzanas urbanas calculadas son: área, perímetro, índice de compacidad, dimensión fractal e índice de forma (para una descripción más profunda véase la Sección 4.2.2.3.).

#### **4.3.4. Selección de características y clasificación**

Una vez calculadas las 64 características descriptivas (ver listado y codificación en la Tabla 2 y la Tabla 3) es conveniente realizar un proceso selectivo para determinar aquellas que presenten una mayor relevancia en el proceso de clasificación, eliminando de la clasificación las que proporcionen una información redundante o no sean lo suficientemente discriminantes. Para ello se ha utilizado el método de análisis discriminante lineal paso a paso (véase la Sección 4.2.2.3.).

Con el fin de evaluar el rendimiento en la clasificación de las diferentes características descriptivas empleadas, ésta se ha realizado progresivamente, de forma que se han ido incluyendo de manera sucesiva dentro del modelo de clasificación los distintos grupos de características. En un primer paso se han incluido características descriptoras de las propiedades de la imagen de los objetos (espectrales y de textura). Tras esto, se incluyen las características relativas a la geometría bidimensional y tridimensional del objeto, a través de las características de forma y de altura. En un tercer paso se introducen las características descriptoras del contexto interno del objeto. Por último, se añaden al modelo de clasificación las características descriptivas del contexto externo del objeto.

La clasificación de los objetos se ha llevado a cabo utilizando la metodología de los árboles de decisión, generados con el algoritmo C5.0, y empleando la técnica de multclasificación *boosting*, creando 10 árboles de decisión. En esta metodología se asigna a cada árbol un peso que es mayor cuanto menor es su error estimado. Posteriormente, se suman los pesos de los árboles que eligen la misma clase para un objeto, y aquella clase que acumule el mayor valor es la clase predicha para el objeto. La descripción completa de la metodología de clasificación puede encontrarse en la Sección 4.2.2.4.

Tabla 2. Listado de las características descriptivas relativas al objeto.

<b>Características relativas al objeto</b>			
<b>Grupo I</b>	Espectrales	Media infrarrojo	<i>MeanIR</i>
		Desv. típica infrarrojo	<i>DesvIR</i>
		Mínimo infrarrojo	<i>MinIR</i>
		Máximo infrarrojo	<i>MaxIR</i>
		Media rojo	<i>MeanR</i>
		Desv. típica rojo	<i>DesvR</i>
		Mínimo rojo	<i>MinR</i>
		Máximo rojo	<i>MaxR</i>
		Media verde	<i>MeanG</i>
		Desv. típica verde	<i>DesvG</i>
		Mínimo verde	<i>MinG</i>
		Máximo verde	<i>MaxG</i>
		Media NDVI	<i>MeanNDVI</i>
	Desv. típica NDVI	<i>DesvNDVI</i>	
	Mínimo NDVI	<i>MinNDVI</i>	
	Máximo NDVI	<i>MaxNDVI</i>	
	Textura	Media intensidad de bordes	<i>MeanIB</i>
		Desv. típica intensidad bordes	<i>DesvIB</i>
		Skewness	<i>Skewness</i>
Curtosis		<i>Curtosis</i>	
Uniformidad		<i>Uniformidad</i>	
Entropía		<i>Entropia</i>	
Contraste		<i>Contraste</i>	
Momento de diferencia inverso		<i>IDM</i>	
Covarianza		<i>Covar</i>	
Varianza		<i>Varianza</i>	
Correlación	<i>Correlación</i>		
<b>Grupo II</b>	Forma	Compacidad	<i>CompacOB</i>
		Índice de forma	<i>IFormaOB</i>
		Dimensión fractal	<i>DfOB</i>
		Área	<i>AreaOB</i>
		Perímetro	<i>PerimOB</i>
	Altura	Media altura	<i>MeanH</i>
		Desv. típica altura	<i>DesvH</i>
	Máximo altura	<i>MaxH</i>	

Tabla 3. Listado de las características descriptivas del contexto interno y externo.

<b>Características del contexto interno</b>			
<b>Grupo III</b>	Edificaciones	Media altura	<i>MeanHED</i>
		Desv. típica altura	<i>DesvHED</i>
		Máximo altura	<i>MaxHED</i>
		Superficie edificada	<i>SupED</i>
		Porcentaje de superficie edificada	<i>BCRED</i>
	Vegetación	Media altura	<i>MeanHV</i>
		Desv. típica altura	<i>DesvHV</i>
		Media NDVI	<i>MeanNDVIV</i>
		Desv. típica NDVI	<i>DesvNDVIV</i>
		Porcentaje de superficie	<i>PercV</i>
<b>Características del contexto externo</b>			
<b>Grupo IV</b>	Conectividad	Número de relaciones	<i>Nrel</i>
		Distancia media	<i>MeanDrel</i>
		Desv. típica distancia	<i>DesvDrel</i>
	Morfología urbana	Volumen medio por edificación	<i>VolM</i>
		Porcentaje de superficie edificada	<i>BCRSO</i>
		Superficie edificada	<i>SupEDSO</i>
		Media altura de las edificaciones	<i>MeanHSO</i>
		Desv. típica altura de las edificaciones	<i>DesvHSO</i>
	Vegetación	Media altura	<i>MeanHVSO</i>
		Desv. típica altura	<i>DesvHVSO</i>
		Media NDVI	<i>MeanNDVIVSO</i>
		Desv. típica NDVI	<i>DesvNDVIVSO</i>
		Porcentaje de superficie	<i>PercVSO</i>
	Forma	Compacidad	<i>CompacSO</i>
		Índice de forma	<i>IFormaSO</i>
		Dimensión fractal	<i>DfSO</i>
		Área	<i>AreaSO</i>
		Perímetro	<i>PerimSO</i>

#### 4.3.5. Evaluación de la clasificación

Se ha empleado la matriz de confusión como método para evaluar la clasificación. Ésta recoge las discordancias entre los datos clasificados y los de referencia (véase la Sección 4.2.2.5.). A partir de la matriz se han calculado los valores de fiabilidad global para cada clasificación realizada, así como los valores de fiabilidad de productor y de usuario para cada clase.

Estos índices de fiabilidad son simples de usar pero no llegan a aprovechar la información contenida en dicha matriz considerada en conjunto. Esto implicaría que una distribución completamente aleatoria en las clases de los objetos pueda conducir a resultados aparentemente correctos en la matriz de confusión. Con el fin de superar estos inconvenientes se ha utilizado, además, el índice denominado coeficiente *kappa*. Este

estadístico es una medida de la diferencia entre la exactitud lograda en la clasificación con un clasificador automático y la posibilidad de lograr una clasificación correcta con un clasificador aleatorio (Richards y Xia, 2006). La definición conceptual del coeficiente kappa viene definida por la expresión (37):

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \cdot x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \cdot x_{+i})} \quad (37)$$

donde  $r$  es el número de filas en la matriz;  $x_{ij}$  el número de observaciones en el elemento en la diagonal mayor;  $x_{i+}$  es el total de las observaciones en la fila  $i$  (total marginal a la derecha de la matriz);  $x_{+i}$  es el total de observaciones en la columna  $i$  (total marginal al pie de la matriz);  $N$  es el número de observaciones incluidas en la matriz. El valor de  $\kappa$  variará entre 0 y 1.

Un análisis pormenorizado de la matriz de confusión permite detectar aquellas clases entre las que existe una mayor dificultad para su separación. Se ha definido un indicador específico para cuantificar la confusión particular producida entre pares de clases, denominado índice de error mutuo. Este índice se calcula como la suma de los errores mutuos entre dos clases divididos entre el sumatorio de los aciertos y errores mutuos para ambas clases, de acuerdo con la ecuación (38):

$$\text{Índice de error mutuo} = \frac{x_{ij} + x_{ji}}{x_{ii} + x_{jj} + x_{ij} + x_{ji}} \quad (38)$$

donde  $x_{ij}$  y  $x_{ji}$  representan los objetos de la clase  $i$  clasificados erróneamente en la clase  $j$  y viceversa, esto es, los errores mutuos;  $x_{ii}$  y  $x_{jj}$  representan el número de observaciones en el elemento diagonal mayor o aciertos. El índice de error varía entre 0, cuando no existen errores mutuos entre un par de clases, y 1, cuando todos los objetos de las clases consideradas se clasifican erróneamente.

Debido a que la tarea de selección de muestras, bien de entrenamiento o de evaluación, es costosa, éstas pueden ser aprovechadas al máximo utilizando la metodología de validación cruzada *leave-one-out*. Este método consiste en utilizar una muestra del conjunto de datos original como muestra de evaluación y el resto de observaciones como muestra de entrenamiento. Esta acción se repite hasta que cada una de las observaciones del conjunto de datos es utilizada como muestra de evaluación, permitiendo obtenerse el rendimiento global y la matriz de confusión.



## Capítulo V

---

### RESULTADOS

---

#### 5.1. Introducción

En este capítulo se presentan los resultados de evaluación de las metodologías propuestas. En la primera parte se analizan y comparan los métodos de detección de edificios planteados, basados en el establecimiento de umbrales y en la clasificación orientada a objetos.

La segunda parte es la referida a los resultados de la clasificación contextual en entornos urbanos. En ella se recoge el análisis de las características discriminantes propuestas, así como los resultados de fiabilidad de la clasificación, analizados de forma global y de manera independiente por clases.

En la tercera y última parte se realiza una evaluación de la aplicabilidad del empleo de las técnicas automáticas para la creación/actualización de bases de datos geo-espaciales de ocupación del suelo. Así, se estima la superficie edificada comparando los resultados de los métodos automáticos frente a los obtenidos empleando métodos tradicionales basados en interpretación visual, que son los utilizados para confeccionar la base de datos del SIOSE. Se analiza también la asignación de las diferentes tipologías de edificación a un polígono SIOSE.

## **5.2. Análisis comparativo de los métodos de detección de edificaciones**

En esta sección se recogen los análisis realizados para evaluar y comparar la precisión de los métodos de detección de edificaciones propuestos. En el primer ensayo se valoran los resultados de la detección de edificaciones del método de establecimiento de umbrales simples para cada zona de estudio y tipología de edificación.

En el segundo ensayo se analizan las dos técnicas de segmentación empleadas: detección de bordes y crecimiento de regiones, y posteriormente se evalúa por separado el efecto en el resultado utilizando del método de detección de edificaciones basado en la clasificación orientada a objetos. Tras esto, se comparan los índices de evaluación obtenidos por medio de la media y la desviación para cada tipología de edificación analizada.

En el tercer ensayo se comparan los resultados de la detección de las edificaciones entre el método de umbralización y el método de clasificación orientada a objetos empleando la técnica de segmentación que mejores resultados proporciona.

En el cuarto ensayo se comparan, a través de los valores de media y desviación de los índices de evaluación, los resultados anteriores con el resultado de la inclusión de condiciones de relaciones de contexto de la edificaciones con las sombras detectadas en la imagen, tanto para el método de definición de umbrales simples como para el método de clasificación orientada a objetos.

Por último, y debido a que la densidad de los datos LiDAR en la zona de Oliva (2 puntos/m<sup>2</sup>) es superior a las demás (Moncada: 1 punto/m<sup>2</sup>; Sagunto: 0,5 puntos/m<sup>2</sup>), se ha analizado el efecto que la densidad de puntos LiDAR tiene en los resultados de la detección de edificaciones.

### **5.2.1. Evaluación del procedimiento para la detección de edificaciones basado en el establecimiento de umbrales**

Los resultados estadísticos de la detección de edificaciones empleando el método de establecimiento de umbrales se presentan en la Tabla 4. Globalmente, los resultados obtenidos muestran la elevada robustez del método en las diferentes tipologías de construcción analizadas.

La evaluación de la detección de edificaciones en zonas de tipología de edificación industrial presenta unos valores de factor por exceso y por defecto muy bajos, lo cual indica que la delineación de las edificaciones detectadas se ajusta con mucha exactitud a



los edificios reales. El valor del porcentaje de calidad es superior al 90% en los dos casos analizados.

Tabla 4. Resultados estadísticos de la evaluación de las zonas de estudio empleando el método de umbralización.

Evaluación		Urbano			Periurbano			Industrial	
		Moncada	Oliva	Sagunto	Moncada	Oliva	Sagunto	Moncada	Sagunto
Por áreas	FE	0,12	0,08	0,11	0,37	0,11	0,15	0,06	0,09
	FD	0,04	0,03	0,02	0,14	0,12	0,16	0,02	0,02
	PD	96,5	97,2	98,1	87,8	89,1	86,3	97,7	98,2
	PC	86,6	90,6	88,3	66,1	81,1	76,6	92	90,3
Por objetos	Cr	74,3	71,9	87,2	89,8	100	99,2	72,4	73,3
	Cm	100	100	100	98,4	99,3	95	100	100

Estudiando los resultados de la evaluación a nivel de objetos se observa el factor de completación en ambos casos indica que no hay ningún edificio real que no esté solapado, al menos en parte, por las edificaciones detectadas. En cambio, el factor de corrección presenta valores menores. Esto, junto con los bajos valores obtenidos en los factores de exceso y defecto indica que se produce la detección errónea como edificaciones de una serie de elementos cuyo pequeño tamaño apenas influye en la evaluación a nivel de área, pero generan *ruido* en la evaluación a nivel de objetos, ya que cada uno de ellos cuenta como una unidad, produciendo un error por exceso en cuanto al número de objetos.

En la Figura 23 se puede observar gráficamente el resultado del método de detección de edificaciones en la zona industrial. Las edificaciones aparecen, por lo general, correctamente definidas y delimitadas, mientras que aparecen detectados erróneamente pequeños objetos. Esto se debe por lo general, a la presencia de elementos característicos de este tipo de áreas, tales como camiones o palés con productos manufacturados. Se producen además errores por la inclusión errónea de vegetación arbórea con baja reflectancia en el infrarrojo o localizada en zonas de sobra como edificaciones.

En la zona urbana, la tónica general es la presencia de factores de exceso ligeramente superiores a los obtenidos en la zona industrial pero con valores muy bajos (inferiores o iguales a 0,12). Los factores de defecto presentan valores muy cercanos a cero. Como resultado, los porcentajes de calidad obtenidos en las tres zonas analizadas se

encuentran entre el 86,6% y el 89,9%, lo que indica la eficacia del método en la detección de edificaciones.



Figura 23. Ejemplos de la detección de edificaciones de tipología industrial en Moncada (izquierda) y Sagunto (centro y derecha).

A nivel de objeto, se producen resultados similares a los de la zona industrial, obteniéndose un valor de corrección notablemente inferior al de completión. Examinando gráficamente los resultados, como en el ejemplo de la Figura 24, puede comprobarse que una buena parte del *ruido* que introduce errores en el resultado de la evaluación a nivel de objetos es debido a árboles que presentan pequeñas diferencias posicionales con respecto a su representación en los datos LiDAR, lo que evita que sean enmascarados empleando el NDVI.



Figura 24. Ejemplos de la detección de edificaciones de tipología urbana en Moncada (izquierda), Oliva (centro) y Sagunto (derecha).

Los resultados de la evaluación del método de umbralización para la zona periurbana son menos eficientes que en las anteriores tipologías de edificación. Aún así, y pese a la complejidad asociada a esta tipología constructiva, los valores de factor de exceso y defecto obtenidos son de nivel medio-bajo. Los porcentajes de calidad obtenidos varían entre 66% y el 78%. Estos valores son similares a los presentados en la literatura en zonas con este tipo de construcciones al combinar datos LiDAR e imágenes (Koc San y Tucker, 2007).

Los valores de corrección y completión obtenidos son más equilibrados que en las anteriores tipologías constructivas analizadas e indican que, al menos el 90% de las edificaciones detectadas, coinciden con edificaciones reales, y que el 95% de las edificaciones reales son automáticamente detectadas. Los resultados menos satisfactorios se dan en la zona de Moncada, cuyas zonas periurbanas son más antiguas a las de las otras zonas de estudio., por lo que el porte de los árboles es mayor, produciendo una oclusión de las edificaciones mayor. Analizando gráficamente los resultados (Figura 25) se aprecia cómo la mayor parte de las edificaciones son detectadas de forma aislada, si bien su forma se encuentra ampliamente condicionada por oclusiones debidas a la vegetación.




Figura 25. Ejemplos de la detección de edificaciones de tipología periurbana en Moncada (izquierda), Oliva (centro) y Sagunto (derecha). Puede observarse las oclusiones debidas a la vegetación.

### 5.2.2. Evaluación del procedimiento para la detección basado en clasificación orientada a objetos

En primer lugar se estudia y analiza el resultado producido por cada uno de los métodos de segmentación analizados. Con el fin de obtener objetos con mayor significado para la detección de edificaciones, la segmentación se ha realizado utilizando el nDSM. La selección del factor de escala debe realizarse de forma empírica, tratando de encontrar el valor que produzca un mayor equilibrio entre la infra-segmentación y la sobre-segmentación de las edificaciones.

En la Figura 26 se muestran distintas imágenes de los resultados de la segmentación empleando ambos métodos. La escala de los objetos definidos en la segmentación por el método de detección de bordes es proporcional al umbral aplicado sobre la imagen de gradientes. Al aplicarse la segmentación sobre el nDSM, estos gradientes representan cambios bruscos de altura. A priori, este método de segmentación presenta la ventaja de no tener en cuenta el área de los objetos generados, sino únicamente el valor del gradiente de la imagen. En la práctica esto produce polígonos con tamaños heterogéneos, que se ajustan a los diferentes elementos que aparecen en la imagen. Así, un mismo factor de escala engloba en objetos únicos edificios con dimensiones tan

dispares como naves industriales y viviendas unifamiliares periurbanas. Por el contrario, en zonas puramente urbanas, los polígonos son de menor tamaño, ya que la tipología de construcción predominante en estas áreas son manzanas con numerosas fincas con alturas diferentes. Cabe destacar también, que al no contar este método con limitación en el área de los objetos resultantes, al trabajar sobre el nDSM se crea un macro-objeto que representa al suelo.

En el método de segmentación de crecimiento por regiones, el factor de escala tiene en cuenta, además de la homogeneidad de la información, la forma y la superficie de los objetos. Por ello, este método divide en polígonos con una superficie homogénea toda la imagen, no ocurriendo casos como el del macro-objeto generado al utilizar el método de detección de bordes. Esta generación de polígonos con áreas similares obliga a la división de edificaciones con altura homogénea en varios objetos. Empleando el mismo factor de escala, el caso contrario puede producirse en zonas con tipologías de edificación unifamiliar, donde por necesidades de crear polígonos con área homogénea, se generen objetos en el que se engloben tanto edificaciones como suelo y vegetación. Por ello el factor de escala para este método de segmentación debe seleccionarse en función del tamaño de la unidad mínima que se desee aislar. En los casos analizados, la unidad mínima coincide con el tamaño de las viviendas unifamiliares.



Figura 26. Detalles de la segmentación empleando ambos métodos sobre una zona industrial en Moncada (izquierda), una zona urbana en Oliva (centro) y una zona periurbana en Sagunto (derecha).

En la Figura 26 se puede observar un ejemplo de cómo las construcciones industriales se dividen en varios objetos mientras que, por lo general, las construcciones periurbanas se engloban en un único objeto. La división en polígonos de las edificaciones en la zona



urbana es similar a la obtenida empleando el método de segmentación de detección de bordes.

Con el fin de realizar el estudio de la manera más robusta posible, las muestras de aprendizaje de la clasificación se seleccionaron de las mismas zonas para ambas segmentaciones, quedando fuera de las áreas definidas para la evaluación de la detección.

La selección de las características descriptivas más significativas se ha llevado a cabo empleando el método de análisis discriminante lineal paso a paso. En la Figura 27 se muestran las gráficas de la fiabilidad global de la clasificación predicha al incluirse sucesivamente nuevas características al modelo en función de su poder de discriminación. Se ha trabajado sobre los objetos-imagen resultantes de la segmentación empleando ambos métodos y considerando todas las clases definidas.

Los mayores aumentos de la fiabilidad se producen con la inclusión de las primeras características descriptivas en el modelo, puesto que estas son las más discriminantes. Con la sucesiva inclusión de características en el modelo, el valor de fiabilidad global de la clasificación predicho tiende a estabilizarse hasta permanecer prácticamente constante. Estas variables no aportan información significativa al modelo discriminante, por lo que deben ser excluidas del proceso de clasificación.

Analizando la naturaleza de las primeras características incluidas en los modelos, destaca cómo se combinan efectivamente los cuatro tipos de características definidas: espectrales, textura, forma y altura; lo que indica que todas las características empleadas colaboran entre sí para realizar una completa descripción de los objetos desde diferentes puntos de vista.

En la Tabla 5 se muestran los valores de fiabilidad global obtenidos en las clasificaciones realizadas con diferentes métodos de segmentación ensayados. Estos valores han sido calculados a partir de la matriz de errores, empleando la técnica de la validación cruzada, tras agrupar las clases definidas en dos únicas: *edificaciones* y *zonas-sin-edificaciones*. Los altos valores de fiabilidad global obtenidos, superiores todos ellos al 95%, indican que la clasificación se ha producido de forma muy precisa.

Tabla 5. Resultados de la fiabilidad global de la clasificación para los objetos resultantes de cada método de segmentación.

Zona de estudio	Método de segmentación	
	Detección de bordes	Crecimiento de regiones
<b>Moncada</b>	95%	97%
<b>Oliva</b>	96%	95%
<b>Sagunto</b>	99%	98%




Figura 27. Gráficas de fiabilidad predicha mediante análisis discriminante lineal para las clasificaciones de las segmentaciones generadas con los métodos analizados.

La Tabla 6 y la Tabla 7 muestran los resultados de la evaluación de la detección de edificaciones empleando el método de clasificación orientada a objetos empleando, respectivamente, las técnicas de segmentación de detección de bordes y crecimiento por regiones.

Los valores estadísticos obtenidos para el caso de la zona industrial son similares en ambos métodos de segmentación. A nivel de áreas se obtienen unos valores muy bajos de factor de exceso y factor de defecto, lo cual indica que la localización y delineación de este tipo de edificaciones se realiza con un grado de fiabilidad elevado. Los porcentajes de calidad obtenidos no muestran diferencias significativas.

Analizando los resultados estadísticos a nivel de objetos, los valores del factor de completión en ambos casos indican que apenas existen edificaciones reales que no sea solapado, al menos en parte, por las edificaciones detectadas automáticamente. Por el contrario, el factor de corrección presenta valores bajos en ambas metodologías, siendo especialmente destacable el caso de Sagunto cuando se emplea la segmentación por detección de bordes. Esto es debido al *ruido* generado por edificaciones erróneamente detectadas de superficie pequeña, que falsean los resultados en la evaluación a nivel de objetos. Al observar la detección de las construcciones industriales en este municipio (Figura 28) se aprecia la detección errónea de pequeños objetos como edificaciones (camiones y palés) es más frecuente en el caso de emplear el método de segmentación de detección de bordes. Esto se debe a que este método no tiene en cuenta en la segmentación el área ni la forma de los objetos, por lo que crea segmentos de menor tamaño que el método de crecimiento de regiones.

Tabla 6. Resultados estadísticos de la evaluación de las zonas de estudio empleando el método de clasificación orientada a objetos con la segmentación por detección de bordes.

Evaluación	Urbano			Periurbano			Industrial		
	Moncada	Oliva	Sagunto	Moncada	Oliva	Sagunto	Moncada	Sagunto	
Por áreas	FE	0,18	0,08	0,13	0,91	0,58	0,29	0,06	0,11
	FD	0,09	0,10	0,04	0,14	0,23	0,19	0,05	0,03
	PD	91,7	91,2	96,2	88,1	81,5	84,1	95,3	96,8
	PC	78,9	84,8	85,4	49,0	55,5	67,6	90,1	87,8
Por objetos	Cr	65,7	38,8	67,3	78,7	62,8	91,6	63,6	38,3
	Cm	96,3	100	100	96,8	100	92,1	100	100

Tabla 7. Resultados estadísticos de la evaluación de las zonas de estudio empleando el método de clasificación orientada a objetos con la segmentación por crecimiento de regiones.

Evaluación	Urbano			Periurbano			Industrial		
	Moncada	Oliva	Sagunto	Moncada	Oliva	Sagunto	Moncada	Sagunto	
Por áreas	FE	0,17	0,06	0,15	0,70	0,20	0,49	0,08	0,11
	FD	0,05	0,10	0,03	0,17	0,16	0,17	0,04	0,04
	PD	95,1	90,9	97,5	85,6	86,3	85,5	96,5	96,1
	PC	81,7	86	85,5	53,6	73,9	60,4	89,6	86,8
Por objetos	Cr	59,5	51,6	53,8	86,6	93,1	84,1	59,5	50
	Cm	96,3	100	100	93	99,3	95,7	100	96,4



Figura 28. Detalles de la segmentación empleando ambos métodos sobre una zona periurbana en Moncada (izquierda), una zona urbana en Oliva (centro) y una zona periurbana en Sagunto (derecha).



Los resultados de evaluación a nivel de áreas de la zona urbana muestran cómo empleando ambos métodos de segmentación se obtiene un factor de exceso similar. Aunque los dos métodos de segmentación presentan valores elevados en estos índices, las diferencias más significativas se observa en el factor de defecto y en el porcentaje de detección para el caso de Moncada. El porcentaje de calidad es siempre favorable al método de crecimiento de regiones.

A nivel de objetos, los resultados son comparables con los obtenidos en las zonas industriales. Así se ha obtenido un valor de compleción alto, que supone un error por exceso bajo, y un valor de corrección medio-alto, salvo para el caso de Oliva. Observando gráficamente el resultado en la Figura 28 se aprecia un ejemplo de cómo tanto los objetos generados empleando ambos métodos de segmentación, como los errores producidos son muy parecidos. Estos errores son, cómo en el caso de en la zona industrial, pequeños elementos (especialmente árboles) que actúan como ruido en los índices de evaluación a nivel de objeto.

En la zona periurbana las fiabilidades a nivel de área son significativamente más bajas que las obtenidas para las zonas industrial y urbana. El valor del factor de exceso es normalmente más alto para el método de segmentación por detección de bordes, salvo en el caso de Sagunto. Por el contrario, los valores de factor de exceso son más moderados. Esto indica, tal y como se observa en la Figura 28, la clasificación como edificaciones de algunos objetos de gran tamaño que engloban a varias edificaciones reales. También muestra cómo las edificaciones detectadas utilizando el método de detección de bordes en zonas periurbanas tienen, por lo general, mayor tamaño y menor exactitud que las detectadas con el método de crecimiento de regiones.

Analizando los resultados a nivel de objetos, los valores de corrección y compleción muestran valores altos, aunque son más equilibrados para el método de crecimiento de regiones. Pese al alto valor del factor de exceso a nivel de áreas, el también elevado índice de compleción apunta a que gran parte de las edificaciones detectadas automáticamente están en contacto con edificaciones reales.

En la Tabla 8 se muestra la comparación de los resultados de evaluación de la detección de edificaciones a través de los valores de media y la desviación estándar de los índices estadísticos empleados. Las diferencias entre los resultados tanto a nivel de áreas como de objetos para las zonas urbanas e industriales no son significativas. Si bien, visualmente, la menor presencia de pequeños objetos que dificultan una correcta interpretación de los resultados hace preferible la utilización del método de crecimiento de regiones para generar los objetos. Además, en entornos periurbanos, los resultados del empleo del crecimiento por regiones como metodología de segmentación son notablemente superiores que la utilización del método de detección de bordes.

Tabla 8. Comparación de los índices estadísticos de evaluación divididos por tipología de edificación para los métodos de clasificación orientada a objetos utilizando la segmentación por detección de bordes o por crecimiento de regiones.

		Urbano		Periurbano				Industrial					
		Det. bordes		C. regiones		Det. bordes		C. regiones		Det. bordes		C. regiones	
		$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$
Por áreas	FE	0,13	0,05	0,13	0,06	0,59	0,39	0,46	0,30	0,09	0,04	0,10	0,02
	FD	0,08	0,03	0,06	0,04	0,19	0,10	0,17	0,08	0,04	0,01	0,04	0
	PD	93,0	2,8	94,5	3,3	84,6	7,4	85,8	6,7	96,1	1,1	96,3	0,3
	PC	83,0	3,6	84,4	2,4	57,4	19,4	62,6	16,1	89,0	1,6	88,2	2
Por objetos	Cr	57,3	16,0	55,0	4,1	77,7	8,2	87,9	21,1	51,0	17,9	54,8	6,7
	Cm	98,8	2,1	98,8	2,1	96,3	1,8	96	3,9	100,0	0	98,2	2,5

### 5.2.3. Comparación de los métodos de detección de edificaciones

En la Tabla 9 se comparan, mediante los valores de media y desviación típica, los resultados estadísticos de evaluación obtenidos para la detección de objetos utilizando el método de clasificación orientada a objetos con la segmentación de crecimiento de regiones y el método de umbralización.

A nivel de área, para la tipología de edificación industrial los resultados obtenidos muestran que en esta tipología ambos métodos realizan una detección de las edificaciones muy correcta, siendo ligeramente menores los errores producidos por el método de clasificación. Esto se corrobora, a su vez, analizando el porcentaje de calidad. A nivel de objetos, los resultados son favorables al método de umbralización. Lo mismo ocurre en el caso de las edificaciones situados en zonas urbanas. A nivel de objetos se confirma esta mejora en la detección de los edificios con aumentos tanto en el índice de corrección como en el de completión.

Son destacables las diferencias existentes en la evaluación por áreas entre las tres zonas de estudio en entornos urbanos. Los resultados de factor de exceso y de defecto para ambos métodos de detección presentan los mayores valores de media y desviación de todos los entornos analizados, siendo notablemente menores los errores producidos empleando el método de umbralización. Esto se debe a que las edificaciones detectadas empleando el método de clasificación orientada a objetos presentan frecuentemente grandes dimensiones, conteniendo varias edificaciones reales en su interior. La predominancia cualitativa del método de umbralización queda confirmada con el valor

medio del porcentaje de calidad, donde supera en más de un 10% al método de clasificación orientada a objetos. Los resultados de la evaluación a nivel de objetos presentan un valor en índice de corrección superior en el caso del método de umbralización. El valor medio del índice de corrección es similar para ambos métodos, si bien la desviación estándar es menor al emplear el método de umbralización.

Tabla 9. Comparación conjunta de los índices estadísticos de evaluación divididos por tipología de edificación para los métodos de detección de edificaciones de umbralización y de clasificación orientada a objetos.

		Urbano				Periurbano				Industrial			
		Umbral.		COO		Umbral.		COO		Umbral.		COO	
		$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$
Por áreas	FE	0,10	0,02	0,13	0,06	0,21	0,13	0,46	0,30	0,08	0,02	0,10	0,02
	FD	0,03	0,01	0,06	0,04	0,14	0,06	0,17	0,08	0,02	0	0,04	0
	PD	97,2	0,8	94,5	3,3	87,7	5,2	85,8	6,7	98	0,4	96,3	0,3
	PC	88,5	2	84,4	2,4	74,6	11,1	62,6	16,1	91,2	1,2	88,2	2
Por objetos	Cr	77,8	8,2	55,0	4,1	96,3	5,6	87,9	21,1	72,9	0,6	54,8	6,7
	Cm	100	0	98,8	2,1	97,6	2,3	96,0	3,9	100	0	98,2	2,5

## 5.2.4. Análisis de la inclusión de las sombras en la detección de edificaciones

En la Tabla 10 y la Tabla 11 comparan los resultados obtenidos antes y después de la inclusión de las sombras en el proceso de detección de edificaciones para los métodos de umbralización y de clasificación orientada a objetos, respectivamente. El empleo de las relaciones con las sombras tiene un efecto restrictivo, especialmente para el caso de la tipología de edificación periurbana. Este efecto implica, en la evaluación por áreas, una ligera reducción del factor de exceso y un pequeño aumento del factor de defecto. Este aumento es especialmente notable en las zonas periurbanas, debido a que las edificaciones tienen unas dimensiones tan reducidas que en ocasiones su sombra no se detecta correctamente, o bien es ocluida por la vegetación circundante (Figura 29). Los resultados obtenidos para las zonas urbanas e industriales no muestran apenas diferencias al incluir las relaciones con las sombras, debido al gran tamaño de las edificaciones presentes en estas zonas. Por lo general, el empleo de las sombras tiene una influencia mínima en el porcentaje de calidad de la detección. Esta influencia es más significativa en las zonas periurbanas, produciéndose una ligera reducción del porcentaje de calidad.

Los resultados estadísticos por objetos muestran un aumento del índice de corrección para todas las tipologías de edificación, lo que implica que el uso de las sombras elimina

una gran cantidad de los pequeños objetos erróneamente detectados como edificaciones y se comportaban como ruido en los resultados estadísticos, tal y como puede observarse en la Figura 30. Cabe destacar los valores de compleción obtenidos para entornos periurbanos donde, al incluir las relaciones con las sombras, el valor obtenido para el método de umbralización desciende por debajo del valor obtenido con el método de clasificación, debido a los problemas en la detección de sombras que ocurren en estas zonas.

Tabla 10. Comparación de los índices estadísticos de evaluación divididos por tipología de edificación para los el método de umbralización con y sin la información de las sombras.

		Urbano		Sombras		Periurbano		Sombras		Industrial		Sombras	
		No sombras		Sombras		No sombras		Sombras		No sombras		Sombras	
		$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$
Por áreas	FE	0,10	0,02	0,10	0,02	0,21	0,13	0,20	0,14	0,08	0,02	0,07	0,01
	FD	0,03	0,01	0,03	0,01	0,14	0,06	0,30	0,13	0,02	0	0,02	0
	PD	97,2	0,8	96,8	0,3	87,7	5,2	77,7	8,3	98	0,4	98	0,4
	PC	88,5	2	88,4	1,4	74,6	11,1	66,8	2,1	91,2	1,2	91,4	0,9
Por objetos	Cr	77,8	8,2	83,4	11,2	96,3	5,6	97,7	3,2	72,9	0,6	76,8	2,5
	Cm	100	0	99,1	1,5	97,6	2,3	82,5	11	100	0	100	0

Tabla 11. Comparación de los índices de evaluación divididos por tipología de edificación para los el método de clasificación orientada a objetos con y sin las información de las sombras.

		Urbano		Sombras		Periurbano		Sombras		Industrial		Sombras	
		No sombras		Sombras		No sombras		Sombras		No sombras		Sombras	
		$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$	$\mu$	$\sigma$
Por áreas	FE	0,13	0,06	0,12	0,06	0,46	0,30	0,45	0,31	0,10	0,02	0,09	0,01
	FD	0,06	0,04	0,06	0,04	0,17	0,08	0,20	0,08	0,04	0	0,04	0,00
	PD	94,5	3,3	94,5	3,3	85,8	6,7	83,2	7,1	96,3	0,3	96,3	0,3
	PC	84,4	2,4	84,6	2,5	62,6	16,1	61,5	16,2	88,2	2	88,7	1,3
Por objetos	Cr	55,0	4,1	59,3	1,0	87,9	21,1	92,7	21,0	54,8	6,7	57,3	3,2
	Cm	98,8	2,1	98,8	2,1	96,0	3,9	91,7	3,6	98,2	2,5	98,2	2,5




Figura 29. Detalles de la detección de edificaciones con y sin la información de las sombras en zonas periurbanas en Oliva (izquierda) y Moncada (derecha).




Figura 30. Detalles de la detección de edificaciones sin (izquierda) y con (derecha) la información de las sombras en una zona urbana en Sagunto.

## 5.2.5. Análisis de la influencia de la densidad de los datos LiDAR en la detección de edificaciones

El análisis de la influencia de la densidad de los datos LiDAR a la detección de los edificios se ha llevado a cabo en la zona de estudio de Oliva empleando la metodología basada en el establecimiento de umbrales, y el resultado de la evaluación estadística se muestra en la Tabla 12. En la evaluación a nivel de áreas de las zonas con tipología de edificación urbana, no se aprecia una diferencia significativa en los índices, obteniéndose valores comparables para todos ellos independientemente de la densidad de los datos LiDAR. Los resultados a nivel de objetos muestran un comportamiento similar, observándose un ligero aumento del índice de corrección al trabajar con la mayor densidad empleada (2 puntos/m<sup>2</sup>)

Tabla 12. Resultados estadísticos de la evaluación de la zona de Oliva variando la densidad (ptos/m<sup>2</sup>) de los datos LiDAR y empleando el método de umbralización.

		Urbano			Periurbano		
		0.5 ptos/m <sup>2</sup>	1 ptos/m <sup>2</sup>	2 ptos/m <sup>2</sup>	0.5 ptos/m <sup>2</sup>	1 ptos/m <sup>2</sup>	2 ptos/m <sup>2</sup>
Por áreas	FE	0,08	0,08	0,08	0,10	0,11	0,11
	FD	0,04	0,03	0,03	0,24	0,21	0,12
	PD	96,6	96,7	97,2	80,7	83,1	89,1
	PC	90,1	90	90,6	74,5	76,4	81,1
Por objetos	Cr	66,7	66,2	71,9	100	100	100
	Cm	100	100	100	100	99,3	99,3

En las zonas periurbanas, los resultados de evaluación a nivel de áreas muestran como el factor de defecto va reduciéndose notablemente a medida que la densidad de los datos LiDAR aumenta, mientras el factor de exceso apenas varía. Tal y como se muestra en la Figura 31, al disminuir la densidad de los datos LiDAR las edificaciones se detectan con un tamaño y superficie ligeramente menor al real. Esto tiene una influencia tanto en el porcentaje de detección, que se reduce de 89% a 80%, como en el porcentaje de calidad, que pasa de un valor de 81% a un 74%. Los resultados de evaluación a nivel de objetos no muestran diferencias significativas en las zonas con edificaciones de tipo suburbano.

Los resultados indican que la densidad de los datos LiDAR tiene una influencia prácticamente nula en zonas urbanas, mientras que esta afección es especialmente significativa para la detección de edificaciones de zonas suburbanas, que son las que presentan edificios de menor tamaño. Es estas zonas se produce una estimación por

defecto de la superficie edificada que esta relacionada con la densidad de los datos LiDAR empleados.




Figura 31. Detalle de la detección de edificaciones empleando diferentes densidades en los datos LiDAR en un área de tipología periurbana en la zona de estudio de Oliva.

## 5.3. Clasificación contextual en entornos urbanos

En esta sección se recogen los resultados de la clasificación por objetos de los usos del suelo en entornos urbanos considerando características de contexto. Con el objetivo de realizar un correcto análisis de las relaciones contextuales se eliminaron del estudio los objetos pertenecientes a vías de comunicación, tales como carreteras, caminos, calles, vías férreas, autopistas, etc., empleando su codificación en la cartografía catastral

### 5.3.1. Definición de clases

A partir de las clases definidas en la Sección 4.3.2., se seleccionaron muestras de entrenamiento de las tres zonas de estudio. Factores como la diferente naturaleza de las zonas de estudio y la disponibilidad restringida de datos provocó la eliminación puntual de ciertas clases. Así, en la zona de estudio de Oliva se eliminó la clase *nave*, y en Moncada las clases *edificio aislado* y *casco histórico*. Para el resto de clases se seleccionó un número de muestras suficientemente amplio que permitieran caracterizar de forma completa sus particularidades internas. El número exacto de muestras adquiridas por clase se presenta en la Tabla 13.

Tabla 13. Número de muestras (objetos) seleccionadas por cada clase y zona de estudio.

Clase	Zona de estudio		
	Moncada	Oliva	Sagunto
Casco histórico	-	294	170
Ensanche	196	115	244
Edificio aislado	-	99	103
Vivienda unifamiliar aislada	150	149	121
Vivienda unifamiliar adosada	60	107	161
Nave	108	-	115
Cultivos arbóreos	136	205	157
Terrenos arables y cultivados	320	160	238
<b>Total por zona de estudio</b>	<b>970</b>	<b>1129</b>	<b>1309</b>

### 5.3.2. Análisis de las características descriptivas

A partir de los valores de las 64 características descriptivas calculadas para cada objeto se estudió su relevancia en el proceso de clasificación, mediante la técnica de análisis discriminante lineal. Para ello, se trabajó sobre el grupo de muestras de entrenamiento u objetos, de las cuales se conocía tanto la clase a la que pertenecían como los valores de las 64 características descriptivas. Se presenta el análisis completo para el área de



estudio de Sagunto, debido a que se trata de la zona de estudio con mayor variabilidad paisajística de las tres disponibles, y de la única de la que se dispuso información de todas las clases definidas.

Con el fin de determinar las más significativas, el conjunto de características descriptivas se analizó utilizando los cuatros grupos definidos, los cuales fueron combinados sucesivamente. Los grupos definidos fueron:

- Grupo I: Características a nivel de objeto referidas a la información de la imagen: espectrales y de textura.
- Grupo II: Características a nivel de objeto referidas a la geometría y a la altura.
- Grupo III: Características del contexto interno del objeto o características de los intra-objetos.
- Grupo IV: Características del contexto externo del objeto o características del super-objeto.

En la Figura 32 se muestra gráficamente la fiabilidad global predicha al incluir sucesivamente características al modelo de clasificación discriminante para cada uno de los subgrupos de variables definidos.

La utilización de las características descriptivas a nivel de objeto referidas a la información de la imagen, son las que mayor fiabilidad global proporcionan, llegando a alcanzar un valor de prácticamente el 80% cuando la variable número 20 es incluida dentro del modelo discriminante. A partir de esta variable la inclusión de nuevas características no parece afectar a la fiabilidad predicha por el modelo. Se quedan fuera del modelo de clasificación, por no cumplir la tolerancia mínima las características: desviación típica de la banda espectral del verde y el descriptor de textura varianza.

Las características geométricas y de altura del objeto producen la menor de las fiabilidades globales, estabilizándose en torno al valor 50%.

Por su parte, la fiabilidad global de las características relativas al contexto interno del objeto se estabiliza en torno al 65%. Las características que no entran al modelo discriminante son la media y la desviación de la altura de la vegetación.

Las características relativas al contexto externo estabilizan la fiabilidad global en un valor en torno al 70%. Estas variables producen un rápido aumento de la fiabilidad al introducir las tres primeras variables al modelo discriminante. Estas características (porcentaje de superficie edificada, altura media y porcentaje de superficie cubierta por vegetación) referidas al super-objeto son e informan de diferentes aspectos de este, provocando un efecto sinérgico en la clasificación.

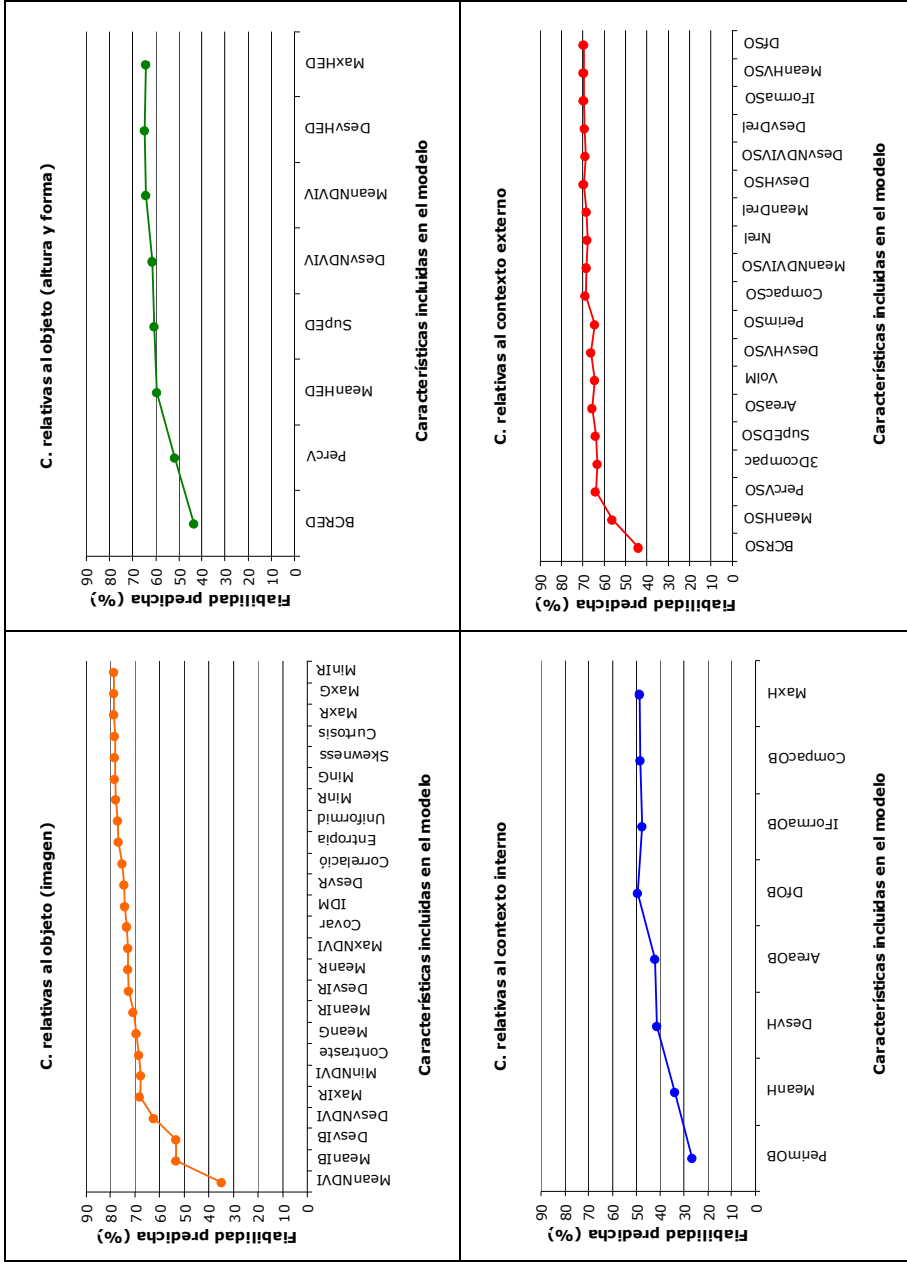


Figura 32. Fiabilidades globales predichas mediante análisis discriminante lineal al incluir sucesivamente variables al modelo de clasificación para los diferentes grupos de características descriptivas.

Además, resulta llamativo que las primeras variables discriminantes incluidas dentro del modelo para las características del contexto interno y para las del contexto externo son las referidas al porcentaje de superficie edificada (BCR). Esto pone de manifiesto la gran importancia de esta información en la discriminación de clases urbanas.

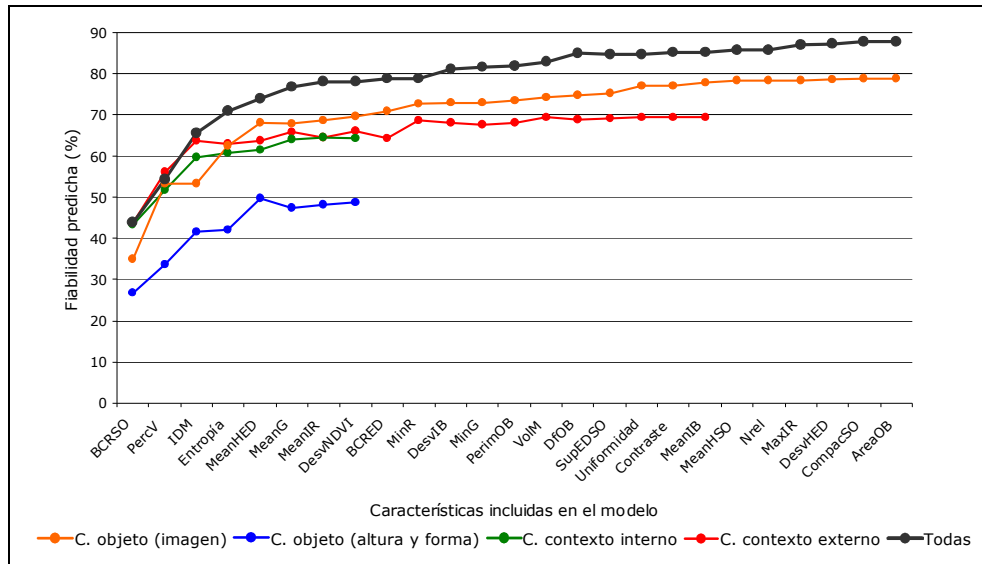


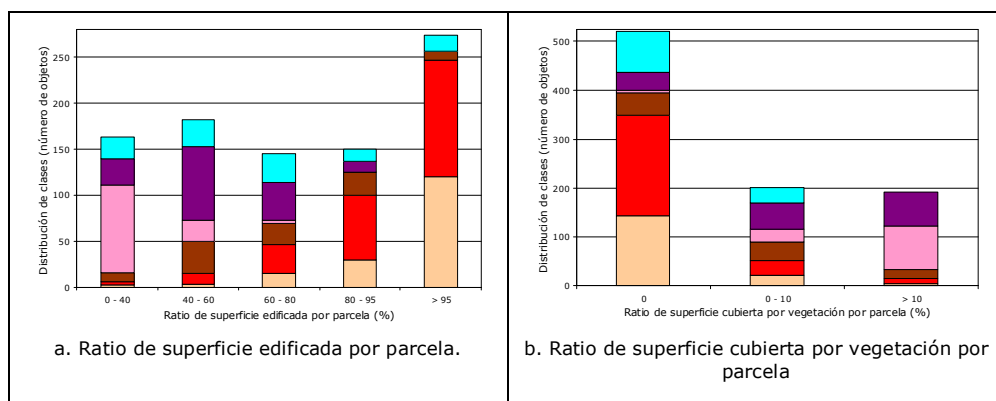
Figura 33. Fiabilidad predicha mediante análisis discriminante lineal para las primeras 25 variables al combinar todos los grupos, frente a las obtenidas empleando grupos de variables independientes. Los nombres de las variables corresponden a las características incluidas al combinar todos los grupos.

Al combinar las características descriptivas incluidas en los modelos discriminantes de los cuatro subgrupos definidos se observa un efecto sinérgico que se traduce en un aumento significativo de la fiabilidad global (ver Figura 33). A medida que se incluyen sucesivamente características en el modelo discriminante, se produce un aumento de la fiabilidad global. Esta fiabilidad presenta una tendencia ascendente que se estabiliza en torno al valor 85% con las últimas variables incluidas en el modelo. La característica de textura curtosis queda excluida del modelo discriminante debido a que no superaba el valor de tolerancia mínima fijado, por lo que el número final de características descriptivas empleadas en la clasificación fue 59.

Entre las características con más poder discriminante —las primeras incluidas en el modelo— aparecen variables pertenecientes a los cuatro grupos definidos. Así encontramos un amplio número de características del Grupo I: IDM, Entropía, MeanG, MeanIR, DesvNDVI, MinR, DesvIB, MinG; del Grupo II: PerimOB, DfOB; del Grupo III: PercV, MeanHED, BCRED; y del Grupo IV: BCRSO, VolM, SupEDSO. Esto pone de manifiesto la complementariedad de los grupos de características descriptivas definidos, además de posibilitar un aumento de la eficiencia de la clasificación, no solo en términos

de fiabilidad, sino también en términos de reducción del número de variables a utilizar, mediante el empleo de un grupo selecto de características con alto poder discriminante.

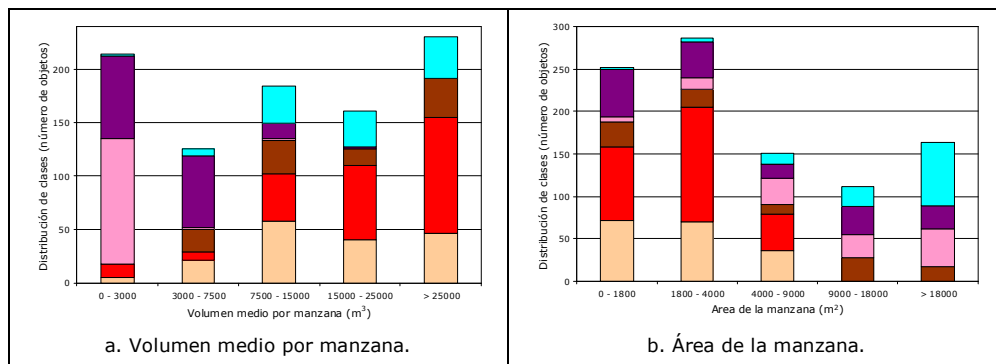
Los aspectos distintivos que permiten la discriminación de las diferentes clases urbanas, de manera análoga al proceso de interpretación humano, han sido expresados numéricamente a través de las características descriptivas definidas. En la Figura 34 y en la Figura 35 se muestran varios ejemplos de distribución de las clases urbanas en función de intervalos de valores de varias características descriptivas del contexto interno y externo, respectivamente. Así, analizando conjuntamente la distribución de clases por parcela de los ratios de superficie edificada y cubierta por vegetación (Figura 34.a y Figura 34.b), las clases *casco histórico* y *ensanche* destacan por presentar sus parcelas prácticamente edificadas en su totalidad, con una escasa cobertura vegetal. En cambio, las clases *vivienda unifamiliar adosada* y, especialmente, *vivienda unifamiliar aislada* presentan una menor superficie edificada y una mayor presencia de vegetación. La clase *nave* tiene una gran variabilidad en sus valores de superficie edificada, y unos valores bajos de superficie cubierta por vegetación.



Leyenda: Casco histórico Ensanche Edificio aislado V. unifamiliar aislada V. unifamiliar adosada Nave

Figura 34. Distribución de las clases urbanas con respecto a los intervalos de valores para dos características descriptivas del contexto interno.

A nivel de manzana se observan diferencias significativas entre las clases. Como se muestra en la Figura 35.a, la clase *vivienda unifamiliar aislada* presenta los valores más bajos de volumen medio por edificio, mientras que los edificios de la clase *vivienda unifamiliar adosada* alcanzan valores mayores. El resto de clases generalmente presentan elevados volúmenes. Analizando la superficie de las manzanas (Figura 35.b) se observa cómo las clases *ensanche* y *casco histórico* se sitúan en manzanas de pequeñas dimensiones, mientras que la clase *nave* aparece normalmente en las manzanas de mayor tamaño. Las clases suburbanas consideradas (*vivienda unifamiliar aislada* y *vivienda unifamiliar adosada*) se distribuyen en manzanas que presentan una gran variabilidad de tamaños.



Leyenda: Casco histórico Ensanche Edificio aislado V. unifamiliar aislada V. unifamiliar adosada Nave

Figura 35. Distribución de las clases urbanas con respecto a los intervalos de valores para dos características descriptivas del contexto externo.

### 5.3.3. Análisis de la clasificación

Las matrices de confusión completas para las distintas clasificaciones al emplear sucesivamente los conjuntos de características considerados se muestran de manera completa en el Anejo II. Ejemplos gráficos de los resultados de la clasificación se muestran en la Figura 36 de forma general para las tres zonas de estudio empleando todos los grupos de características. Por su parte, en la Figura 38, la Figura 40 y la Figura 43, se presentan composiciones cartográficas que muestran los resultados de manera más detallada.

En la Tabla 14 y en la Tabla 15 se presentan los índices estadísticos globales de la clasificación: índice de fiabilidad global de la clasificación e índice *kappa*. Analizando conjuntamente estos parámetros se observa cómo la incorporación de los diferentes grupos de características descriptivas produce una mejora de la precisión de la clasificación, cuyos valores más bajos se obtienen al emplear únicamente las características a nivel de objeto referidas a la imagen. La menor variación en los índices de fiabilidad se produce en la zona de estudio de Moncada, donde los valores de ambos índices oscilan entre 90 y 96%. Esto se debe a que el número de clases empleadas para realizar la clasificación (seis) es menor al del resto de zonas de estudio (siete en Oliva y ocho en Sagunto). Además, en la zona de estudio de Moncada no están definidas las clases *casco histórico*, que presenta un alto grado de confusión con *ensanche*, ni *edificio aislado*.

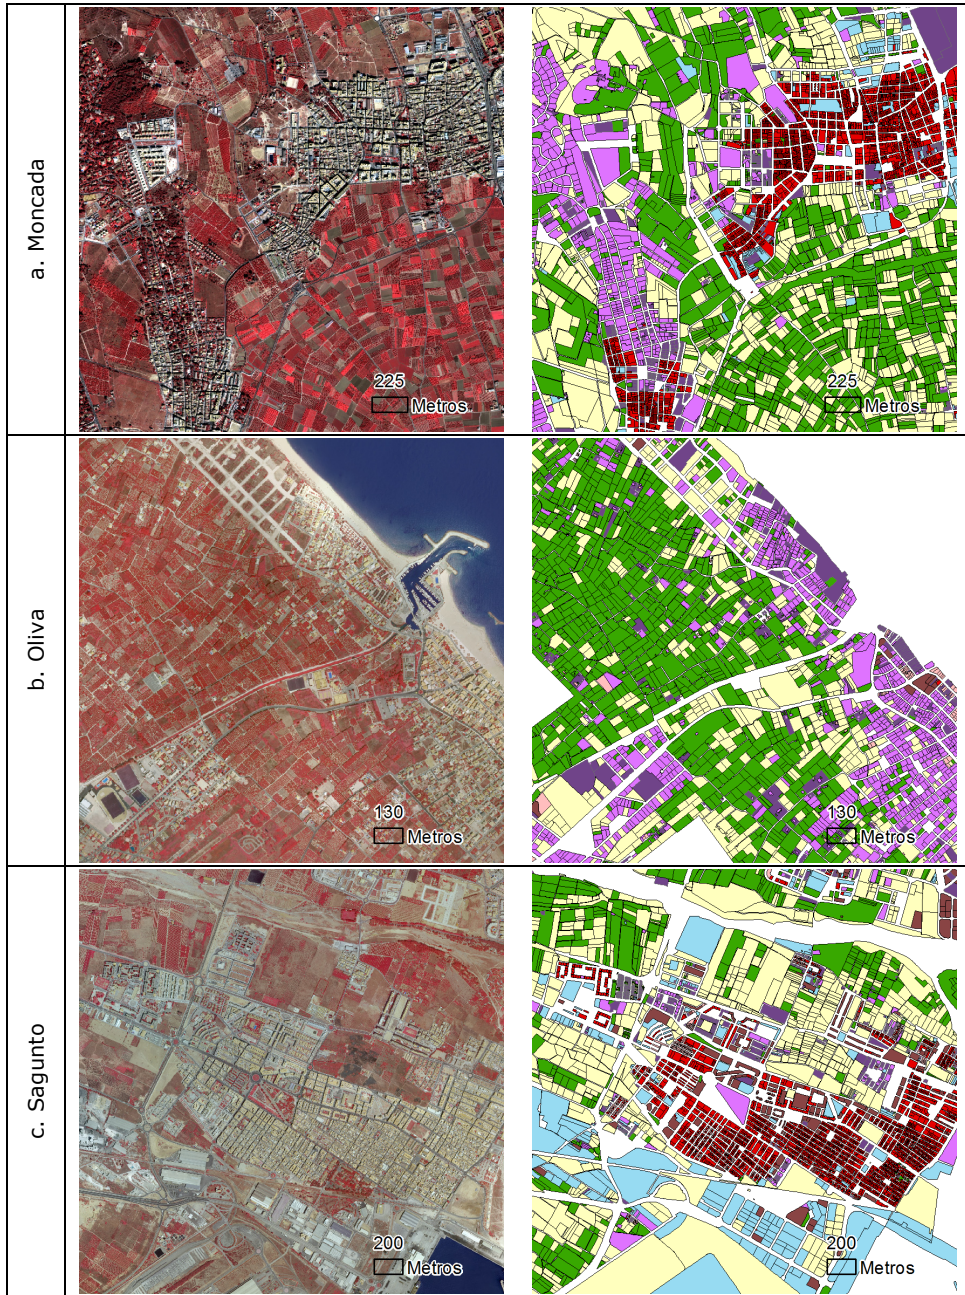


Figura 36. Vistas generales de la clasificación empleando todos los grupos de características descriptivas para las zonas de estudio.

Tabla 14. Valores de fiabilidad global al combinar progresivamente los diferentes grupos de características.

<b>Características</b>	<b>Moncada</b>	<b>Oliva</b>	<b>Sagunto</b>
Grupo I	89,8%	82,1%	76,4%
Grupos I + II	92,7%	89,1%	85,2%
Grupos I + II + III	93,8%	90,3%	88,9%
Grupos I + II + III + IV	95,8%	94,3%	93,0%

Los resultados destacan que la información tridimensional aporta una valiosa información para una precisa clasificación de los entornos urbanos. El principal aumento de los valores estadísticos se produce al añadir a las características derivadas de la imagen relativas al objeto (Grupo I), los descriptores de altura y forma (Grupo II). Al combinar todos los grupos de características descriptivas, añadiendo como último paso las características del contexto externo (Grupo IV) se observa un notable aumento de los valores de fiabilidad global e índice *kappa*. Aunque este es el último grupo de características introducidas en la clasificación, se produce un aumento de la fiabilidad considerable. Las características del contexto interno (Grupo III) producen pequeñas mejoras en los valores globales, salvo para la zona de estudio de Sagunto, que es la que presenta una mayor diversidad de clases urbanas, siendo su incremento superior al resto de zonas, comparable al producido al utilizar las características del contexto externo.

Tabla 15. Valores del índice kappa al combinar progresivamente los diferentes grupos de características.

<b>Características</b>	<b>Moncada</b>	<b>Oliva</b>	<b>Sagunto</b>
Grupo I	89,8%	78,4%	72,9%
Grupos I + II	91,4%	86,9%	82,7%
Grupos I + II + III	92,7%	88,3%	87,1%
Grupos I + II + III + IV	95,0%	93,2%	91,8%

En la Figura 37 se muestran gráficamente las fiabilidades del productor y del usuario obtenidas para cada una de las clases al incluir sucesivamente los conjuntos de características considerados. Análogamente a los valores globales de fiabilidad al utilizar las características a nivel de objeto referidas a la imagen se producen los valores más bajos. Al caracterizar los objetos-imagen con el resto de grupos de descriptores produce un continuo aumento en los índices de fiabilidad del productor y del usuario por clases.

Destacan especialmente los resultados de la clase *nave*, que obtiene los valores de fiabilidad más altos, tanto por defecto como por exceso, empleando un menor número de características. Esto se debe a la homogeneidad en las texturas y respuesta espectral de este tipo de construcciones, así como a sus acusadas diferencias morfológicas con respecto al resto de clases referentes a las edificaciones. Debido a los altos valores de fiabilidad obtenidos con las características a nivel de objeto referidas a la imagen, la consiguiente inclusión de grupos de descriptores tiene un menor impacto en estos índices, destacándose un ligero aumento en la fiabilidad del usuario al incluir las características del contexto externo en las dos zonas de estudio donde esta clase fue definida.



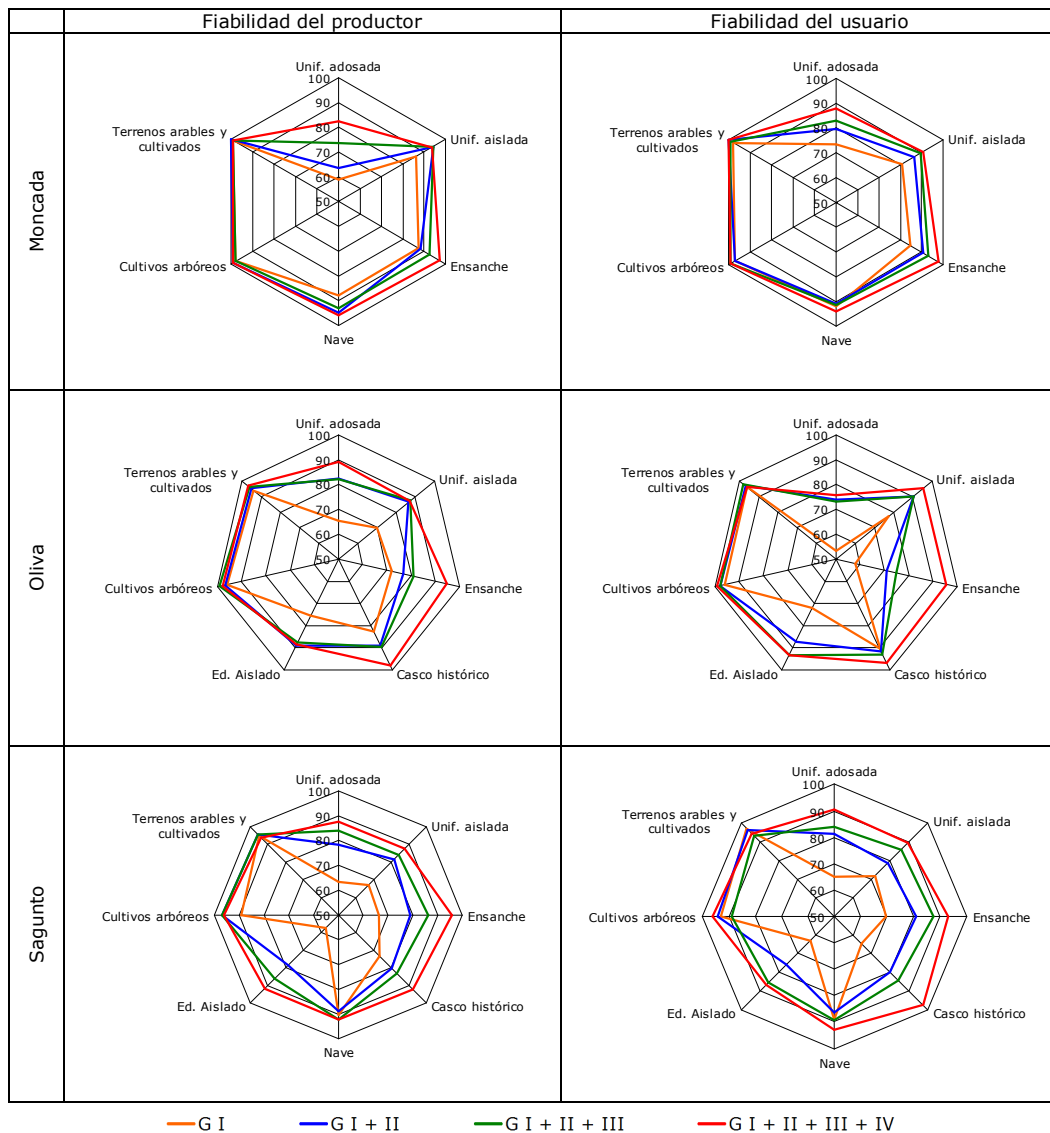


Figura 37. Fiabilidades del productor y del usuario de las clases definidas para los sucesivos conjuntos de características descriptivas incluidas en la clasificación. GI: características a nivel de objeto espectral y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo.

En la Figura 38 se presentan dos ejemplos gráficos del resultado de la clasificación en áreas industriales de Moncada y Sagunto. Analizando estos ejemplos, se puede observar que, pese a que todos los objetos situados en una misma manzana están descritos por las mismas características de contexto externo, la asignación de las clases se realiza correctamente para los diferentes usos. Esto también puede apreciarse en la Figura 43.a.



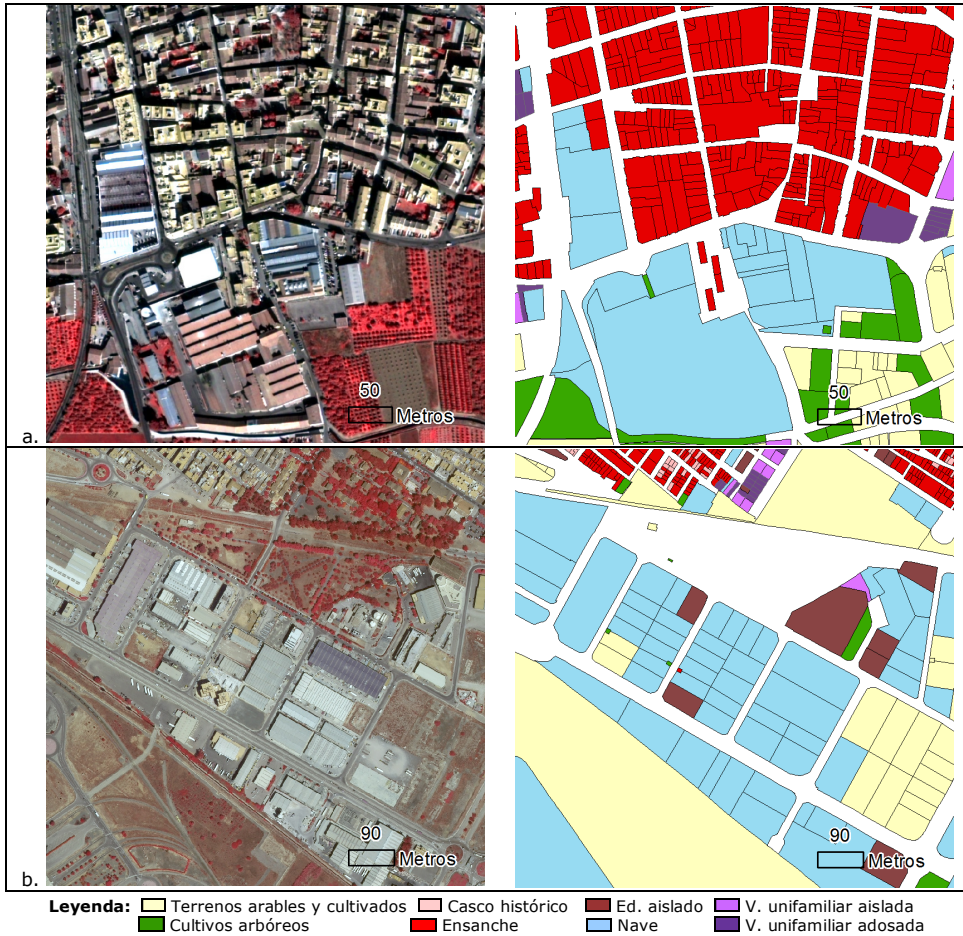


Figura 38. Ejemplos de la clasificación empleando todos los grupos de características descriptivas en zonas con presencia de industria (a. Moncada, b. Sagunto).

Los resultados muestran como la utilización de características descriptivas del contexto (principalmente el externo) de una parcela (objeto), produce una mejora significativa en la clasificación de clases entre las que se produce una mayor confusión. Estas son las clases que presentan unos valores iniciales en los índices de error mutuo: *vivienda unifamiliar aislada* y *vivienda unifamiliar adosada*, *edificio aislado* y *ensanche*, y *casco histórico* y *ensanche*.

Por lo general, la clase *vivienda unifamiliar adosada* obtiene unos valores de fiabilidad inferiores a los de la clase *vivienda unifamiliar aislada*, reduciendo esta diferencia a medida que se incluyen nuevos grupos de características en la clasificación, de manera que prácticamente se llegan a igualar los valores de fiabilidad de ambas clases. El índice de confusión mutuo entre estas clases (Figura 39) disminuye fuertemente al emplear información tridimensional y geométrica referida al objeto. Esto se debe a que la clase

*vivienda unifamiliar adosada* presenta construcciones con alturas superiores y parcelas menores que *vivienda unifamiliar aislada*. La posterior inclusión de información contextual prosigue con la reducción del índice de confusión entre ambas clases, hasta situarse por debajo de 0,10 para todas las zonas de estudio. Este es el valor de índice de error mutuo más alto que se produce al combinarse todos los grupos de características descriptivas, lo que indica la gran similitud existente entre ambas clases.

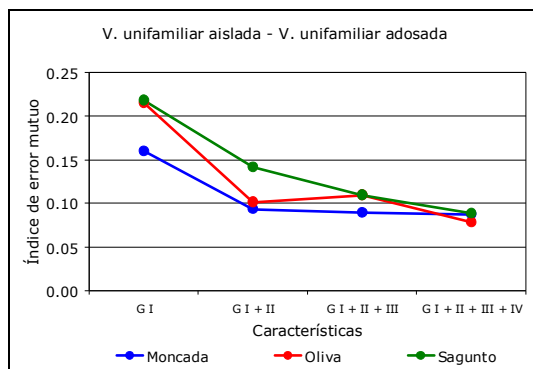


Figura 39. Evolución del valor del índice de error mutuo para las clases *vivienda unifamiliar adosada* y *vivienda unifamiliar aislada* al emplear progresivamente los diferentes grupos de características descriptivas. GI: características a nivel de objeto espectrales y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo.

En la Figura 40.a se presentan gráficamente varios ejemplos en los que se muestra la eficiencia en la separación entre ambas clases. Se observa, además cómo algunos objetos pertenecientes a las clases *vivienda unifamiliar adosada* y *vivienda unifamiliar aislada* en los que apenas aparece vegetación son incorrectamente asignados a la clase *Casco histórico* (Figura 40.b).

El empleo único de características a nivel de objeto referidas a la imagen ofrece resultados de fiabilidad bajos para la clase *edificio aislado*. Al trabajar con estas características se produce un considerable número de errores entre esta y la clase *ensanche*. Estas clases presentan una respuesta espectral similar, y requieren de una contextualización que permita su correcta clasificación. Tal y como se observa en los valores de del índice de error mutuo mostrados en la Figura 41, la utilización de información tridimensional y de contexto contribuye claramente a la reducción de la confusión entre ambas clases. Esta reducción es más relevante en el caso de la zona de estudio de Sagunto, donde se reduce el índice de error mutuo de 0,15, al emplear únicamente las características del Grupo I, hasta un valor inferior a 0,04 al combinarse todos los grupos de características descriptivas.




Figura 40. Ejemplos de la clasificación empleando todos los grupos de características descriptivas en zonas con predominio de viviendas unifamiliares (a. Moncada, b. Oliva).




Figura 41. Evolución del valor del índice de error mutuo para las clases *edificio aislado* y *ensanche*, al emplear progresivamente los diferentes grupos de características descriptivas. GI: características a nivel de objeto espectral y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo

Las clases *casco histórico* y *ensanche* presentan unos valores iniciales altos del índice de error mutuo (Figura 42). Las características tridimensionales y de forma a nivel de objeto contribuyen en gran parte a la reducción del valor de este índice, pero el descenso más significativo se produce al considerar las características referidas al contexto externo. Esto se debe a que ambas clases presentan características morfológicas referidas a las parcelas (objetos) similares, si bien las edificaciones de la clase *Ensanche* suelen presentar una altura superior. La principal diferencia radica en un nivel de contexto superior, definido por la manzana urbana (super-objeto). Así, los objetos pertenecientes a la clase *ensanche* se localizan en un entorno ordenado, producido por una planificación previa, mientras que los objetos característicos de la clase *casco histórico* aparecen en manzanas irregulares, fruto de un crecimiento esporádico de la ciudad a lo largo de la historia.

La inclusión en la clasificación de las características tridimensionales y del contexto interno consiguen situar el índice de error mutuo en un valor ligeramente superior a 0,10 para ambas zonas de estudio. La inclusión final de las características descriptivas de contexto externo producen una reducción del valor de este índice por debajo del 0,04 en la zona de estudio de Sagunto, y por debajo de 0,02 en la zona de estudio de Oliva.




Figura 42. Evolución del valor del índice de error mutuo para las clases *Casco histórico* y *Ensanche* al emplear progresivamente los diferentes grupos de características descriptivas. GI: características a nivel de objeto espectrales y de textura; GII: características a nivel de objeto de altura y forma; GIII: características del contexto interno; y GIV: características del contexto externo.

Gráficamente, se puede apreciar en la Figura 43.a y en la Figura 43.b cómo la zona de ensanche es, por lo general, satisfactoriamente diferenciada del casco histórico. Los errores en la clasificación de los objetos pertenecientes a la clase *casco histórico*, incorrectamente asignados a la clase *ensanche*, hacen referencia a edificaciones con unas dimensiones superiores a las esperadas, y corresponden, por lo general, con edificios de tipo religioso. En sentido contrario, algunas parcelas de la clase *ensanche* se asignan clasifican incorrectamente como pertenecientes a la clase *casco histórico*. Estos corresponden, por lo general, con edificaciones de pequeñas dimensiones que presentan características morfológicas similares a las de las parcelas situadas en áreas históricas de



la ciudad, pero situadas en un entorno ordenado como es en la zona del ensanche (Figura 43.c). Este tipo de errores podrían ser paliados aplicando un análisis posterior de objetos aislados entre otras clases.

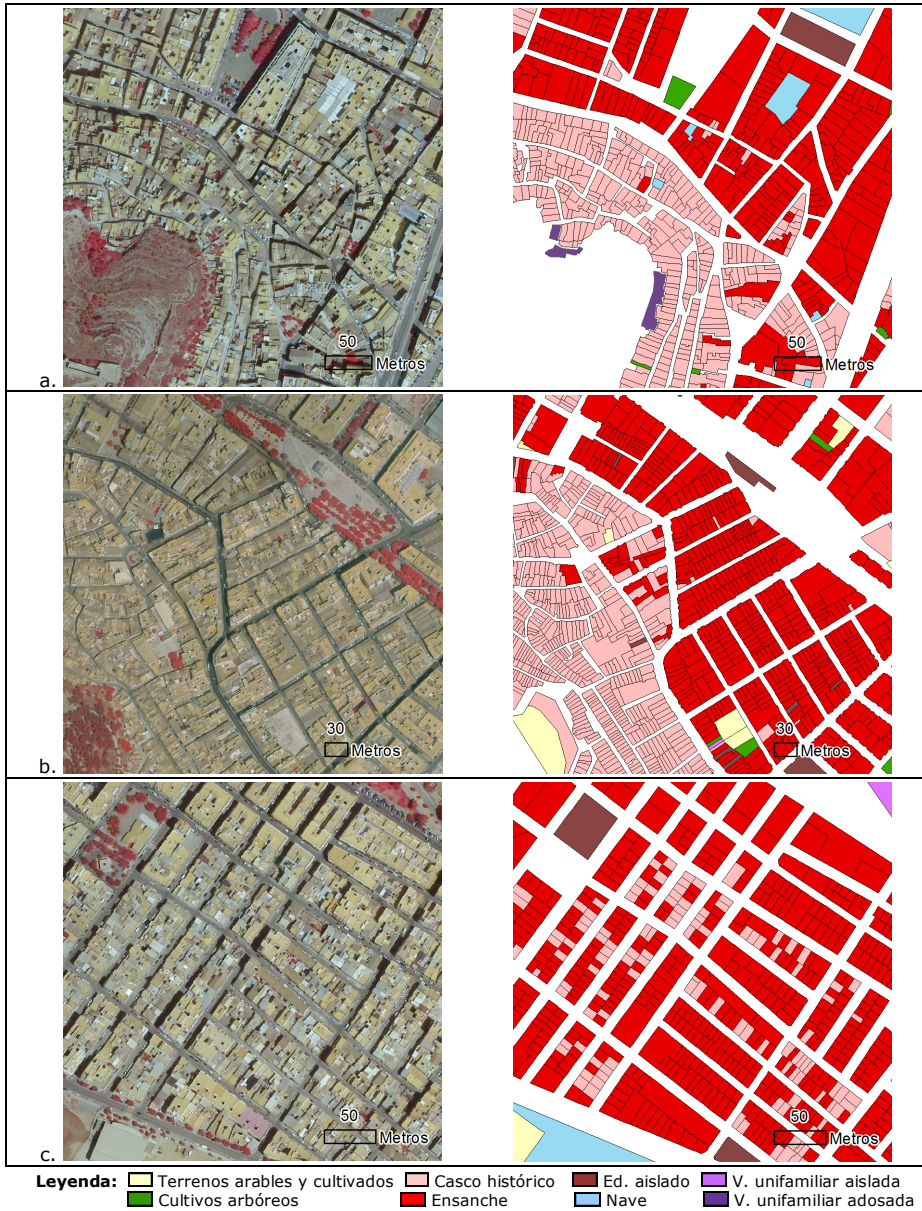


Figura 43. Ejemplos de la clasificación empleando todos los grupos de características descriptivas en áreas de transición entre el casco histórico y el ensanche (a. Sagunto, b. Oliva), y en una zona de ensanche (c. Sagunto).

## **5.4. Aplicabilidad del cálculo de parámetros para su inclusión en bases de datos de ocupación del territorio**

En esta sección se analiza la aplicabilidad de las técnicas propuestas para la automatización de la extracción de parámetros útiles en el proceso de creación o actualización de bases de datos de ocupación del territorio. Se ha trabajado utilizando la base de datos del SIOSE, cuya información ha sido confeccionada principalmente empleando técnicas de fotointerpretación. En áreas urbanas, esta base de datos geoespacial informa de la superficie edificada en cada polígono SIOSE y de la tipología mayoritaria de las edificaciones.

En primer lugar se ha realizado una completa evaluación estadística del cálculo del porcentaje de superficie edificada, comparando los resultados de metodologías automáticas de detección de edificaciones frente a la información contenida en la base de datos del SIOSE, obtenida empleando técnicas de estimación visual. A continuación, se analiza y discute la conveniencia del empleo de la metodología de clasificación automática para la asignación de las distintas tipologías de edificación de los polígonos SIOSE en entornos urbanos.

### **5.4.1. Aplicabilidad para la determinación de la superficie edificada**

La superficie edificada se ha determinado empleando la metodología de detección de edificaciones basada en el establecimiento de umbrales (Sección 4.2.1). La superficie de referencia se ha determinado mediante la delineación manual de los edificios.

En la Figura 44 se muestra de manera gráfica la relación entre la detección automática y la información contenida en la base de datos del SIOSE con respecto a las edificaciones de referencia para las superficies edificadas expresadas en porcentaje, para los polígonos SIOSE analizados en las tres zonas de estudio. Se presentan, además, los valores de los coeficientes de correlación lineal  $R^2$  entre la superficie de referencia y la detectada automáticamente, y entre la superficie de referencia y la contenida en la base de datos del SIOSE.

Los resultados obtenidos mediante detección automática muestran una fuerte correlación lineal con los datos de referencia, presentando valores de  $R^2$  superiores en los tres casos a 0,95. Por el contrario, los valores de correlación obtenidos al utilizar la información de

porcentaje de edificación contenida en la base de datos del SIOSE muestran unos valores de  $R^2$  más bajos que oscilan entre 0,73 y 0,82.

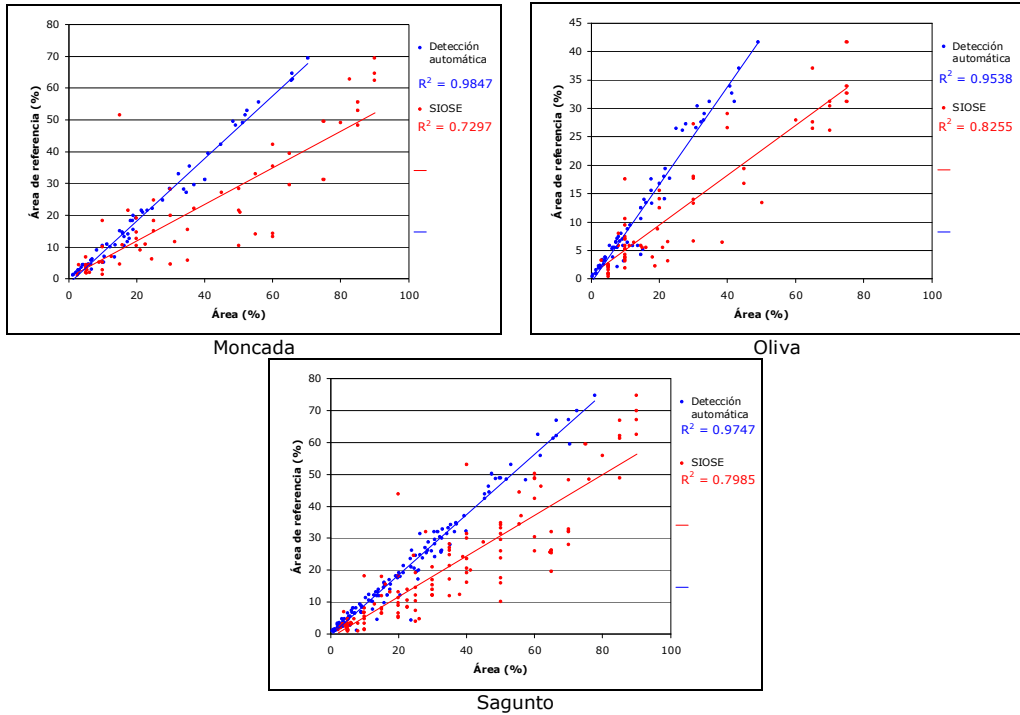


Figura 44. Relación entre el porcentaje de superficie edificada de referencia en cada polígono frente a la contenida en la base de datos del SIOSE y la detectada automáticamente en las tres áreas de estudio.

Los resultados del cálculo del error medio cuadrático (Tabla 16) corroboran la mayor precisión de la detección automática en la estimación del porcentaje de superficie edificada, frente a la estimación visual. Los errores medios cuadráticos obtenidos están en un rango del 3-4%, frente al 17,9-20,4% que presentan las superficies contenidas en la base de datos del SIOSE. Los valores del sesgo indican que la detección automática produce una leve estimación por exceso del porcentaje de la superficie edificada, mientras las superficies recogidas en la base de datos del SIOSE claramente sobreestiman el porcentaje de superficie edificada.

Analizando los gráficos de la relación entre superficie real y superficie estimada por ambos métodos según la tipología de edificación de los polígonos SIOSE (ver Figura 45) se observa cierta analogía en los resultados. Los valores del índice de correlación  $R^2$  obtenidos mediante técnicas de detección automáticas son del orden de 0,96 y 0,98 para las tipologías de edificación urbana e industrial. La tipología periurbana obtiene un valor menor, del orden de 0,92. Por su parte, la estimación de superficie edificada contenida

en la base de datos del SIOSE presenta su mayor valor de índice de regresión  $R^2$  para las zonas urbanas (0,78), seguido por las zonas periurbanas (0,70). Las zonas con edificaciones de tipología industrial presentan un índice de regresión  $R^2$  mucho menor (0,52), causado por la presencia de dos errores groseros. Sin estos el valor del índice de regresión sería del orden de 0,81.

Tabla 16. Valores de error medio cuadrático (EMC) y sesgo, agrupados por zonas de estudio, en la estimación de la superficie edificada mediante técnicas de detección automática y mediante técnicas de estimación visual empleadas en el SIOSE.

Zona	Detección automática		SIOSE	
	EMC	Sesgo	EMC	Sesgo
Moncada	3,0%	1,9%	19,3%	13,7%
Oliva	4,0%	2,8%	17,9%	13,2%
Sagunto	3,5%	1,8%	17,9%	13,2%

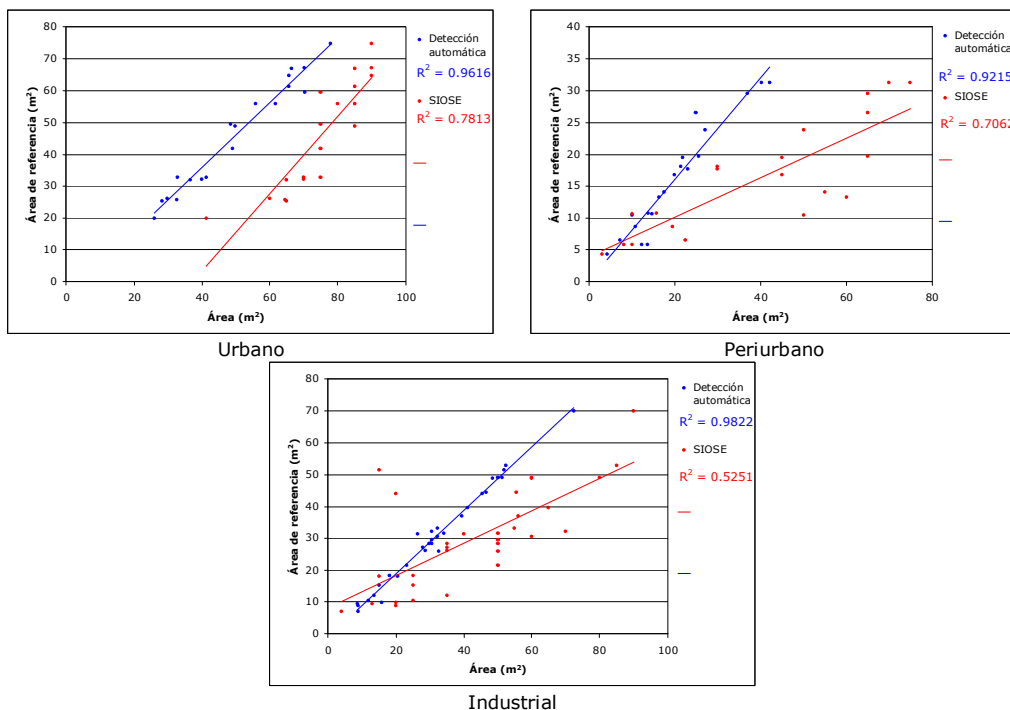


Figura 45. Relación entre el porcentaje de superficie edificada de referencia en cada polígono frente a la contenida en la base de datos del SIOSE y la detectada automáticamente para las tres tipologías de edificaciones consideradas.



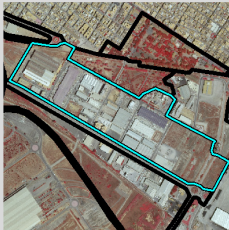


Mientras la metodología basada en la detección automática presenta una cierta homogeneidad en los valores de error medio cuadrático para las diferentes tipologías analizadas (entre 2,4% y 5,1%), los errores obtenidos para el porcentaje de superficie edificada contenido en el SIOSE son más dispares y presentan unos valores mucho más altos, de entre el 20 y el 30% (ver Tabla 17). En ambos casos, son las zonas industriales donde el la superficie edificada se calcula con una mayor precisión, mientras que las tipologías urbanas y periurbanas presentan unos errores superiores.

Tabla 17. Valores de error medio cuadrático (EMC) y sesgo, agrupados por tipología de edificación, en la estimación de la superficie edificada mediante técnicas de detección automáticas y mediante técnicas de estimación visual empleadas en el SIOSE.

Tipología	Detección automática		SIOSE	
	EMC	Sesgo	EMC	Sesgo
<b>Urbano</b>	5,1%	3,9%	30,3%	29,1%
<b>Periurbano</b>	5,1%	4,0%	28,7%	23,5%
<b>Industrial</b>	2,4%	1,3%	20,1%	13,2%

En la Tabla 18 se muestran tres ejemplos de polígonos que presentan importantes errores por exceso en los datos del SIOSE, junto con los valores de superficie edificada: de referencia, recogida en la base de datos del SIOSE, y detectada automáticamente mediante técnicas de procesamiento digital de imágenes. Analizando estos resultados, se observa cómo en ocasiones la superficie edificada descrita en la base de datos del SIOSE duplica e incluso triplica a la de referencia. Por el contrario, los valores obtenidos mediante la detección automática de edificaciones presentan unos valores más próximos al porcentaje de superficie edificada real.

Tabla 18. Ejemplos de determinación del porcentaje de superficie edificada en la zona de Sagunto, en los que se presentan polígonos con importantes errores recogidos en la base de datos del SIOSE.

			
<b>Referencia</b>	31%	26%	20%
<b>SIOSE</b>	60%	65%	65%
<b>Det. automática</b>	32%	31%	25%

Globalmente, los resultados indican que los métodos de percepción visual utilizados para la estimación de la superficie edificada en la generación de la base de datos del SIOSE presentan una baja eficiencia, con una patente sobrestimación de la superficie edificada.

Ésta se produce de manera análoga en las tres zonas de estudio, y tiene especial repercusión en zonas urbanas y suburbanas. Esto se debe a que la estimación de la superficie basada en la percepción visual es un método subjetivo, en el que diferentes factores (vegetación, sombras, agrupación de los edificios) pueden inducir a error y negativamente afectar a la capacidad perceptiva del fotointérprete. Por el contrario, los métodos basados en la detección automática son objetivos, y su fiabilidad dependerá del ajuste de los parámetros de cálculo y de la calidad de los datos geográficos empleados.

### **5.4.2. Aplicabilidad para la determinación de las tipologías de edificación**

Las técnicas automáticas de clasificación de imágenes pueden aportar datos útiles a las bases de datos de ocupación del territorio, de modo que se automaticen en parte su proceso de construcción o actualización. En esta sección se compara la información que extraída del análisis de la base de datos del SIOSE, frente a la derivada de las técnicas automáticas de clasificación de los usos del suelo. El cálculo de la superficie total de cada tipología de edificación obtenida por técnicas automáticas se ha realizado sumando la superficie de las edificaciones presentes dentro de parcelas a las que se han asignado una misma clase. Esta información se ha comparado con la contenida en la base de datos del SIOSE.

A pesar de que la base de datos del SIOSE indica únicamente la tipología de edificación mayoritaria de un polígono, en el caso del *mosaico* se produce una excepción. El *mosaico* se define como una asociación de *coberturas* (usos del suelo) cuya distribución geométrica y separación entre ellas es claramente perceptible. En la práctica, en zonas urbanas los *mosaicos* contienen agrupaciones de polígonos de superficie inferior a la mínima, y estos aparecen generalmente aislados de los núcleos de población, rodeados por terrenos agrícolas.

En la Figura 46 se muestra un ejemplo de polígono SIOSE y su correspondiente resultado del proceso de clasificación de imágenes a nivel de parcelas, coloreadas según la clase asignada. Además, se presentan, mediante un entramado, las edificaciones automáticamente detectadas. Concretamente, este ejemplo es un polígono de tipo *mosaico* en el que la base de datos distingue los usos urbano e industrial, y donde se detalla la superficie de dos tipologías de edificación: *edificio entre medianeras* y *nave*, correspondientes a cada uno de estos usos. Al combinar las técnicas de detección de edificaciones y clasificación automática orientada a objetos se llegan a distinguir hasta cuatro tipologías de edificación diferentes. De esta forma se permite detallar de manera más profunda la superficie ocupada por todas las clases de edificación presentes en un polígono SIOSE.

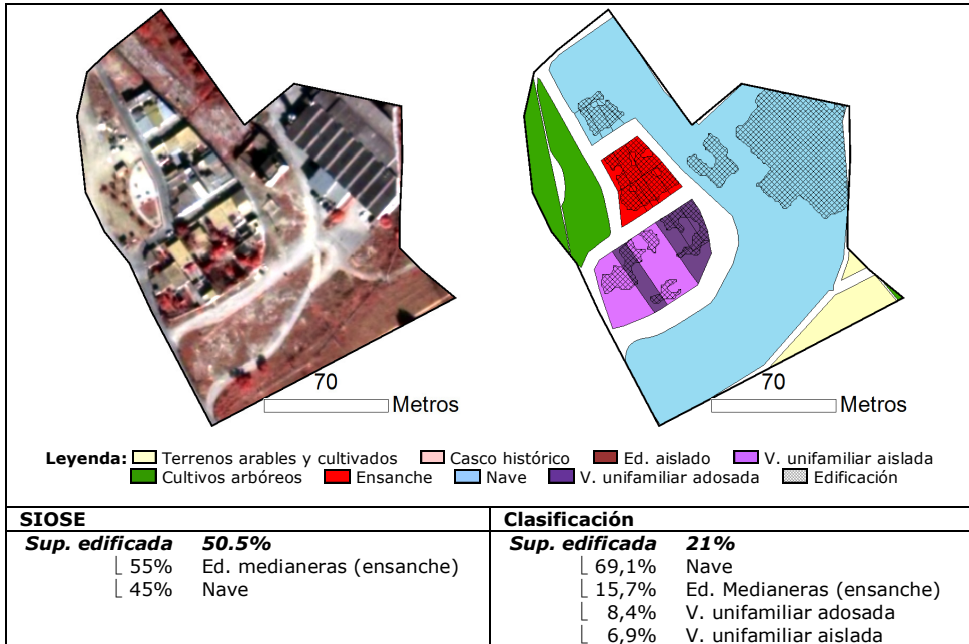


Figura 46. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono de tipo *mosaico*, en el que se distinguen los usos urbano e industrial.

Pese a que el *mosaico* distingue entre varios tipos de edificación, por lo general, la mayor parte de los polígonos SIOSE dibujados en entornos urbanos sólo informan de una tipología, con la consecuente pérdida de detalle. Así, por ejemplo, en la Figura 47 se muestra un polígono SIOSE característico de una zona urbana de ensanche consolidado. Estas zonas se componen principalmente de *edificios en medianeras*, pero frecuentemente conviven con otras tipologías de edificación, tales como *edificio aislado*, viviendas de tipo unifamiliar, o incluso *naves* con uso industrial. El empleo de técnicas automáticas de clasificación permite un desglose más detallado de las tipologías, lo que supone una descripción más completa del polígono.

La coexistencia de *edificios entre medianeras* de tipo *ensanche* y *casco*, y el hecho de que el polígono contiguo pertenezca a la categoría *casco*, nos apunta que la geometría del polígono SIOSE analizado podría ser redefinida de acuerdo con los resultados de la clasificación, de modo que se consiguiera que las edificaciones de cada polígono presenten una mayor homogeneidad en sus tipologías. Así, el uso de las técnicas automáticas facilitaría una delimitación de los polígonos SIOSE automática y con mayor objetividad que las técnicas basadas en percepción visual en entornos de difícil discriminación, como el caso de los detalles presentados en la Figura 48.a y Figura 48.b, pertenecientes ambos a los límites del polígono SIOSE mostrado en la Figura 47.

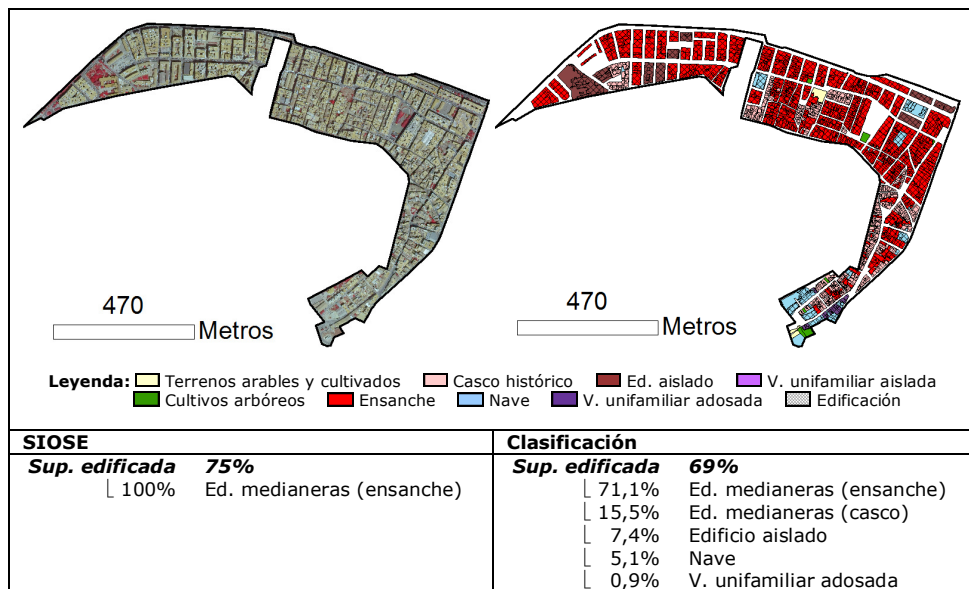


Figura 47. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono urbano de ensanche.



Figura 48. Ejemplo de zonas donde la clasificación automática puede ayudar en la definición de los polígonos SIOSE (cuyos límites están representados por líneas de color negro).

En las zonas de ensanche de más reciente construcción presentan, por lo general, una mayor variabilidad en las tipologías de edificación. En la Figura 49 se muestra un ejemplo de un polígono SIOSE característico de un área de crecimiento urbano actual. La base de datos del SIOSE indica para este polígono que la tipología predominante de edificación es la *vivienda unifamiliar adosada*, lo que coincide con la tipología mayoritaria determinada mediante clasificación automática de imágenes. La principal diferencia radica en que con esta metodología se puede especificar que la ocupación de las edificaciones de tipo *vivienda unifamiliar adosada* ronda el 40% de la superficie y está seguida de cerca por la ocupación de la tipología de edificación *edificio aislado*, próxima al 30%. Además, existe una presencia menor de otras tipologías. En casos como este, la caracterización mediante una única tipología de construcción de los polígonos SIOSE conlleva una importante pérdida de información.

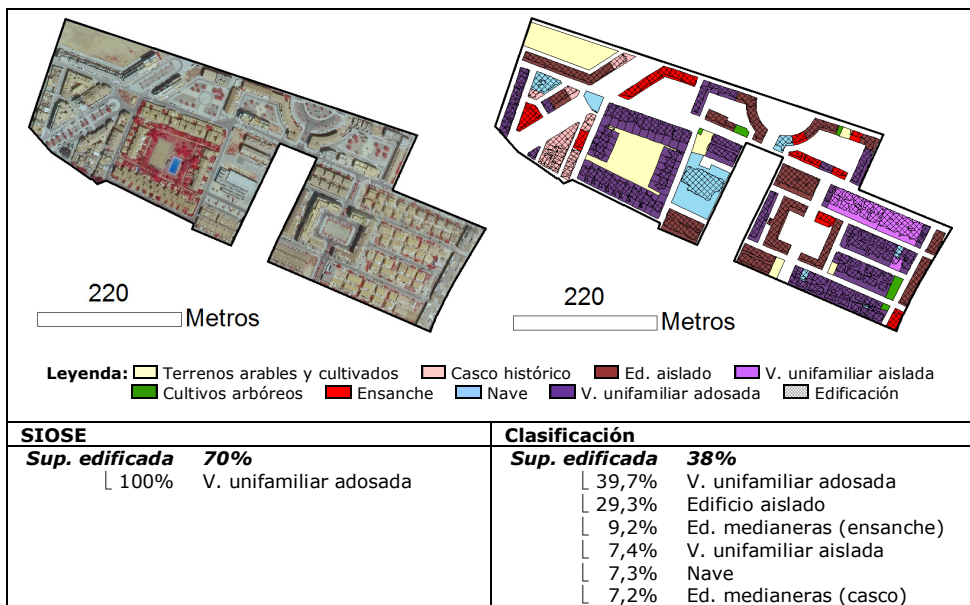


Figura 49. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono urbano de ensanche.

En las zonas periurbanas son extremadamente frecuentes las tipologías de vivienda unifamiliar. Por lo general, las áreas periurbanas más antiguas están compuestas principalmente por edificaciones del tipo *vivienda unifamiliar aislada*, mientras que las de más reciente construcción están formadas en su mayoría por edificaciones de tipo *vivienda unifamiliar adosada*. En la práctica ambas tipologías de edificación pueden hallarse conjuntamente.

En la Figura 50 se presenta un polígono SIOSE localizado en una zona periurbana residencial de viviendas unifamiliares. Es frecuente que este tipo de polígonos presenten huecos en su interior que corresponden a diferentes dotaciones, con usos educativos,

culturales, comerciales, etc. En primer lugar, destaca las diferencia entre el porcentaje de superficie edificada total recogida por la base de datos del SIOSE, frente a la obtenida empleando técnicas automáticas de detección. Con respecto a las tipologías de edificación, la base de datos indica que la principal es la *vivienda unifamiliar aislada*, al igual que el resultado de la clasificación automática de imágenes, que indica que el 80% de las edificaciones son de esta tipología. Además, cabe destacar la importante presencia de edificaciones – superior al 20% de la superficie edificada – de tipo *vivienda unifamiliar adosada*, distribuidas de modo disperso a lo largo del polígono SIOSE.

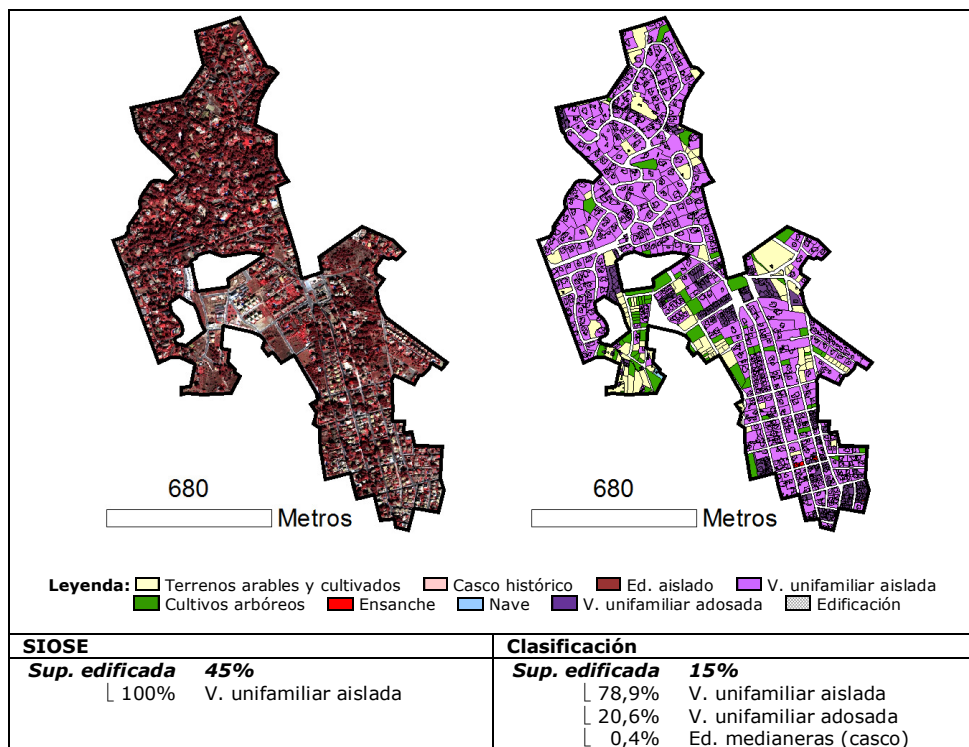


Figura 50. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono residencial periurbano con edificaciones de tipología unifamiliar.

Las áreas industriales se sitúan normalmente separadas de las áreas residenciales, por lo que los polígonos SIOSE definidos en estas zonas contienen prácticamente en su totalidad edificios de la tipología *nave*. Pese a esto, en ocasiones pueden aparecer otras tipologías de edificación.

Las áreas industriales más antiguas son tradicionalmente entornos que cuentan con una baja planificación, y que, con frecuencia, se presentan físicamente unidos a zonas residenciales. En ocasiones, los polígonos SIOSE que engloban estas zonas industriales muestran una variedad tanto de tipologías de edificación, como de sus usos. Este caso



ocurre en el polígono SIOSE mostrado en la Figura 51, donde la base de datos indica que la edificación principal pertenece a la clase *nave*. El resultado de la clasificación automática corrobora este dato, asignándole a esta tipología un porcentaje del 97,4% de la superficie edificada. El 2,4% restante pertenece a la clase *edificio entre medianeras*, y representa a tres bloques de viviendas enclavadas en esta zona industrial. Ciertamente, éste es un porcentaje muy bajo, pero se trata de una información importante a considerar, puesto que puede tratarse como un indicador para la redefinición de la geometría del polígono SIOSE.




Figura 51. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono industrial en el que aparecen edificaciones residenciales.

Los polígonos industriales de más reciente construcción presentan un nivel de planificación muy superior, y por lo tanto, resulta más improbable la presencia de usos residenciales. Por el contrario, es frecuente que en estas zonas aparezcan modernas construcciones de tipo *edificio aislado* con uso comercial o de oficinas. El polígono SIOSE presentado en la Figura 52 es un ejemplo claro de este tipo de áreas industriales planificadas. La base de datos del SIOSE indica que la tipología de edificación principal pertenece a la clase *nave*. Al analizar el resultado de la detección de edificaciones y clasificación automática, es posible detallar que casi el 95% de la superficie edificada pertenece a la tipología *nave*, mientras que la superficie edificada restante corresponde con edificaciones de tipo *edificio aislado*, correspondientes a edificios ocupados por oficinas.

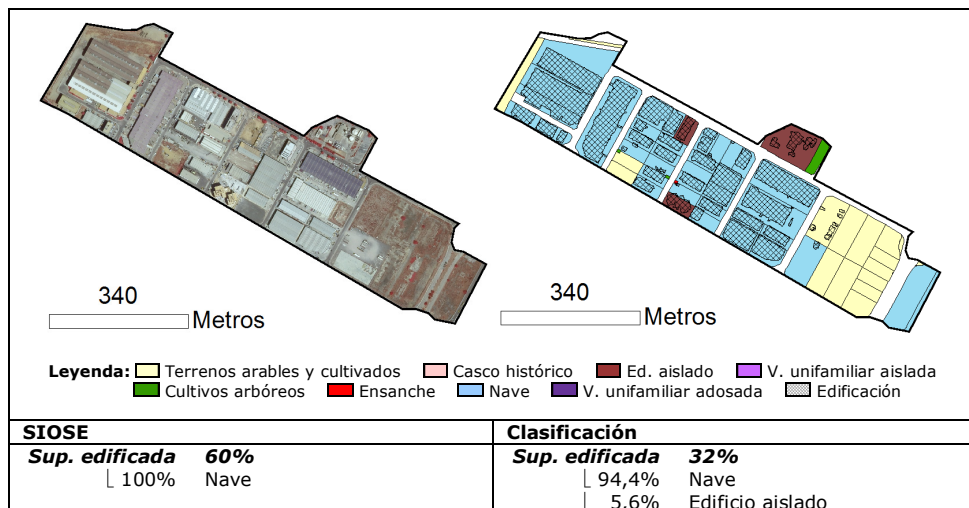


Figura 52. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono industrial con presencia de edificaciones comerciales de tipo *edificio aislado*.

Las zonas costeras de reciente construcción presentan urbanizaciones residenciales con cierta homogeneidad en la disposición espacial de las diferentes tipologías de sus edificaciones, que pertenecen principalmente las clases *edificio aislado* (formado por los edificios y torres de apartamentos), y viviendas de tipo unifamiliar, tanto aisladas como adosadas. La Figura 53 muestra un polígono SIOSE de un área urbana situada en la primera línea de costa. La tipología principal de edificación es *edificio aislado*. Si atendemos a los resultados de la clasificación automática, podemos especificar que aproximadamente el 50% de la superficie edificada pertenece a esta clase, mientras que las construcciones de tipo *vivienda unifamiliar aislada* y *vivienda unifamiliar adosada* ocupan el 28 y 15%, respectivamente.

El polígono que se presenta en la Figura 54 también corresponde con una zona urbana de construcción muy reciente situada en la franja costera, donde la principal tipología de edificación pertenece a la clase vivienda *unifamiliar adosada*. Las técnicas de clasificación de usos del suelo complementan y completan esta información concretando que esta clase ocupa un 80%, y que aproximadamente el 20% restante corresponde con construcciones de tipo *edificio aislado*.

Los ejemplos presentados muestran el potencial de las metodologías automáticas de detección de edificios y clasificación de los usos del suelo empleando datos adquiridos mediante técnicas de teledetección para la estimación y cálculo de parámetros útiles para la creación/actualización de bases de datos geo-espaciales de ocupación de usos del suelo. Los resultados muestran una mayor fiabilidad y nivel de detalle que los obtenidos al emplear métodos de estimación visual, lo que permite caracterizar de manera objetiva y más profunda las diferentes tipologías de edificación en áreas urbanas y periurbanas.



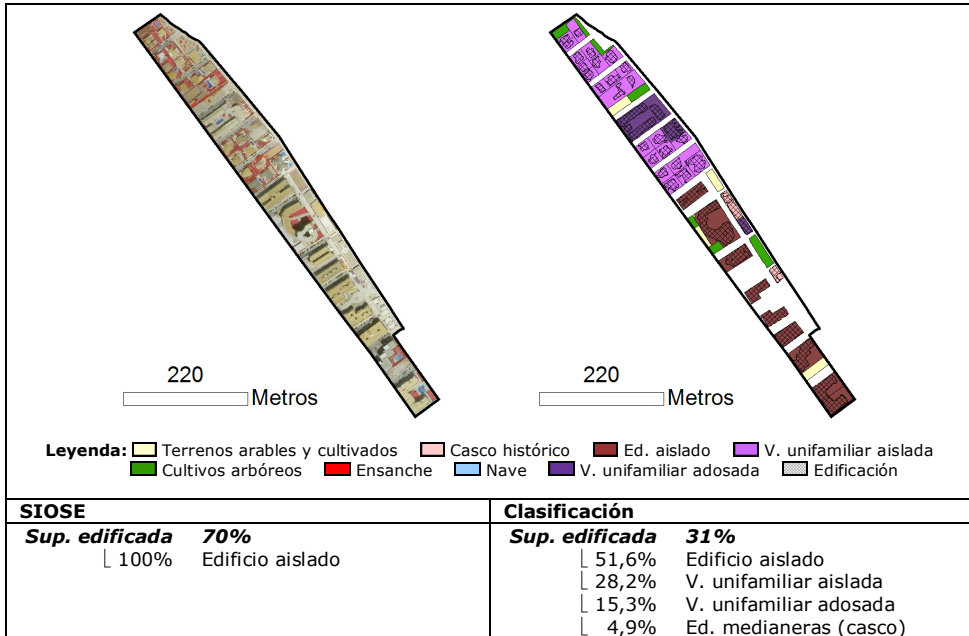


Figura 53. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono residencial costero.

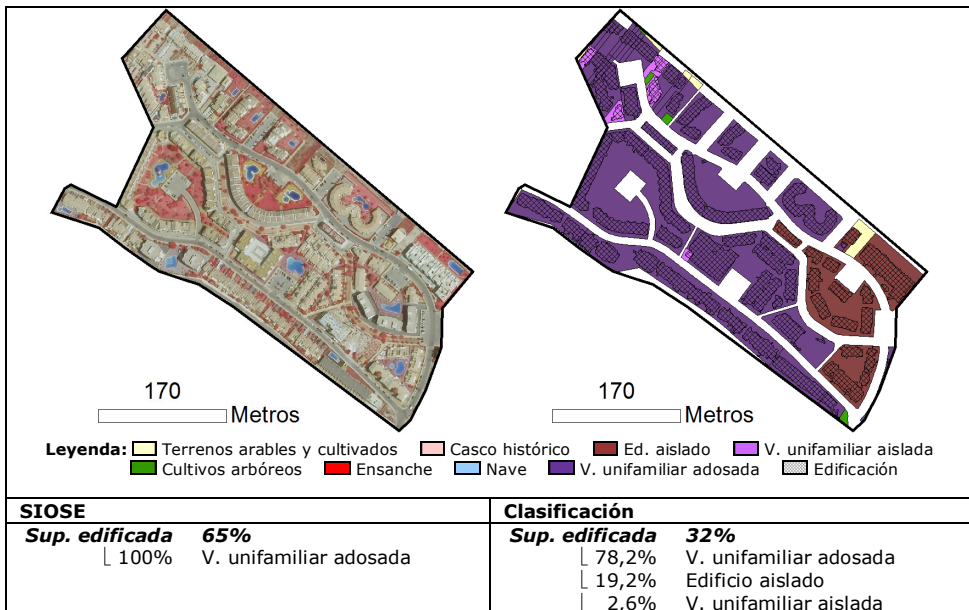


Figura 54. Imagen, resultado de la clasificación y porcentaje de superficie edificada descrita en el SIOSE y estimada automáticamente (total y por tipologías) de un polígono residencial costero.



## Capítulo VI

---

# CONCLUSIONES Y LÍNEAS FUTURAS DE INVESTIGACIÓN

---

### 6.1. Conclusiones

Debido a la naturaleza dinámica de las áreas urbanas, la información cartográfica referida a estas queda desfasada rápidamente. Desde el punto de vista del planeamiento urbano y territorial, el conocimiento actualizado y preciso de las evolución de los usos y ocupación del suelo en las ciudades y áreas de influencia es necesario para diferentes propósitos, tales como la predicción de las tendencias demográficas, el diseño y planificación de infraestructuras de transportes y comunicación, la zonificación de los barrios, análisis paisajísticos, de riesgo o medioambientales, la asignación de recursos y planeamiento de servicios sociales, educativos, culturales, redes de suministro de aguas, energía, gestión de residuos o los servicios de protección y actuación en emergencias. Esto confiere una gran importancia a la disponibilidad de información cartográfica detallada y actualizada de las áreas urbanas. Los sistemas y equipos de teledetección permiten adquirir masivamente un gran volumen de datos que requieren de procesos y métodos que permitan la extracción de información útil para la gestión y ordenación de manera automática, precisa, sistemática, y eficiente.

Dentro de este marco, esta tesis se ha centrado específicamente en el desarrollo de metodologías de detección automática de edificios a partir de imágenes aéreas de alta resolución y datos LiDAR, cuya disponibilidad aumenta de forma progresiva a través de

diversos programas nacionales y locales, y en su incorporación, mediante técnicas de análisis de imágenes orientadas a objeto, a la clasificación automática de los usos del suelo en entornos urbanos, con el propósito de contribuir a mejorar la eficiencia en las tareas de actualización de bases de datos de ocupación y uso del suelo. Se han adaptado y evaluado dos metodologías de detección y localización de edificaciones empleando imágenes de alta resolución y datos LiDAR. La primera está basada en el establecimiento de umbrales en alturas y vegetación, mientras que la segunda se fundamenta en la clasificación orientada a objetos. Además, se ha analizado el efecto de la inclusión de las relaciones de adyacencia de las edificaciones con las sombras en la detección de edificaciones.

Los resultados de la evaluación de estas técnicas automáticas muestran que la metodología de detección de edificaciones basada en el establecimiento de umbrales sencillos en altura y vegetación proporciona, en general, mayor fiabilidad tanto en la delimitación de las edificaciones (nivel de áreas) como en la localización de los edificios (nivel de objetos) que la metodología basada en clasificación orientada a objetos.

El método de detección orientada a objetos presenta una complejidad técnica mayor, requiriendo la selección de un gran número de parámetros como el método de segmentación, el factor de escala, la definición de clases, la selección de muestras de aprendizaje, el cálculo y selección de características descriptivas, y la selección de un algoritmo de clasificación.

La tipología de edificación influye en gran medida en la precisión de la detección de las edificaciones. Así, las zonas urbanas e industriales muestran indicadores de calidad más favorables que las zonas periurbanas, debido a que estas están caracterizadas por pequeñas edificaciones de escasa altura, y por presencia de vegetación, que frecuentemente produce la oclusión de las construcciones.

La utilización de las relaciones con las sombras en el proceso de detección de las edificaciones tiene una mayor influencia en los valores de evaluación a nivel de objetos, siendo útiles para eliminar pequeños elementos detectados erróneamente como edificios, afectando negativamente a los índices de calidad. A nivel de áreas, su utilización implica una ligera reducción del factor de exceso, a la vez que un ligero aumento del factor de defecto. Por ello, su uso podría estar indicado para detectar edificaciones, pero en menor medida cuando se desee cuantificar la superficie o localizar de forma precisa los edificios.

El empleo de datos LiDAR con densidades bajas produce estimaciones por defecto de la superficie edificada. Este efecto es especialmente acusado en las áreas periurbanas, en las que predominan edificaciones de menor tamaño. En las áreas urbanas el hecho de utilizar datos LiDAR de baja densidad tiene menor influencia, no llegando a apreciarse una degradación significativa de los indicadores de calidad de la detección.

Se ha empleado una metodología orientada a objetos para el análisis y la clasificación de las áreas urbanas. La segmentación se ha realizado empleando los límites cartográficos de las parcelas catastrales, que representan las unidades administrativas de propiedad

de suelo diferenciadas en una zona urbana. Esto facilita que los objetos considerados posean un significado real, posibilitando una relación directa del resultado de la clasificación con las bases de datos geo-espaciales que proporcionan los límites cartográficos.

El empleo del enfoque orientado a objetos permite un análisis más pormenorizado de los datos espaciales en zonas urbanas, posibilitando el cálculo y la extracción de un mayor número de características descriptivas. Las características descriptivas calculadas cuantifican numéricamente las propiedades de los objetos. Se han diseñado características descriptivas del objeto (parcela) considerando tres niveles: el propio objeto, su contexto interno y su contexto externo. Las características a nivel de objeto describen sus propiedades espectrales, de textura, de altura, de geometría y de forma. Las características del contexto interno del objeto describen las diferentes coberturas internas de la parcela, centrándose principalmente en la vegetación y las edificaciones. Las características del contexto externo del objeto describen un nivel de agregación superior al del objeto (manzana urbana) explicando las relaciones espaciales entre las parcelas contenidas en la manzana urbana, su geometría y las propiedades de las diferentes coberturas (edificaciones y vegetación).

El diseño y la utilización de características de contexto es novedoso en este campo y puede realizarse gracias al empleo de técnicas de clasificación y análisis basado en objetos, permitiendo completar la descripción de éstos con la incorporación de información referida a diferentes niveles de escala. Estas características presentan una alta complementariedad y un efecto sinérgico al combinarse con el resto de características derivadas de la imagen y de los datos LiDAR para la descripción conjunta de los entornos urbanos. Esta combinación produce un incremento notable de la fiabilidad de la clasificación, permitiendo alcanzar precisiones globales elevadas.

Las metodologías automáticas de detección de edificaciones presentan una gran aplicabilidad para la estimación de registros cuantitativos en bases de datos, como el porcentaje de superficie edificada. Esta información es relevante, por ejemplo, para la determinación de la superficie impermeable de áreas urbanas, el cálculo de estadísticas, tareas de planificación urbana, etc.

Los resultados de detección de edificaciones son de gran precisión, con unos errores muy bajos y un ligero sesgo a la sobreestimación de las superficies. Además, los resultados son coherentes independientemente de la tipología urbana analizada. Al tratarse de valores objetivos, que no dependen de operadores humanos, su utilización para la estimación de las superficies edificadas parece más indicada que las metodologías basadas en técnicas de percepción visual. Estas técnicas, además de subjetivas, producen errores notablemente mayores y con una clara tendencia a la sobreestimación de la superficie. Además, los resultados varían dependiendo del entorno urbano analizado y de la pericia del operador.

Así mismo, la combinación de la detección de edificaciones y la clasificación automática de los usos del suelo presentan una elevada aplicabilidad en la actualización de

información incluida en bases de datos de ocupación del territorio. Como ejemplo se ha demostrado que esta metodología permite distinguir tipologías de edificación adicionales a las recogidas para cada polígono en la base de datos del SIOSE. Esto posibilitaría introducir mayor nivel de detalle semántico en esta u otras bases de datos geoespaciales, sin incrementar por ello el coste de procesado.

En general, los resultados obtenidos ofrecen una solución práctica, transferible e integrada a la creciente necesidad de metodologías automatizadas que permitan la explotación masiva de información geográfica. Estas metodologías facilitan la inclusión de modo semi-automático de información útil y actualizada en bases de datos de ocupación del territorio, centrándose en entornos especialmente dinámicos como son las áreas urbanas. Teniendo en cuenta que el planeamiento urbano y territorial está fuertemente condicionado por la disponibilidad y calidad de la información espacial, su eficacia podría mejorar sustancialmente al contar con información actual y precisa del escenario a analizar. Así, estas técnicas pueden contribuir a facilitar la gestión eficiente del planeamiento urbano y la ordenación del territorio, desde el punto de vista físico –a través del conocimiento de la topografía, la densidad y la tipología de las edificaciones, monitorización de los cambios en coberturas y usos del suelo, o su relación con los espacios naturales–, económico –mediante análisis de accesibilidad y emplazamiento, necesidades de nuevas infraestructuras y sistemas de transporte público–, y social – estudiando la distribución de la población u otros factores socioeconómicos y su relación espacio-temporal con las estructuras urbanas. Adicionalmente, el uso metódico y continuado de esta información y de su análisis combinado con otros datos espaciales puede configurar un sustrato metodológico para la creación de modelos de predicción de dispersión, y crecimiento urbano y, en definitiva, para el seguimiento de los procesos evolutivos y la asistencia en las medidas conducentes al mantenimiento de la sostenibilidad territorial.

## **6.2. Líneas futuras de investigación**

La realización de esta Tesis ha abierto varias líneas de investigación cuyo desarrollo puede mejorar la extracción de conocimiento y clasificación de los entornos urbanos, aportando información en las bases de datos de ocupación del territorio.

En primer lugar se plantearía el uso de nuevas fuentes de datos, pudiéndose considerar imágenes con una resolución espacial superior, así como imágenes de tipo hiperespectral. Estas últimas aportan una mayor cantidad de información sobre el comportamiento espectral de las cubiertas y materiales que componen los entornos urbanos. En lo referente a la información tridimensional, podría considerarse datos LiDAR de diferentes densidades, e incluso datos LiDAR adquiridos con sensores *full waveform*, que adquieren completamente el retorno del pulso LiDAR en función del tiempo, y que en los próximos años se prevé que aumente notablemente su disponibilidad.

En lo referente a la descripción de los objetos, pueden proponerse y analizarse nuevas características descriptivas, especialmente basadas en el contexto. Así, sería interesante profundizar y realizar un estudio más pormenorizado de estos descriptores, tanto interno como externo, permitiendo un análisis más complejo del contexto. Además, pueden considerarse nuevos niveles de agregación que permitan una contextualización externa superior al permitido por las manzanas urbanas, y aplicarlo a otro tipo de entornos no urbanos. Las nuevas características permitirían la definición de un mayor número de clases más detalladas.

Además, estas técnicas de clasificación abren la puerta a un paso posterior para la confección automática de los polígonos de coberturas empleando técnicas automáticas de generalización, de forma que se evite en lo posible la subjetividad aportada por los operadores humanos, y se automatice al máximo la creación de las bases de datos geo-espaciales de ocupación del territorio.

Con el tiempo, la disponibilidad de series de datos estándar de una misma zona adquiridos en diferentes épocas, posibilitaría el seguimiento y análisis temporal de las zonas urbanas. Por ello, es importante el desarrollo de metodologías de detección de cambios en objetos basadas en la integración de distintos niveles de información, incluyendo el contexto. La definición de métodos que faciliten la detección de cambios en entornos urbanos permitiría mantener en un nivel máximo de utilidad y eficiencia las bases de datos de ocupación del territorio.





---

## REFERENCIAS BIBLIOGRÁFICAS

---

- Ahmady, S., Ebadi, H., Zouj, M.J.V., Moghaddam, H.A., 2008. Automatic building extraction from high resolution satellite images using active contour mode. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 37 (B3b), 453-456.
- Alberti, M., Waddell, P., 2000. An integrated urban development and ecological simulation model. *Integrated Assessment* 1, 215-227.
- Almeida J.P., Morley, J.G., Dowman, I.J., 2007. Graph theory in higher order topological analysis of urban scenes. *Computers, Environment and Urban Systems* 31 (4), 426-440.
- Axelsson, P., 1999. Processing of laser scanner data – algorithms and applications. *ISPRS Journal of Photogrammetry and Remote Sensing* 54 (2-3), 138-147.
- Ambrosio, G., Arévalo, V., González, J., Valdés, J., 2006. Detección de sombras en imágenes de satélite de alta resolución QuickBird. *Actas de las XXVII Jornadas de Automática*, 6-9 Septiembre, Almería, España, pp. 1306-1313.
- Antunes, A.F.B.; Lingnau, C., Centeno da Silva, J., 2003. Object oriented analysis and semantic network for high resolution image classification. *Anais XI SBSR*, 5-10 Abril, Belo Horizonte, Brasil, pp. 273-279.

- Aronoff, S., 1982. Classification accuracy: a user approach. *Photogrammetric Engineering & Remote Sensing* 48 (8), 1299-1307.
- Arozarena, A., Villa, G., Hermosilla, J., Papí, F., Valcárcel, N., Peces, J.J., Doménech, E., García, C., Tejeiro, J.A., 2006. El Plan Nacional de Observación del Territorio en España: situación actual y próximos pasos. *Mappin Interactivo* 111, 16-22.
- Baatz, M., Schäpe, A., 2000. Multi-resolution segmentation: an optimization approach for high quality multi-scale image segmentation. Strobl, J., Blaschke, T., Griesebner, G. (Eds.), *Angewandte Geographische Informationsverarbeitung XII*, Wichmann, Heidelberg, pp. 12-23.
- Balaguer, A., Ruiz, L.A., Hermosilla, T., Recio, J.A., 2010. Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification, *Computers & Geosciences* 36 (2), 231-240.
- Baltsavias E.P., 1999. Airborne laser scanning: existing systems and firms and other resources. *ISPRS Journal of Photogrammetry and Remote Sensing* 54 (2-3), 164-198.
- Barnsley, M.J., Barr, S.L., Sadler, G.J., 1991. Spatial re-classification of remote sensed images for urban land use monitoring. *Proceedings of Spatial Data 2000*, 17-20 Septiembre, Oxford, UK, pp. 106-117.
- Barnsley, M., Barr, S., 1997. A graph-based structural pattern recognition system to infer land use from fine spatial resolution land cover data. *Computers, Environment and Urban Systems* 21 (3-4), 209-225.
- Barnsley, M. J., Barr, S. L., 2000. Monitoring urban land use by Earth Observation. *Surveys in Geophysics* 21, 269-289.
- Barr, S., Barnsley, M., 1998. A syntactic pattern recognition paradigm for the derivation of second-order thematic information from remotely-sensed image. Atkinson, P., y Tate, N (Eds.), *Advances in Remote Sensing and GIS Analysis*, John Wiley and Sons, Chichester, UK.
- Bauer, T., Steinnocher, K., 2001. Per-parcel land use classification in urban areas applying a rule-based technique. *GeoBIT/GIS* 6, 24-27
- Bellman, C., Shortis, M., 2003. Building recognition using wavelet analysis and support vector machines. *Proceedings of Spatial Knowledge Without Boundaries*, 22-27 Septiembre, Canberra, Australia, 10p.
- Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65 (1), 2-16.
- Boffet, A., Coquerel, C., 2000. Urban classification for generalization orchestration. *The International Archives of Photogrammetry and Remote Sensing* 33 (B4), 132-139.

- Boffet, A. and Rocca-Serra, S.; 2001: Identification of spatial structures within urban blocks for town characterization. Proceedings of 20th International Cartographic Conference, 6-10 Agosto, Pekín, China, pp.1974-1983.
- Bogaert, J., Rousseau, R., Hecke, P.V., Impens, I., 2000. Alternative area-perimeter ratios for measurement of 2D shape compactness of habitats. Applied Mathematics and Computation 111 (1), 71-85.
- Breuste, J., Feldmann, H., Uhlmann, O., 1998. Urban Ecology. Springer, Berlin.
- Burghardt, D., Steiniger, S., 2005. Usage of principal component analysis in the process of automated generalisation. Proceedings of XXII International Cartographic Conference, ICC2005, 11-16 Julio, A Coruña, España, 12p.
- Canny, J.F., 1986. A computational approach to edge detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, 679-698.
- Champion, N., 2007. 2D building change detection from high resolution aerial images and correlation digital surface models. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 36 (3/W49A), 197-2002.
- Chang, T., Kuo, C.J., 1993. Texture analysis and classification with tree-structured wavelet transform. IEEE Transactions on Image Processing 2, 429-441.
- Chen, L.C., Teo, T.A., Shao, Y.C., Lai, Y.C., and Rau, J.Y., 2004. Fusion of LIDAR Data and Optical Imagery for Building Modeling. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (B4), 732-737.
- Cheng, L., Gong, J., Chen, X., Han, P., 2008. Building boundary extraction from high resolution imagery and LiDAR data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 37 (B3b), 693-698.
- Cho, W., Jwa, Y.S., Chang, H.J., Lee, S.H., 2004. Pseudo-grid based building extraction using airborne LIDAR data, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (B3), 378-381.
- Cord, M., Declercq, D., 2001. Three-dimensional building detection and modelling using a statistical approach. IEEE Transactions on Image Processing 10, 715-723.
- Cui, S.Y., Yam, Q., Liu, Z.J., Li, M., 2008. Building detection and recognition from high resolution remotely sensed imagery. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 37 (B3b), 411-416.
- Croitoru, A., Doytsher, Y., 2003. Monocular right-angle building hypothesis generation in regularized urban areas by pose clustering. Photogrammetric Engineering & Remote Sensing 69 (2), 151-169.

- Dare, P.M., 2005. Shadow analysis in high-resolution satellite imagery of urban areas. *Photogrammetric Engineering & Remote Sensing* 71, 169-177.
- Delaunay, B, 1934. Sur la sphère vide. A la mémoire de Georges Voronoi. *Izvestia Akademii Nauk SSSR, Otdelenie Matematicheskikh i Estestvennykh Nauk* (Bulletin of Academy of Sciences of the USSR) 7, 793-800.
- Donnay, J.P., Barnsley, M.J., Longley, P.A., 2001. Remote sensing and urban analysis. Donnay, J.P., Barnsley, M., Longley, P. (Eds.) *Remote Sensing and Urban Analysis*, Taylor & Francis, London, UK, pp. 3-18.
- Duan J., Prinnet, V., Lu H., 2004. Building extraction in urban areas from satellite images using GIS data as prior information. In: *Geosciences and Remote Sensing Symposium* 7, 4762- 4764.
- Ekhtari, N., Sahebi, M.R., Valadan Zoej, M.J., Mohammadzadeh, A., 2008. Automatic Building Detection from LIDAR Point Cloud Data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. 37. Part B4, pp. 473-477.
- Estornell, J., Ruiz, L.A., Velázquez-Martí, B., Hermosilla, T., 2010. Analysis of the factors affecting LiDAR DTM accuracy in a steep shrub area. *International Journal of Digital Earth*. <http://dx.doi.org/10.1080/17538947.2010.533201>.
- Everitt, B.S., Dunn, G., 2001. *Applied multivariate data analysis*. 2ª ed. Edward Arnold, London.
- Eyton, J.R., 1993. Urban land use classification and modeling using cover-type frequencies. *Applied Geography* 13, 111-121.
- Felícísimo, A.M., 1994. Modelos digitales del terreno. Introducción y aplicaciones en las ciencias ambientales. Pentalfa Ediciones, Oviedo, España, 118 pp.
- Ferreira, J., Bernardino, A., 2006. Acquisition of 3D Regular Prismatic Models in Urban Environments from DSM and Orthoimages. *Proceedings of Symposium on Computational Modelling of Objects Represented in Images: Fundamentals, Methods and Applications*, Coimbra, Portugal.
- Ferro, C.J., Warner, T.A., 2002. Scale and texture in digital image classification. *Photogrammetric Engineering & Remote Sensing* 68, 51-63.
- Fundación BBVA, 2010. La población en España. *Cuadernos de Población* 51, 16p.
- Freund, Y., 1995. Boosting a weak learning algorithm for majority. *Information and Computation* 121, 256-285.
- Freund, Y., Shapire, R.E., 1997. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences* 55, 119-139.

- Friedman, J., Hastie, T., Tibshirani, R., 2000. Additive logistic regression: a statistical view of boosting. *The Annals of Statistics* 28, 337-407.
- Gastellu-Etchegorry, J., 1990. An assessment of SPOT XS and Landsat MSS data for digital classification of near-urban land cover. *ISPRS International Journal of Remote Sensing* 11, 225-235.
- Ge, Q.Z., Li, Q., Ling, Z.C., Hui, X.X., Zhang, G., 2008. Stochastic Motion and the Level Set Method in Semi-Automatic Building Detection. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37. (B3b), 431-434.
- Guo, T., Yasuoka, Y., 2002. Snake-based approach for building extraction from high-resolution satellite images and height data in urban areas. *Proceedings of 23rd Asian Conference on Remote Sensing*, 25-29 Noviembre, Kathmandu, Nepal, 7p.
- Haralick, R.M., Shanmugan, K., Dinstein, I., 1973. Texture features for image classification. *IEEE Transactions on Systems, Man and Cybernetics* 3, 610-621.
- Hay, G.J., Castilla, G., 2006. Object-based image análisis: strengths, weaknesses, opportunities and tretas (SWOT). *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (4/C42), 3p.
- Hermosilla, T., Ruiz, L.A., Fernández. Sarría, A., Recio, J.A, 2008. Detección automática de edificios en imágenes aéreas mediante técnicas de teledetección y análisis contextual. *Congreso Internacional sobre Ingeniería Geomática y Topográfica, TOP-CART 2008*. 18-21 Febrero, Valencia, España, 6p..
- Hermosilla, T., Ruiz, L.A., 2009. Detección automática de edificios combinando imágenes de satélite y datos Lidar. *Semana Geomática Internacional*, 3-5 marzo 2009, Barcelona, 9p.
- Hernández Orallo, J., Ramírez Quintana, M.J., Ferri Ramírez, C., 2004. *Introducción a la minería de datos*. Pearson Educación S.A., Madrid, España.
- Herold, M., Couclelis, H., Clarke, K.C., 2005. The role of spatial metrics in the analysis and modelling of urban land use change. *Computers, Environment and Urban Systems* 29 (4), 369-399.
- Herold, M., Liu, X., Clarke, K.C., 2003. Spatial metrics and image texture for mapping urban land use. *Photogrammetric Engineering & Remote Sensing* 69 (9), 991-1001.
- Hofmann, A.D., Maas, H.G., Streilein, A., 2002. Knowledge-based building detection based on laser scanner data and topographic map information. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 34 (A3), 169-174.

- Hofmann, P., Strobl, J., Blaschke, T., Kux, H., 2006. Detecting informal settlements from QuickBird data in Rio de Janeiro using an object based approach. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (4/C42), 6p.
- Huberty, C.J., 1994. *Applied Discriminant Analysis*. Wiley, New York, USA.
- Hussain, M., Davies, C., Barr, R., 2007. Classifying buildings automatically: a methodology. *Proceedings of the Geographical Information Science Research UK Conference, GISUK*, 11-13 Abril, County Kildare, Irlanda, 5p.
- Hsu, P.H., 2006. Comparison of Projection Pursuit and Matching Pursuit in Feature Extraction of Hyperspectral Images. *Proceedings of the 27th Asia Conference on Remote Sensing*, 9-13 October, Ulán Bator, Mongolia, 6p.
- Instituto Geográfico Nacional, 2007. *Sistema de información de ocupación del suelo en España. Manual de Fotointerpretación. Versión 1.2*.
- Irvin, R.B., McKeown, D.M.Jr., 1989. Methods for exploiting the relationship between buildings and their shadows in aerial imagery, *IEEE Transactions on Systems, Man, and Cybernetics* 19 (6), 1564-1575.
- Jin, X., Davis, C.H., 2005. Automated Building Extraction from High-Resolution Satellite Imagery in Urban Areas Using Structural, Contextual, and Spectral Information. *EURASIP Journal on Applied Signal Processing* 14, 2196-2206.
- Jin, Xiaoying. 2009. Segmentation-based image processing system. US Patent 20,090,123,070, Filled: Nov. 14, 2007, and issued May 14, 2009.
- Jordan, M., Cord, M., Belli, T., 2002. Building Detection from High Resolution Digital Elevation Models in Urban Areas. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 34 (3B), 96-99.
- Karsli, F., Kahya, O., 2008. Building extraction from laser scanning data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (B3b), 289-294.
- Katartzis, A. Sahli, H., 2008. A stochastic framework for the identification of building rooftops using a single remote sensing image. *IEEE Transactions on Geoscience and Remote Sensing* 46 (1), 259-271.
- Kim, T., Lee, T.Y., Lim, Y.J., Kim, K.O., 2005. The use of voting strategy for building extraction from high resolution satellite images. *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium.*, 25-29 Julio, Seúl, Corea, pp. 1269-1272.
- Kim, T., Muller, J., 1999. Development of a graph based approach for building detection. *Image and Vision Computing* 17 (1), 3-14.

- Kim, Z.W., Netavia, R., 1999. Uncertain reasoning and learning for feature grouping. *Computer Vision and Image Understanding* 73, 278-288.
- Klaric, M., Scott, G., Shyu, C.R., Davis, C.H., 2005. Automated object extraction through simplification of the differential morphological profile for high-resolution satellite imagery. *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium.*, 25-29 Julio, Seúl, Corea, pp.1265-1268.
- Koc San, D., Turker, M., 2006. Automatic Building Detection and Delineation from High Resolution Space Images Using Model Based Approach. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (1/W41), 6p.
- Kokubu, K., Kohiyama, M., Umemura F., Yamazaki, F., 2001. Automatic Detection of Building Properties from Aerial Photographs Using Color and 3D Configuration. *Proceedings of the 22nd Asian Conference on Remote Sensing*, 5-9 Noviembre, Singapur, 6p.
- Krishnamachari, S., Chellapa, R., 1994. An energy minimization approach to building detection in aerial images. *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing* 5, 13-16.
- Krummel, J.R., Gardner, R.H., Sugihara, G., O'Neill, V., Coleman, P.R., 1987. Landscape patterns in a disturbed environment. *OIKOS* 48, 321-324.
- Kundsén, T., Nielsen, A.A., 2004. Detection of buildings through multivariate analysis of spectral, textural, and shape based features. *Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, 25-30 Julio, Honolulu, HA, USA, pp. 2830-2833.
- Lavigne, D. A. Saeedi, P. Dlugan, A. Goldstein, N. Zwick, H., 2007. Automatic building detection and 3D shape recovery from single monocular electro-optic imagery. Kadar, I. (Eds) *Signal Processing, Sensor Fusion, and Target Recognition XVI*, pp. 6567-16
- Lafarge, F., Descombes, X., Zerubia, J., Pierrot-Deseilligny, M., 2008. Automatic building extraction from DEMs using an object approach and application to the 3D-city modelling. *ISPRS Journal of Photogrammetry & Remote Sensing* 63 (3), 365-381.
- Lari, Z., Ebadi, H., 2007. Automatic Extraction of Building Features from High Resolution Satellite Images Using Artificial Neural Networks. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (1/W51), 6p.
- Laskari, S., Hanna, S., Derix, C., 2008. Urban identity through quantifiable spatial attributes: coherence and dispersion of local identity through the automated comparative analysis of building block plans. *Proceedings of the Third*

- International Conference on Design Computing and Cognition, 23–25 June, Atlanta, USA, pp. 615-634.
- Laurini, R., Thompson, D., 1992. *Fundamentals of spatial information* (Vol. 5). London, UK, Academic Press.
- Lee, D.S., Shan, J., Bethel, J., 2003. Class-guided building extraction from IKONOS imagery. *Photogrammetric Engineering & Remote Sensing* 69 (2), 143-150.
- Lefèvre, S., Weber, J., Sheeren, D. 2007. Automatic Building Extraction in VHR Images using Advanced Morphological Operators. In: *Urban Remote Sensing Joint Event*, pp. 1-5.
- Leukert, K., Darwish, A., Reinhardt, W., 2003. Urban land-cover classification: an object-based perspective. *Proceedings of the 2nd Joint Workshop on Remote Sensing and Data Fusion over Urban Areas, 22-23 May, 2003, Berlín, Alemania*, pp. 278-282.
- L'Homme, S., Weber, C., He D.C., Morin, D., Puissant, A., 2004. Building extraction from very high spatial resolution image. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 35 (B3), 921-925.
- Li, H., Gu, H., Han, Y., Yang, J., 2007. Fusion of High-Resolution Aerial Imagery and LIDAR Data for Object-oriented Urban Land-cover Classification Based on SVM. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (4/W54), 179-184.
- Li, Y., Sasagawa, T., Gong, P.A., 2004. System of Shadow Detection and Shadow Removal for High Resolution City Aerial Photo. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 35 (B3), 802-807.
- Li, H.Y., Wang, H.Q., Ding, C.B., 2006. A New Solution of Automatic Building Extraction in Remote Sensing Images. *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium. 31 Julio – 4 Agosto, Denver, CO, USA*, pp. 3790-3793.
- Lin, C., Huertas, A., Navatia, R., 1994. Detection of buildings using perceptual grouping and shadows. *IEEE Computer Vision Pattern Recognition*, 62–69.
- Lin, Y., Zhang, S., Xie, F., Chen, Y., 2008. The construction of anti-symmetrical wavelet and building extraction from remote sensing imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (B3b), 467-472.



- Liu, W., Prinet, V., 2005. Building detection from high-resolution satellite image using probability model. Proceedings of the IEEE International Geoscience and Remote Sensing Symposium., 25-29 Julio, Seúl, Corea, pp. 3888-3891.
- Liu, Z.J., Wang, J., Liu, W.P., 2005. Building extraction from high resolution imagery based on multi-scale object oriented classification and probabilistic Hough transform. Proceedings of the IEEE International Geoscience and Remote Sensing Symposium., 25-29 Julio, Seúl, Corea, pp. 2250- 2253
- Madhavan, B.B., Tachibana, K., Sasagawa, T., Okada, H., Shimozuma, Y., 2004. Automatic Extraction of Shadow Regions in High-resolution Aerial Images. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (B3), 808-810.
- Marangoz, A.M., Oruç, M., Büyüksalih, G., 2004: Object-oriented Image Analysis and Semantic Network for Extracting the Roads and Buildings From Ikonos Pan-sharpened Images. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (B3), 4p.
- Massalabi, A., He, D.C, Beaudry, G.B.B.E, 2004. Restitution of Information Under Shadow in Remote Sensing High Space Resolution Images: Application to Ikonos Data of Sherbrooke City. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (B3), 6p.
- Matikainen, L., Hyypä, J., Kaartinen, H. 2004. Automatic detection of changes from laser scanner and aerial image data for updating building maps. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (B2), 434-439.
- Matikainen, L., Kaartinen, H., Hyypä, J., 2007. Classification tree based building detection from laser scanner and aerial image data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 36 (3/W52), 280-287.
- 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., Zhang, Y., Coleman, D. J., 2005. Semi-Automatic Building Extraction Utilizing Quickbird Imagery. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 36 (3/W24), 131-136.
- McGarigal, K., Marks, B.J., 1995. FRAGSTATS: Spatial pattern analysis program for quantifying landscape structure. USDA Forest Service General Technical Report PNW-GTR-351.
- McGlone, J. C., Shufelt, J. A., 1994, Projective and object space geometry for monocular building extraction. Proceedings of IEEE Conference Computer Vision and Pattern Recognition 2486, pp. 25-36.

- Miliareisis, G, Kokkas, N, 2007. Segmentation and object-based classification for the extraction of the building class from LIDAR DEMs. *Computers & Geosciences* 33 (8), 1076-1087.
- Müller, S., Zaum, D.W., 2005. Robust building detection in aerial images. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (3/W24), 143-148.
- Novack, T., Kux, H.J.H., Feitosa, R.Q., Costa, G. A., 2010. Per block urban land use interpretation using optical VHR data and the knowledge-based system interimage. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 38 (4/C7), 6p.
- Oczipka, M., Bucher, T., Trosset, A., 2008. Mapping and updating maps in dense urban regions using high resolution digital airborne imagery, surface models and object-based classification. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (B7), 551-556.
- Ok, A.O., 2008. Robust detection of buildings from a single color aerial image. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (4/C1), 6p.
- Olsen, B.P., 2004. Automatic change detection for validation of digital map databases. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 35 (B2), 569-574.
- Olsen, B.P., Knudsen, T., Frederiksen, P., 2002. Digital Change Detection for Map Database Update. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 34 (2), 357-364.
- Organización de las Naciones Unidas, 2003. *World Urbanization Prospects: The 2003 Revision*. Department of Economic and Social Affairs/Population Division. United Nations. New York.
- Organización de las Naciones Unidas, 2007. *World population prospects, the 2006 revision*. The Department of Economic and Social Affairs, United Nations. New York.
- Pathegama, M., GöI, O., 2004. Edge-end pixel extraction for edge-based image segmentation. *Transactions on Engineering, Computing and Technology* 2, 213-216.
- Paparoditis, N., 1998. Building detection and reconstruction from mid- and high-resolution aerial imagery. *Computer Vision and Image Understanding* 72 (2), 122-142.
- Pickett, S.T.A., Cadenasso, M.L., Grove, J.M., Nilon, C.H., Pouyat, R.V., Zipperer, W.C., Costanza, R., 2001. Urban ecological systems: linking terrestrial ecological,

- physical, and socioeconomic components of metropolitan areas. *The Annual Review of Ecology, Evolution, and Systematics* 32 (1), 27-57.
- Pielke, R.A., 1974. A three-dimensional numerical model of the sea breeze over South Florida. *Monthly Weather Review* 102 (22), 115-139.
- Quinlan, J.R., 1993. C4.5. Programs for machine learning. San Mateo: Morgan Kaufmann.
- Quinlan, J.R., 1996a. Bagging, boosting and C4.5. *Proceedings of the 30th National Conference on Artificial Intelligence and the 8th Innovative Applications of Artificial Intelligence*, pp. 725-730.
- Quinlan, J.R., 1996b. Improved use of continuous attributes in C4.5. *Journal of Artificial Intelligence Research* 4, 77-90.
- Quinlan, J.R. 1996c. Learning decision tree classifiers. *ACM Computing Surveys* 28, 71-72.
- Richards, J.A., Jia, X., 2006. *Remote Sensing Digital Image Analysis: An Introduction*. Springer-Verlag. Berlín, Alemania.
- Robinson, D.J., Redding, N.J., and Crisp, D.J., 2002. Implementation of a fast algorithm for segmenting SAR imagery. Scientific and Technical Report. Australia: Defense Science and Technology Organization.
- Rottensteiner, F., Trinder, J., Clode, S., Kubic, K., 2003. Building detection using LIDAR data and multispectral images. *Proceedings of the International Conference on Digital Image Computing*, 24-29 Agosto, Sydney, Australia, pp. 673-682.
- Rottensteiner, F., Trinder, J., Clode, S., Kubik, K., 2004. Building Detection by Dempster-Shafer Fusion of LIDAR Data and Multispectral Aerial Imagery. *Proceedings of 17th International Conference on Pattern Recognition* 2, 339-342.
- Ruiz, L.A., Fernández Sarría, A., Recio, J.A., 2002. Evaluation of texture analysis techniques to characterize vegetation. *Proceedings of Recent Advances in Quantitative Remote Sensing*, 16-20 Septiembre, Torrent, España, pp. 514-521.
- Ruiz, L.A., Fernández Sarría, A., Recio, J.A., 2004. Texture feature extraction for classification of remote sensing data using wavelet decomposition: A comparative study. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 35 (B7), 1109-1115.
- Ruiz, L.A., Recio, J.A., Fernández-Sarría, A., Hermosilla, T., en prensa. A feature extraction software tool for agricultural object-based image analysis. *Computers and Electronics in Agriculture* 76 (4), 284-296.
- Sadler, G.J., Barnsley, M.J., Barr, S.L., 1991. Information extraction from remotely sensed images for urban land analysis. *Proceedings of the Second European*

- conference on Geographical Information Systems, 2-5 Abril, Bruselas, Belgica, pp. 955-964.
- Scanlan, J.M., Chabries, D.M., Christiansen, R.W., 1990. A shadow detection and removal algorithm for 2-d images. *IEEE Acoustic Speech Signal Processing 4*, 2057-2060.
- Shackelford, A.K., Davis, C.H., Wang, X., 2004. Automated 2-D building footprint extraction from high-resolution satellite multispectral imagery. *IEEE International Proceedings of IEEE International Geoscience and Remote Sensing Symposium*, 25-30 Julio, Honolulu, HA, USA, pp. 1996-1999.
- Shan, J., Lee, D.S., 2002. Generalization of building polygons extracted from IKONOS imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 34 (2)*, 286-290.
- Shan, J., Lee, D.S., 2005. Quality of building extraction from IKONOS imagery, *Journal of Surveying Engineering 131 (1)*, 27-32.
- Shyu, R., Scott, G., Klaric, M., Davis, C.H., Palaniappan, K., 2005. Automatic object extraction from full differential morphological profile in urban imagery for efficient object indexing and retrievals. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 36 (8-W27)*, 6p
- Sohn, G., Dowman, I., 2001. Extraction of buildings from high resolution satellite data. In: Baltsavias, E., Gruen, A., Van Gool, L. (Eds.), *Automated Extraction of Man-Made Object from Aerial and Space Images (III)*. Balkema Publishers, Lisse, pp.345- 355.
- Stassopoulou, A., Caelli, T., 2000. Building detection using Bayesian networks. *International Journal of Pattern Recognition and Artificial Intelligence 14 (6)*, 715-733.
- Steiniger, S., Taillandier, P., Weibel, R., 2010. Utilising urban context recognition and machine learning to improve the generalisation of buildings. *International Journal of Geographical Information Science 24 (2)*, 253-282.
- Schneider W., Steinwendner, J., 1999. Land cover mapping by interrelated segmentation and classification of satellite images. *International Archives of Photogrammetry and Remote Sensing 32 (7-4-3-W6)*, 46-52
- Story, M., Congalton, R.G, 1986. Accuracy assessment: a user's perspective. *Photogrammetric Engineering & Remote Sensing 52 (3)*, 397-399.
- Sumer, E., Turker, M., 2008. Building detection from high-resolution satellite imagery using adaptive fuzzy-genetic approach. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 38 (4/C1)*, 6p.

- Sutton, R.N., Hall, E.L., 1972. Texture measures for automatic classification of pulmonary disease. *IEEE Transactions on Computers* 21 (7), 667-676.
- Tan, G., Shibasaki, R., 2002. A research for the extraction of 3d urban building by using airborne laser scanner data. *Proceedings of 23rd Asian Conference on Remote Sensing*, 25-29 Noviembre, Kathmandu, Nepal, 5p.
- Teo, T.A., Chen, L.C., 2004. Object-based building detection from LiDAR data and high resolution satellite imagery. *Proceedings of Proceedings of the 25th Asian Conference on Remote Sensing*, 22-26 Noviembre, Chiang Mai, Tailandia, pp. 1614-1619.
- Theng L.B., 2006. Automatic Building Extraction from Satellite. *Imagery Engineering Letters* 13 (3), 5p.
- Thomson, M. K., Béra, R., 2008. A methodology for inferring higher level semantic information from spatial databases. *Proceedings of the GIS Research UK 16th Annual Conference (GISRUK 2008)*, April 2-4, 2008, Manchester, UK, pp. 268-274.
- Tian, J., Wang, J., Shi, P., 2003. Urban building boundary extraction from Ikonos imagery. *Proceedings of the 25th Symposium canadien sur la télédétection*, 17-21 Mayo, Montreal, Canadá, 6p.
- Tsai, J.D., 2003. Automatic Shadow Detection and Radiometric Restoration on Digital Aerial Images. *International Geoscience and Remote Sensing Symposium: Learning From Earth's Shapes and Colours*, 21-25 Julio, Toulouse, Francia, pp. 732-733.
- Tse, R.O.C., Gold, C.M., Kidner, D.B., 2007. Building Reconstruction Using LIDAR Data, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (4-W54), 121-126.
- Van de Voorde, T., Van der Kwast, J., Engelen, G., Binard, M., Cornet, Y., Canters, F., 2009. Quantifying intra-urban morphology of the Greater Dublin area with spatial metrics derived from medium resolution remote sensing data. *Proceedings of the 7th International Urban Remote Sensing Conference, IEEE Geoscience and Remote Sensing Society*, 20-22 Mayo, Shanghai, China, 6p.
- Vanderhaegen, S., Canters, F., 2010. Developing urban metrics to describe the morphology of urban areas at block level. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 38 (4/C7), 6p.
- Vestri, C., Devernay, F., 2001. Using Robust Methods for Automatic extraction of buildings, *Proceedings of the International Conference on Computer Vision and Pattern Recognition*, pp. 208-213.

- Villa, G., Peces, J.J., Doménech, E., García, C., Tejeiro, J.A., Plaza, N., 2008. El Plan Nacional de Observación del Territorio en España. Actas del Congreso Internacional de Ingeniería Geomática y Topografía, TOP-CART, 18-21 Febrero, Valencia, España, 6p.
- Vögtle, T., Steinle, E., 2000. 3D modelling of buildings using laser scanning and spectral information. *The International Archives of the Photogrammetry and Remote Sensing* 32 (B3), 927-934.
- Vosselman, G., Gorte, B.G.H., Sithole, G., 2004. Change detection for updating medium scale maps using laser altimetry. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 34 (B3), 207-212.
- Vozikis, G., Jansa, J., 2008. Advantages and disadvantages of the Hough transformation in the frame of automated building extraction. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (B3b), 719-724.
- Vu, T.T., Matsuoka, M., Yamazaki, F., 2004a. LiDAR Signature to Update Japanese Building Inventory Database. *Proceedings of Proceedings of the 25th Asian Conference on Remote Sensing*, 22-26 Noviembre, Chiang Mai, Tailandia, pp. 624-629.
- Vu, T.T., Matsuoka, M., Yamazaki, F., 2004b. Shadow Analysis in Assisting Damage Detection Due to Earthquakes from Quickbird Imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 35 (B7) 607-610.
- Wan, C.K., Hsu, P.H., 2008. Building detection and structure line extraction from airborne LiDAR data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (B3b), 267-272.
- Wang, C.,K., Hsu, P.H., 2006. Building Extraction from LiDAR Data Using Wavelet Analysis. *Proceedings of the 27th Asia Conference on Remote Sensing*, 9-13 Octubre, Ulan-Bator, Mongolia, 6p.
- Wei, Y., Zhao, Z., Song, J., 2004. Urban building extraction from high-resolution satellite panchromatic image using clustering and edge detection. *Proceedings of the IEEE International Geoscience and Remote Sensing Symposium*, 20-24 Septiembre, Anchorage, AK, USA, pp.2008-2010.
- Weidner, U., Förstner, W., 1995. Towards automatic building extraction from high-resolution digital elevation models. *ISPRS International Journal of Photogrammetry and Remote Sensing* 50 (4), 38-49.
- Welch, R., 1982. Spatial resolution requirements for urban studies. *ISPRS International Journal of Remote Sensing* 3 (2), 139-146.

- Whitford, V., Ennos, A.R., Handley, J.F., 2001. City form and natural process - indicators for the ecological performance of urban areas and their application to Merseyside, UK. *Landscape and Urban Planning* 57 (2), 91-103.
- Wijnant, J., Steenberghen, T., 2004. Per-parcel classification of urban ikonos imagery. *Proceedings of 7th AGILE conference on geographic information science*, 29 Abril - 1 Mayo, Heraklion, Grecia, pp. 447-455.
- Xudong, L., Youchuan, W., Wei W., 2008. A flow to generate DEM and segment building in urban areas from LiDAR data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37 (B3b), 149-152.
- Yoshida, H., Omae, M., 2005. An approach for analysis of urban morphology: methods to derive morphological properties of city blocks by using an urban landscape model and their interpretations. *Computers, Environment and Urban Systems*, 29 (2), 223-247.
- Yu, B., Liu, H., Wu, J., Hu, Y., Zhang, L., 2010. Automated derivation of urban building density information using airborne LiDAR data and object-based method. *Landscape and Urban Planning*, 98 (3-4), 210-219.
- Zhang, L., Wu, J., Zhen, Y., Shu, J., 2004. A GIS-based gradient analysis of urban landscape pattern of Shanghai metropolitan area, China. *Landscape and Urban Planning* 69 (1), 1-16.
- Zhang, S., Liu, X., 2005. Realization of data mining model for expert classification using multi-scale spatial data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (4/W6), 107-111.
- Zhan, Q., Molenaar, M., Gorte, B., 2000. Urban land use classes with fuzzy membership and classification based on integration of remote sensing and GIS. *International Archives of Photogrammetry and Remote Sensing* 33 (B7), 1751-1759.
- Zhan, Q., Molenaar, M., Tempfli, K., 2002a. Finding spatial units for land use classification based on hierarchical image objects. *International Archives of Photogrammetry and Remote Sensing* 34 (4), 6 p.
- Zhan, Q., Molenaar, M., Tempfli, K., 2002b. Hierarchical image object based structural analysis toward urban land use classification using HR imagery and airborne lidar data. *Proceedings of the 3rd Symposium on Remote Sensing of Urban Areas*, 11-13 Junio, Estambul, Turquía, 251-258.





# **Anejos**



## **Anejo I**

---

### **PNOT Y SIOSE**

---

#### **AI.1. Introducción**

En este Anejo se recogen los fundamentos del Plan Nacional de Observación del Territorio (PNOT), del que es parte el Plan Nacional de Ortofotografía Aérea (PNOA), de donde proviene una gran parte de los datos utilizados.

Se incluye, además, una descripción del Sistema de Información sobre Ocupación del Suelo de España (SIOSE), así como una explicación de cómo se clasifican las edificaciones y las zonas urbanas en esta base de datos cartográfica.

#### **AI.2. Plan Nacional de Observación de la Tierra (PNOT)**

El Plan Nacional de Observación del Territorio (PNOT) ha sido desarrollado por el Ministerio de Fomento, a través del IGN y el CNIG y apoyadas por el Consejo Superior Geográfico. De acuerdo con lo descrito en Arozarena et al. (2006), los objetivos que se persiguen con la aplicación de este plan son:

- Mejorar la eficiencia y optimizar los recursos económicos invertidos por cada uno de los organismos participantes en la captura de la información geográfica, de forma que el ahorro conseguido al evitar duplicidades de esfuerzos revierta en una mejor calidad y actualización de la información obtenida y, en consecuencia, de todas las bases de datos que se obtengan a partir de los mismos.
- Aprovechar todo el potencial de utilización de los productos y datos, fomentando la máxima difusión y utilización de los mismos por todos los agentes sociales a los que puedan resultar de utilidad
- Obtener unos Sistemas de Información integrados y coherentes (espacial, temporal y semánticamente) a lo largo de todo el territorio español, que sirvan para que las diferentes Administraciones coordinen sus procesos de toma de decisiones, al estar basadas éstas en la misma información de partida
- Apoyar y favorecer la implementación de las políticas Europeas y Mundiales: Desarrollo Sostenible (UNEP -United Nations Environmental Program-), GSDI (*Global Spatial Data Infrastructure*), GMES (*Global Monitoring for Environment and Security*), INSPIRE (*Infrastructure for Spatial Information in Europe*), etc.
- Aprovechar la convergencia de intereses entre los distintos organismos de los cuatro niveles de las Administraciones (Europeo, Nacional, Autonómico y Local)
- Fomentar la producción cooperativa y descentralizada de modo que los distintos organismos, en lugar de “competir” en cierto modo entre sí, cooperen a un fin común.
- Facilitar que se produzcan sinergias entre distintos proyectos y grupos de trabajo
- Permitir la explotación eficiente de la información según escalas y resoluciones.
- Fomentar la ampliación y mejora del tejido empresarial español en el sector de la información geoespacial, promoviendo que las empresas trabajen con mayor calidad, rigor y eficiencia, reduciendo al mismo tiempo los costes y siendo por tanto más competitivas a nivel internacional.
- Facilitar la consolidación de un tejido empresarial dedicado a la realización de productos de valor añadido a partir de los datos básicos generados

Dentro del PNOT se distinguen tres fases (Arozarena et al.; 2006): Obtención y tratamiento de las coberturas de imágenes, Extracción de la información y Diseminación de la información.

### **AI.2.1. Primera fase: obtención y tratamiento de las coberturas de imágenes**

Tiene por objeto la obtención de coberturas de imágenes aéreas y de satélite, con resoluciones y ritmos de actualización optimizados desde el punto de vista económico, así como de las aplicaciones en que se van a utilizar dichas imágenes. Estas coberturas se

organizan en distintos niveles de resolución espacial (tamaño de píxel) y frecuencia temporal.

### **AI.2.1.1. Plan Nacional de Ortofotografía Aérea (PNOA)**

Su objetivo es la obtención de coberturas con vuelos fotogramétricos con una frecuencia de actualización de 2 años. A partir de ellos se obtiene un DTM con precisión altimétrica de 2 m (emc) y ortofotos digitales en color con tamaño de píxel de 50 cm y precisión planimétrica de 1 m (emc). Ciertas zonas, por intereses especiales de las Comunidades Autónomas u otros organismos, se están realizando en algunos de los recubrimientos con un tamaño de píxel de 25 cm.

A partir del año 2009 se comenzó a capturar datos LiDAR de baja densidad (0,5 puntos/m<sup>2</sup>) con el fin de realizar DTM y DEM con mayor precisión, lo que conlleva una mayor precisión planimétrica de las ortofoto. Además, estos datos posibilitan múltiples nuevas aplicaciones: hidrológicas, control de líneas eléctricas, estudios de vegetación y ocupación del suelo, detección de cambios y edificios, etc. (Villa; 2008).

### **AI.2.1.2. Plan Nacional de Teledetección (PNT)**

El Plan Nacional de Teledetección tiene como objetivo la coordinación de la obtención y del tratamiento de recubrimientos de imágenes de satélite sobre nuestro territorio, de forma que se adquieran y se procesen una sola vez y puedan ser utilizadas por todos los organismos de las distintas Administraciones Españolas. El organismo responsable de la obtención de las imágenes es el Instituto Nacional de Técnica Aeroespacial (INTA). Estas coberturas se estructuran en tres niveles de resolución espacial y temporal.

El nivel de alta resolución consta de coberturas con imágenes de satélites de 2 a 10 metros de resolución espacial en modo pancromático y de 10 a 30 metros en modo multiespectral (satélites SPOT 5, IRS, Eros, etc.). La periodicidad prevista es de una cobertura al año, tomada en la época de verano. Las aplicaciones de estas imágenes son muy variadas, incluyendo, entre otras, la realización de bases de datos de ocupación del suelo (proyecto SIOSE), información agraria y actualización de bases de datos topográficas de escalas medias y pequeñas (1:200.000 a 1:1.000.000). Desde el año 2005 se han adquirido coberturas completas del territorio español con imágenes SPOT 5 HRG (Pancromático Supermode de 2,5 metros de píxel y Multiespectral de 10 metros simultáneos).

El nivel de media resolución comprende coberturas con imágenes de satélites de 10 a 15 metros en modo pancromático y de 20 a 50 metros de resolución en modo multiespectral (satélites SPOT 4, SPOT 2, Landsat 5, Landsat 7, IRS, Aster, etc.). La periodicidad prevista es de 3 o más coberturas al año, en las distintos períodos fenológicos (primavera, verano, otoño-invierno). Las aplicaciones principales son: análisis multitemporal estacional e interanual, clasificación automática de coberturas del suelo, identificación de cultivos, detección de regadíos, información forestal, parámetros

biofísicos, etc. Asimismo, se ha propuesto un proyecto para recopilar e inventariar todas las imágenes Landsat históricas existentes en los distintos organismos de las Administraciones, de forma que se puedan compartir entre todos ellos.

El nivel de baja resolución esta formado por coberturas con imágenes multiespectrales de 50 a 1000 metros de resolución (satélites NOAA AVHRR, TERRA MODIS, SPOT Vegetation, etc.). con un intervalo de periodicidad de 1 a 30 días. Las aplicaciones principales son: extracción de parámetros biofísicos y medioambientales (NDVI, temperatura del suelo, material combustible, riesgo de incendio, etc.), información para la obtención de los Indicadores Agroambientales estandarizados demandados por distintas organizaciones de Naciones Unidas, Unión Europea y España.

### **AI.2.2. Segunda fase: extracción de la información**

En esta fase el objetivo es la generación de dos productos, el Sistema de Información sobre Ocupación del Suelo en España (SIOSE) y el Plan Nacional de Indicadores Agroambientales por Teledetección (PNI).

### **AI.2.3. Tercera fase: diseminación de la información**

El objetivo de esta fase es poner toda esta información a disposición de todos los organismos de las Administraciones Públicas, así como para el resto de los agentes sociales que la demanden. Para esto se prevén varios mecanismos simultáneos, de los que se empleará de forma flexible el más idóneo en cada caso según las características de la situación y el tipo de información a transmitir: publicación en servidores de datos, Internet, transmisión vía FTP, entrega en soportes físicos ópticos o magnéticos, etc.

## **AI.3. Sistema de Información sobre Ocupación del Suelo en España (SIOSE)**

### **AI.3.1. Introducción**

El Sistema de Información sobre Ocupación del Suelo de España (SIOSE) es un ambicioso proyecto destinado a convertirse en un referente español y europeo en materia de información geográfica, cuyo objetivo es la integración de la información de las Bases de Datos de Ocupación del Suelo de las Comunidades Autónomas y de la Administración General del Estado (Instituto Geográfico Nacional, 2007). El SIOSE está

enmarcado dentro del PNOT y tiene la pretensión de establecer una gran infraestructura de información geográfica de uso multidisciplinar y actualizada periódicamente, a disposición de la Administración General del Estado y de las Comunidades Autónomas.

Las principales características del SIOSE son (Arozarena et al., 2006):

- Escala nominal: 1/25.000
- Unidad mínima cartografiable: 1 Ha para superficies artificiales y 2 Ha para el resto (superficies agrícolas y forestales) excepto los humedales que son 0,5 Ha.
- Periodo de actualización: 5 años (aunque se está estudiando la conveniencia de actualizar las zonas urbanas con mayor frecuencia).
- Basado en imágenes de: PNT, PNOA, PAO.
- Modelo de datos avanzado:
  - orientado a objetos: diseñado en UML.
  - multiparámetro: varios atributos por polígono.
  - multinivel
  - extensible y compatible con otros proyectos nacionales y europeos.

La entidad de trabajo es el polígono SIOSE, que es la unidad espacial del terreno que presenta una ocupación del suelo con cobertura homogénea. El polígono es la única entidad con geometría propia del modelo de datos SIOSE y esta definido por un conjunto de arcos que limitan su extensión superficial, separando dos entornos o coberturas de usos diferentes. Asociado al polígono se han definido dos superclases denominadas uso y cobertura. La cobertura está directamente referida al tipo de superficie en el terreno o elementos que aparecen sobre dicha superficie, y por tanto puede ser obtenida por sus propiedades biofísicas, mientras que el uso es un concepto relativo a las actividades socioeconómicas que se realizan sobre dicho terreno, y por tanto pueden superponerse en superficie.

El modelo de datos SIOSE permite la asignación de uno o más usos y una cobertura a un único polígono. Teniendo en cuenta que la cobertura de un polígono deberá ocupar siempre el 100% del mismo, sin embargo, el uso podrá diferir de este valor. Los cambios en el modelo de datos mantienen la interoperabilidad entre el SIOSE y otras bases de datos europeas, nacionales y autonómicas.

Los polígonos tendrán una cobertura simple cuando ésta sea única, y una cobertura compuesta cuando se encuentre formada por dos o más coberturas simples y/o compuestas a su vez. En función del tipo de combinación, la cobertura compuesta será asociación o mosaico. La asociación es la combinación de coberturas sin distribución fija, cuando éstas se encuentren entremezcladas indistintamente. El mosaico es la combinación de coberturas cuya distribución geométrica y separación entre ellas es claramente perceptible. En la Tabla 19 se muestra la clasificación de las coberturas en el SIOSE.

Tabla 19. Clasificación de las coberturas en el SIOSE.

Coberturas simples	Artificiales	Artificiales Edificación Zona verde artificial y arbolado urbano Lámina de agua artificial Vial, aparcamiento o zona peatonal Suelo no edificado Zonas de extracción o vertido
	Zonas agrícolas, forestales y naturales	Arbolado forestal: frondosas y coníferas Matorral Pastizal Terrenos sin vegetación Coberturas húmedas Coberturas de agua Cultivos: herbáceos, leñosos y prados
Coberturas compuestas	Dehesa Huerto familiar Asentamiento agrícola residencial Olivar/viñedo Artificial Compuesto	

### AI.3.2. Las zonas urbanas en el SIOSE

Las edificaciones son englobadas en el SIOSE dentro de la clase *Edificación*. Esta se define como una cobertura artificial simple que contiene construcciones fijas, hechas con materiales resistentes, destinadas a alojar personas, animales, vehículos, maquinaria, materiales, etc., cualquiera que sea su fin: residencial, comercial, industrial, etc. (Instituto Geográfico Nacional, 2007). En los atributos de esta clase, se definen cinco tipologías diferentes:

- *Edificio aislado*: Edificaciones destinadas a alojar personas, diseñadas para estar separadas unas de las otras. Su uso podrá ser residencial o comercial.
- *Edificio entre medianeras*: Edificaciones destinadas a alojar personas diseñadas para estar unas al lado de otras separadas por medianeras (pared lateral de contacto entre dos edificaciones que se levanta desde los cimientos hasta la cubierta). Su uso podrá ser residencial o comercial.
- *Vivienda unifamiliar adosada*: Edificaciones destinadas a alojar personas para su uso como vivienda de una sola familia, limitadas por medianeras que la separan de las viviendas adyacentes.
- *Vivienda unifamiliar aislada*: Edificaciones aisladas destinadas a alojar personas para su uso como vivienda de una sola familia.
- *Nave*: Edificaciones que pueden ser aisladas o adosadas, destinadas a alojar animales, vehículos, maquinaria, materiales, etc., para uso industrial o comercial. Normalmente tendrán techos altos y grandes puertas para permitir el acceso a su interior de elementos de gran tamaño.



Las edificaciones pueden estar presentes en el territorio de forma aislada o bien formando coberturas compuestas con otras coberturas simples o compuestas. De hecho, la forma más habitual de encontrar la clase *Edificación* en el SIOSE es integrada en una cobertura compuesta. Así, se distinguen tres asociaciones, definidas como la combinación de coberturas superpuestas espacialmente sin distribución fija, en las que la clase *Edificación* puede tener lugar: *Huerta Familiar*, *Asentamiento Agrícola Residencial*, *Artificial Compuesto*.

Por *Huerta Familiar* se entienden aquellas zonas fundamentalmente agrícolas con estructura de mosaico de parcelas de pequeño tamaño donde predominan las hortalizas y los pies sueltos de frutales u otros cultivos leñosos. Se trata de áreas generalmente en regadío intensivo, cuya producción se dedica principalmente al autoconsumo. Debido a sus características, la presencia de edificaciones dentro de esta asociación es mínima.

Según el SIOSE se clasificará como *Asentamiento Agrícola Residencial* aquellas zonas donde hay un claro y principal uso residencial del suelo, caracterizado por un poblamiento disperso de edificaciones, o bien concentraciones de pequeños núcleos de casas, alrededor de las cuales coexisten parcelas cultivadas con hortalizas y cultivos leñosos.

Las coberturas *Artificiales Compuestas* surgen al agruparse coberturas artificiales simples que por sus características en el terreno son fácilmente reconocibles y presentan un gran interés debido a la estructura que le dan al territorio. Las coberturas artificiales compuestas se clasifican tal y como se muestra en la Tabla 20.

Cada una de estas tres coberturas compuestas es una asociación con nombre propio que deben identificarse a partir de las coberturas simples que las componen y en las que se debe indicar el porcentaje de ocupación del suelo de cada una de las coberturas simples que las integran.

Las zonas urbanas y periurbanas están enmarcadas dentro de la clase *Urbano Mixto*, que representa áreas con superficie mayor de una hectárea ocupadas por edificaciones principalmente destinadas a viviendas y sus terrenos asociados, como son viales, zonas verdes artificiales, aparcamientos u otras construcciones. Estas superficies, aunque estarán destinadas principalmente a uso residencial, incluirán también otras edificaciones y sus terrenos asociados destinados a otros usos no residenciales (terciario, equipamiento/dotacional) que, o bien por su pequeño tamaño, o bien porque no se pueden diferenciar de la trama residencial, no puedan ser individualizados. La cobertura *Urbano Mixto* se categoriza según las siguientes clases: *Casco*, *Ensanche* y *Discontinuo*.

El *Casco* se caracteriza por tener una trama irregular en ocasiones con parcelación "gótica" (parcelas muy estrechas y con mucho fondo), viales muy estrechos y pocas zonas verdes. Generalmente responde a la topografía del terreno, con crecimientos sobre las vías preexistentes y limitados por los sucesivos perímetros defensivos. La tipología de las edificaciones que lo forman suele ser de edificios entre medianeras formando normalmente manzanas compactas. Puede, o no, coincidir con lo que se ha venido

conociendo como "casco histórico". En municipios de pequeña-mediana entidad en los que con frecuencia sólo encontraremos un "casco" coincidirá. Sin embargo, en municipios grandes lo normal será encontrar varios recintos "casco" que pueden corresponder a antiguos cascos históricos de municipios agregados o bien, simplemente, responder a la característica más relevante, que va a ser la irregularidad en la configuración de manzanas y en la propia parcelación.

Tabla 20. Clasificación de las coberturas Artificiales Compuestas en el SIOSE.

Urbano Mixto	Casco Ensanche Discontinuo
Primario	Agrícola / Ganadero Forestal Minero extractivo Piscifactoría
Industrial	Polígono industrial ordenado Polígono industrial sin ordenar Industria aislada
Terciario	Comercial y oficinas Parque recreativo Complejo hotelero Camping
Equipamiento / dotacional	Administrativo institucional Sanitario Cementerio Educación Penitenciario Religioso Cultural Deportivo Campo de golf Parque urbano
Infraestructuras	Transporte Energía Suministro de agua Telecomunicaciones Residuos

El *Ensanche* se define cómo una zona urbana que puede estar o no ya consolidada, producida basándose en un planeamiento urbano definido, que, generalmente, se desarrolla ordenando áreas en torno al casco existente. Se caracteriza por tener trama más regular, viales más anchos y mayor superficie de zonas verdes que el Casco. Las edificaciones que pudiera contener en su mayor parte serán de los tipos *Edificio aislado*, *Edificio entre medianeras*, *Vivienda unifamiliar adosada* o *Vivienda unifamiliar aislada* y normalmente no tendrán por qué formar manzanas compactas. Existirán diferentes tipos de Ensanche dependiendo de la tipología de las edificaciones o de la diferente proporción de cada una de las clases simples que la componen.

Zona urbana categorizada como *Discontinuo* que puede estar consolidada o en vía de consolidación, de trama regular producida por un planeamiento urbanístico definido y que, fundamentalmente, se distingue del Ensanche porque su conexión o contacto con la trama configurada por Casco-Ensanche es a través de una vía de comunicación. Se incluyen aquí urbanizaciones, colonias, etc., situadas en extrarradios.

Las áreas industriales se incluyen en la tipología *Industrial*, que son zonas de superficies artificiales en las que existen instalaciones destinadas a la obtención, elaboración, transformación, reparación, almacenamiento y distribución de productos.



Figura 55. Ejemplo de las clases de la cobertura *Urbano Mixto*. Ortofotografías en color natural.

(Fuente: Instituto Geográfico Nacional, 2007).

## AI.4.Referencias

Arozarena, A., Villa, G., Hermosilla, J., Papí, F., Valcárcel, N., Peces, J.J., Doménech, E., García, C., Tejeiro, J.A., 2006. El Plan Nacional de Observación del Territorio en España: situación actual y próximos pasos. Mappin Interactivo 111, 16-22.

Instituto Geográfico Nacional, 2007. Sistema de información de ocupación del suelo en España. Manual de Fotointerpretación. Versión 1.2.



## **Anejo II**

---

# **RESULTADO DE LA CLASIFICACIÓN CONTEXTUAL DE ENTORNOS URBANOS**

---

En este Anejo se recogen de manera completa las matrices de confusión resultantes de las pruebas de clasificación contextual en las diferentes zonas de estudio analizadas y considerando progresivamente los grupos de características descriptivas definidos.

Tabla 21. Matriz de confusión de la clasificación empleando las características a nivel de objeto de la imagen en Moncada.

	Referencia						Total	F. del Usuario
	Cultivos arbóreos	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	131	1		3			135	<b>0.97</b>
Ensanche		164	11		7	12	194	<b>0.85</b>
Nave		9	101				110	<b>0.92</b>
T. arables y cultivados	1		3	310	2		316	<b>0.98</b>
V. unif. aislada	1	7			122	21	151	<b>0.81</b>
V. unif. adosada		6			11	47	64	<b>0.73</b>
Total	133	187	115	313	142	80	970	
F. del Productor	<b>0.98</b>	<b>0.88</b>	<b>0.88</b>	<b>0.99</b>	<b>0.86</b>	<b>0.59</b>		<b>0.90</b>

Tabla 22. Matriz de confusión de la clasificación combinando las características a nivel de objeto de la imagen, altura y forma en Moncada.

	Referencia						Total	F. del Usuario
	Cultivos arbóreos	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	132		1	1	2		136	<b>0.97</b>
Ensanche	0	165	5		3	9	182	<b>0.91</b>
Nave	0	7	109			4	120	<b>0.91</b>
T. arables y cultivados	1			312			313	<b>1.00</b>
V. unif. aislada		5			134	16	155	<b>0.86</b>
V. unif. adosada		10			3	51	64	<b>0.80</b>
Total	133	187	115	313	142	80	970	
F. del Productor	<b>0.99</b>	<b>0.88</b>	<b>0.95</b>	<b>1.00</b>	<b>0.94</b>	<b>0.64</b>		<b>0.93</b>

Tabla 23. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, y del contexto interno en Moncada.

	Referencia						Total	F. del Usuario
	Cultivos arbóreos	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	131			1			132	<b>0.99</b>
Ensanche		173	7			6	186	<b>0.93</b>
Nave		7	107		1	2	117	<b>0.91</b>
T. arables y cultivados	2			311		1	314	<b>0.99</b>
V. unif. aislada		3		1	134	12	150	<b>0.89</b>
V. unif. adosada		4	1		7	59	71	<b>0.83</b>
Total	133	187	115	313	142	80	970	
F. del Productor	<b>0.98</b>	<b>0.93</b>	<b>0.93</b>	<b>0.99</b>	<b>0.94</b>	<b>0.74</b>		<b>0.94</b>

Tabla 24. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, del contexto interno y externo en Moncada.

	Referencia						Total	F. del Usuario
	Cultivos arbóreos	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	132			1			133	<b>0.99</b>
Ensanche		182	3			1	186	<b>0.98</b>
Nave		4	110		1	2	117	<b>0.94</b>
T. arables y cultivados	1			311			312	<b>1.00</b>
V. unif. aislada		1	1	1	133	11	147	<b>0.90</b>
V. unif. adosada			1		8	66	75	<b>0.88</b>
Total	133	187	115	313	142	80	970	
F. del Productor	<b>0.99</b>	<b>0.97</b>	<b>0.96</b>	<b>0.99</b>	<b>0.94</b>	<b>0.83</b>		<b>0.96</b>

Tabla 25. Matriz de confusión de la clasificación empleando las características a nivel de objeto de la imagen en Oliva.

	Referencia							Total	F. del Usuario
	T. arables y cultivados	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	V. unif. aislada	V. unif. adosada		
T. arables y cultivados	154	3	2	2		2		163	<b>0.94</b>
Cultivos arbóreos	3	197	2			4		206	<b>0.96</b>
Casco histórico		1	266	5	38	3	8	321	<b>0.83</b>
Edificio aislado	3		1	71	5	8	6	94	<b>0.76</b>
Ensanche			14	6	67		6	93	<b>0.72</b>
V. unif. aislada		4	6	9	1	115	30	165	<b>0.70</b>
V. unif. adosada			3	6	4	17	57	87	<b>0.66</b>
Total	160	205	294	99	115	149	107	1129	
F. del Productor	<b>0.96</b>	<b>0.96</b>	<b>0.90</b>	<b>0.72</b>	<b>0.58</b>	<b>0.77</b>	<b>0.53</b>		<b>0.82</b>

Tabla 26. Matriz de confusión de la clasificación combinando las características a nivel de objeto de la imagen, altura y forma en Oliva.

	Referencia							Total	F. del Usuario
	T. arables y cultivados	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	V. unif. aislada	V. unif. adosada		
T. arables y cultivados	155	4		1		3		163	<b>0.95</b>
Cultivos arbóreos	5	201				1	1	208	<b>0.97</b>
Casco histórico			269		27		7	303	<b>0.89</b>
Edificio aislado			1	86	5		5	97	<b>0.89</b>
Ensanche			17	6	82		2	107	<b>0.77</b>
V. unif. aislada			5	3		134	13	155	<b>0.86</b>
V. unif. adosada			2	3	1	11	79	96	<b>0.82</b>
Total	160	205	294	99	115	149	107	1129	
F. del Productor	<b>0.97</b>	<b>0.98</b>	<b>0.91</b>	<b>0.87</b>	<b>0.71</b>	<b>0.90</b>	<b>0.74</b>		<b>0.89</b>



Tabla 27. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, y del contexto interno en Oliva.

	Referencia							Total	F. del Usuario
	T. arables y cultivados	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	V. unif. aislada	V. unif. adosada		
T. arables y cultivados	156	5				1		162	<b>0.96</b>
Cultivos arbóreos	3	200						203	<b>0.99</b>
Casco histórico	1		273		24	1	6	305	<b>0.90</b>
Edificio aislado				92	4	1	8	105	<b>0.88</b>
Ensanche			17	2	86		1	106	<b>0.81</b>
V. unif. aislada			4	1		134	14	153	<b>0.88</b>
V. unif. adosada				4	1	12	78	95	<b>0.82</b>
Total	160	205	294	99	115	149	107	1129	
F. del Productor	<b>0.98</b>	<b>0.98</b>	<b>0.93</b>	<b>0.93</b>	<b>0.75</b>	<b>0.90</b>	<b>0.73</b>		<b>0.90</b>

Tabla 28. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, del contexto interno y externo en Oliva.

	Referencia							Total	F. del Usuario
	T. arables y cultivados	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	V. unif. aislada	V. unif. adosada		
T. arables y cultivados	154	3				1		158	<b>0.97</b>
Cultivos arbóreos	5	202						207	<b>0.98</b>
Casco histórico			284		2	1	3	290	<b>0.98</b>
Edificio aislado	1			92	2	1	8	104	<b>0.88</b>
Ensanche			5	1	110			116	<b>0.95</b>
V. unif. aislada			4	2		142	15	163	<b>0.87</b>
V. unif. adosada			1	4	1	4	81	91	<b>0.89</b>
Total	160	205	294	99	115	149	107	1129	
F. del Productor	<b>0.96</b>	<b>0.99</b>	<b>0.97</b>	<b>0.93</b>	<b>0.96</b>	<b>0.95</b>	<b>0.76</b>		<b>0.94</b>

Tabla 29. Matriz de confusión de la clasificación empleando las características a nivel de objeto de la imagen en Sagunto.

	Referencia								Total	F. del Usuario
	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	139		2	5		2	3	6	157	<b>0.89</b>
Casco histórico	3	125	4	50	1			11	194	<b>0.64</b>
Edificio aislado	1	2	59	13	2		5	12	94	<b>0.63</b>
Ensanche	2	28	27	162	4		3	7	233	<b>0.70</b>
Nave		1	2	6	104	4			117	<b>0.89</b>
T. arables y cultivados	5	5		1	4	228	1		244	<b>0.93</b>
V. unif. aislada	1		4	2		2	81	23	113	<b>0.72</b>
V. unif. adosada	6	9	5	5		2	28	102	157	<b>0.65</b>
Total	157	170	103	244	115	238	121	161	1309	
F. del Productor	<b>0.89</b>	<b>0.74</b>	<b>0.57</b>	<b>0.66</b>	<b>0.90</b>	<b>0.96</b>	<b>0.67</b>	<b>0.63</b>		<b>0.76</b>

Tabla 30. Matriz de confusión de la clasificación combinando las características a nivel de objeto de la imagen, altura y forma en Sagunto.

	Referencia								Total	F. del Usuario
	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	153				1	6			160	<b>0.96</b>
Casco histórico		137		31				4	172	<b>0.80</b>
Edificio aislado			81	13	4	1	1	7	107	<b>0.76</b>
Ensanche		26	13	193				6	238	<b>0.81</b>
Nave		1	5	3	102	5	2		118	<b>0.86</b>
T. arables y cultivados	4				5	224			233	<b>0.96</b>
V. unif. aislada		2	1	1	3	2	99	18	126	<b>0.79</b>
V. unif. adosada		4	3	3			19	126	155	<b>0.81</b>
Total	157	170	103	244	115	238	121	161	1309	
F. del Productor	<b>0.97</b>	<b>0.81</b>	<b>0.79</b>	<b>0.79</b>	<b>0.89</b>	<b>0.94</b>	<b>0.82</b>	<b>0.78</b>		<b>0.85</b>

Tabla 31. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, y del contexto interno en Sagunto.

	Referencia								Total	F. del Usuario
	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	153		1		2	7	1		164	<b>0.93</b>
Casco histórico		142	1	23				3	169	<b>0.84</b>
Edificio aislado			89	5	3			7	104	<b>0.86</b>
Ensanche		22	6	211				2	241	<b>0.88</b>
Nave		1	4	1	106	4	3		119	<b>0.89</b>
T. arables y cultivados	4				2	226			232	<b>0.97</b>
V. unif. aislada			1		1	1	102	14	119	<b>0.86</b>
V. unif. adosada		5	1	4	1		15	135	161	<b>0.84</b>
Total	157	170	103	244	115	238	121	161	1309	
F. del Productor	<b>0.97</b>	<b>0.84</b>	<b>0.86</b>	<b>0.86</b>	<b>0.92</b>	<b>0.95</b>	<b>0.84</b>	<b>0.84</b>		<b>0.89</b>

Tabla 32. Matriz de confusión de la clasificación combinando las características a nivel de de objeto de la imagen, altura y forma, del contexto interno y externo en Sagunto.

	Referencia								Total	F. del Usuario
	Cultivos arbóreos	Casco histórico	Edificio aislado	Ensanche	Nave	T. arables y cultivados	V. unif. aislada	V. unif. adosada		
Cultivos arbóreos	151		1		1	6	1		160	<b>0.94</b>
Casco histórico		157		4					161	<b>0.98</b>
Edificio aislado			95	5	2			8	110	<b>0.86</b>
Ensanche		11	5	234	2				252	<b>0.93</b>
Nave	1		2	1	106	3	1		114	<b>0.93</b>
T. arables y cultivados	5				3	228	1		237	<b>0.96</b>
V. unif. aislada						1	106	12	119	<b>0.89</b>
V. unif. adosada		2			1		12	141	156	<b>0.90</b>
Total	157	170	103	244	115	238	121	161	1309	
F. del Productor	<b>0.96</b>	<b>0.92</b>	<b>0.92</b>	<b>0.96</b>	<b>0.92</b>	<b>0.96</b>	<b>0.88</b>	<b>0.88</b>		<b>0.93</b>



## Anejo III

---

# LISTADO DE PUBLICACIONES RELACIONADAS CON ESTA TESIS

---

En este Anejo se referencian las publicaciones científicas derivadas total o parcialmente de los trabajos realizados por el autor durante el desarrollo de esta Tesis.

### AIII.1. Artículos en revistas indexadas

Balaguer, A., Ruiz, L.A., **Hermosilla, T.**, Recio, J.A., 2010. Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification, *Computers & Geosciences* 36 (2), 231-240.

Estornell, J., Ruiz, L.A., Velázquez-Martí, B., **Hermosilla, T.**, 2010. Analysis of the factors affecting LiDAR DTM accuracy in a steep shrub area. *International Journal of Digital Earth*. Doi: 10.1080/17538947.2010.533201.

Ruiz, L.A., Recio, J.A., Fernández-Sarría, A., **Hermosilla, T.**, 2011. A feature extraction software tool for agricultural object-based image analysis. *Computers and Electronics in Agriculture* 76 (4), 284-296.

**Hermosilla, T.**, Ruiz, L.A., Recio, J.A., Estornell, J., 2011. Evaluation of automatic building detection approaches combining high resolution imagery and LiDAR data. *Remote Sensing* 3, En prensa. (Aceptado: 1-Jun-2011).

**Hermosilla, T.**, Ruiz, L.A., Recio, J.A., Cambra-López, M. Contextual object-based image classification of urban areas. *Landscape and Urban Planning* (Enviado: 14-Feb-2011).

## **AIII.2. Comunicaciones en congresos científico-técnicos**

Recio, J.A., Ruiz, L.A., Fernández-Sarría, A., **Hermosilla, T.**, 2006. Integration of multiple feature extraction and object oriented classification of aerial images for map updating. *Proceedings of Second International Symposium on Recent Advances in Quantitative Remote Sensing*. 25-29 septiembre 2006, Torrente, España, pp.391-396.

Ruiz, L.A., Recio, J.A., **Hermosilla, T.**, 2007. Methods for automatic extraction of regularity patterns and its application to object-oriented image classification. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Munich, Alemania*, 36 (3/W49A), 117-121.

**Hermosilla, T.**, Ruiz, L.A., Fernández. Sarría, A., Recio, J.A., 2008. Detección automática de edificios en imágenes aéreas mediante técnicas de teledetección y análisis contextual. *Congreso Internacional sobre Ingeniería Geomática y Topográfica, TOP-CART 2008*, 18-20 febrero 2008, Valencia, España, 6p.

**Hermosilla, T.**, Ruiz, L.A., 2009. Detección automática de edificios combinando imágenes de satélite y datos Lidar. *Semana Geomática Internacional*, 3-5 marzo 2009, Barcelona, 9p.

Recio, J.A., Ruiz, L.A., Fernández, A., **Hermosilla, T.**, 2009. Extracción de características estructurales en un sistema de clasificación de imágenes basado en parcelas. *XIII Congreso Nacional de la Asociación Española de Teledetección*, 23-26 septiembre 2009, Calatayud, España, pp.577-580.

Estornell, J., Ruiz, L.A., **Hermosilla, T.**, 2009. Generación de un MDT a partir de datos Lidar utilizando procesos iterativos basados en la selección de alturas mínimas en una zona de montaña. *XIII Congreso Nacional de la Asociación Española de Teledetección*, 23-26 septiembre 2009, Calatayud, España, pp.481-484.

Recio, J.A., **Hermosilla, T.**, Ruiz, L.A., Fernández-Sarría, A., 2010. Addition of geographic ancillary data for updating geo-spatial databases. *The International*

Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Haifa, Israel, 38 (4-8-2-W9), 46-51.

**Hermosilla, T.**, Díaz-Manso, J.M., Ruiz, L.A., Recio, J.A., Fernández-Sarría, A., Ferradáns-Nogueira, P., 2010. Parcel-based image classification as a decision-making supporting tool for the Land Bank of Galicia (Spain). The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Haifa, Israel, 38 (4-8-2-W9), 40-45.

**Hermosilla, T.**, Almonacid, J., Fernández-Sarría, A., Ruiz, L.A., Recio, J.A., 2010. Combining features extracted from imagery and lidar data for object-oriented classification of forest areas. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Gante, Bélgica, 38 (4/C7), 6p.

Ruiz, L.A., Recio, J.A., Fernández-Sarría, A., **Hermosilla, T.**, 2010. A tool for object descriptive feature extraction: application to image classification and map updating. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Gante, Bélgica, 38 (4/C7), 6p.

Ruiz, L.A., **Hermosilla, T.**, Serisa, G., Recio, J.A., Fernández-Sarría, A., 2011. A Multi-Approach and Object-Oriented Strategy for Updating LU/LC Geo-databases Based on Worldview-2 Imagery. Geospatial World Forum 2011, 18-21 enero, Hyderabad, India.

**Hermosilla, T.**, Ruiz, L.A., Recio, J.A., Cambra-López, M, 2011. Efficiency of context-based attributes for land use classification of urban environments. Aceptado en ISPRS Hannover Workshop 2011 High-Resolution Earth Imaging for Geospatial Information.

### **AIII.3. Otras publicaciones**

**Hermosilla, T.**, Ruiz, L.A., Recio, J.A., 2010. Detección automática de edificios mediante imágenes de alta resolución y datos lidar para la actualización de bases de datos cartográficas en entornos urbanos. Revista de Teledetección 34, 89-93.

Balaguer-Beser, A., **Hermosilla, T.**, Recio, J., Ruiz, L.A., 2011. Semivariogram calculation optimization for object-oriented image classification. Modelling in Science Education and Learning 4 (7), xxx-xxx.