



UNIVERSIDAD
POLITECNICA
DE VALENCIA

DPTO. DE INGENIERÍA CARTOGRÁFICA, GEODESIA Y FOTOGAMETRÍA

**TÉCNICAS DE EXTRACCIÓN DE CARACTERÍSTICAS Y
CLASIFICACIÓN DE IMÁGENES ORIENTADA A
OBJETOS APLICADAS A LA ACTUALIZACIÓN DE
BASES DE DATOS DE OCUPACIÓN DEL SUELO**

TESIS DOCTORAL

Presentada por:

Director:

D. Jorge Abel Recio Recio

D. Luis Ángel Ruiz Fernández

Valencia, 2009

A mis padres

Agradecimientos

Agradezco a mis compañeros y amigos del Grupo de Investigación en Cartografía Geoambiental y Teledetección y de la Unidad Docente en Cartografía y Teledetección su colaboración en el desarrollo de esta tesis, ya que con sus numerosos consejos, sugerencias y muestras de ánimo han contribuido a crear este documento.

Mención especial en estos agradecimientos para Luis Ángel que en su calidad de tutor ha dirigido en estos años mi carrera investigadora, ha supervisado y participado concienzudamente en este trabajo y hace un esfuerzo continuado para su difusión y aplicación práctica.

Doy las gracias también a Txomin por su inestimable ayuda en la programación en IDL y por la minuciosa revisión que ha llevado a cabo de este texto.

No quiero dejar de agradecer a mis compañeros Alfonso y Maru que con su ayuda en mis obligaciones docentes me han permitido dedicarme con mayor intensidad a este trabajo.

Administraciones públicas como el Instituto Geográfico Nacional, el Instituto Cartográfico Valenciano, el Instituto Murciano de Investigación y Desarrollo Agrario y Alimentario o el Banco de Terras de Galicia y empresas como Agroseguros S.A. han apoyado el desarrollo de esta tesis con medios, datos, propuestas sobre líneas de trabajo y críticas constructivas. A todos ellos les doy las gracias por mostrar su interés en este trabajo.

Agradezco por último a mi familia y amigos, que bien de forma directa, como David en el trabajo de campo, o bien de forma indirecta con su cariño y compañía me han ayudado tanto a realizar este trabajo como a evadirme de él cuando era necesario.

RESUMEN

A lo largo de los últimos años ha aumentado el interés y la necesidad de disponer de una información de usos y coberturas del territorio fiable y actualizada, siendo numerosos los proyectos de carácter local, nacional e internacional cuyo objetivo es la creación y actualización de bases de datos de usos y ocupación del suelo. Los procedimientos metodológicos para llevar a cabo estas tareas requieren un alto grado de intervención humana, ya que están basados casi íntegramente en la fotointerpretación de imágenes o su comparación con otras imágenes u otra base de datos. Los recientes avances en la calidad de los sensores, tanto aerotransportados como espaciales, y en su cantidad, han supuesto un incremento significativo en la disponibilidad de imágenes de alta resolución. Por otra parte, desde las administraciones públicas se están gestionando iniciativas conjuntas para adquirir y facilitar la disponibilidad de datos e imágenes aéreas y satelitales, como es el Plan Nacional de Observación de la Tierra (PNOT), al tiempo que se desarrollan nuevas metodologías para la explotación de estos datos. Es en esta línea de trabajo donde se enmarca esta tesis, cuyos desarrollos y ensayos pretenden aportar una contribución a la automatización progresiva de los procesos de obtención de información relativa a los usos del territorio mediante el análisis de las imágenes disponibles de forma regular por los planes de observación en España, así como su integración con la información contenida en las bases de datos cartográficas ya existentes.

El objetivo general de esta tesis es el desarrollo de metodologías para la actualización de bases de datos cartográficas de ocupación del suelo, aplicadas a zonas agrícolas mediterráneas y basadas en el empleo de datos de observación de la Tierra y geográficos disponibles regularmente en España para los trabajos de actualización cartográfica. Estos datos suelen consistir en imágenes aéreas de la fecha en la que se quiere actualizar la cartografía, la misma base cartográfica que se va a actualizar y otro tipo de información auxiliar, variable en función de cada caso concreto. No se han considerado otras fuentes de datos que, si bien supondrían un complemento eficaz a los datos básicos, como información de tipo altimétrico (lidar), multitemporal, hiperespectral, microondas, etc., su coste limitaría su aplicación en el escenario actual español, y que no es probable que estén disponibles de forma periódica y con una cobertura estatal.

Esta actualización se aborda mediante la integración y el análisis de información cartográfica en formato vectorial, imágenes aéreas de alta resolución, la información alfanumérica contenida en la base de datos a actualizar y la información auxiliar. En concreto, se ha utilizado un mosaico de ortoimágenes aéreas con resolución espacial de 0.5m/píxel, obtenido tras la fusión de las bandas pancromática y multispectrales tomadas con el sistema de cámaras fotogramétricas DMC. La base de datos cartográfica utilizada en los ensayos corresponde a la base cartográfica de la D.G. de Catastro, junto a su

información temática asociada, en once polígonos catastrales en el término municipal de Benicarló (Castellón). Como información auxiliar se ha utilizado la altitud media, la pendiente media y la distancia a la costa extraída de modelos digitales del terreno con una resolución espacial de 1m. La integración de los datos se realiza mediante la extracción de características y la clasificación de imágenes orientada a objetos. En primer lugar, la cartografía aporta los límites espaciales que delimitan los objetos de estudio, que en nuestro caso se corresponden con la subparcela catastral. En segundo lugar, el uso de las subparcelas se asigna mediante el análisis de un conjunto de características, como son las extraídas a partir del análisis de una imagen de alta resolución, o las definidas por su forma, su uso previo, etc.

Así, la descripción cuantitativa de cada objeto se hace por medio de un conjunto de características diseñadas específicamente para la descripción de parcelas fundamentalmente agrícolas. La información que proporcionan estas características se refiere a la respuesta espectral de cada objeto o parcela, a la textura, a la existencia de elementos con una estructura o patrón determinado (marcos de plantación,...), así como a las propiedades de algunos de esos elementos y, por último, a la propia geometría de las parcelas o características de forma. El desarrollo y aplicación de estas características descriptoras constituye el núcleo central de esta tesis.

Se han evaluado, mediante una serie de ensayos, la utilización y el rendimiento de estas características como descriptores de las propiedades que definen los usos de las parcelas. Así, por ejemplo, se ha comprobado que la posición del primer máximo del semivariograma omnidireccional calculado sobre la banda del infrarrojo es un indicador preciso del diámetro de la copa de los árboles dispuestos según un marco de plantación regular. Así mismo, la transformada de *Hough* sobre una imagen binaria con la localización de árboles permite determinar las dimensiones de los marcos de plantación en cultivos arbóreos. Se ha diseñado un método de segmentación automática y caracterización de árboles por parcela para determinar la superficie cubierta por árboles en una parcela y, al mismo tiempo, la clase de cultivo presente, dentro de la variación existente en la zona de estudio. También se ha comprobado que el uso previo de una parcela, introducido como una característica descriptora más de las parcelas, incrementa la fiabilidad de la clasificación de manera muy relacionada con el grado de actualización de la base de datos. En los ensayos realizados este incremento está próximo al 4%.

Como método de decisión para la asignación de clases se ha utilizado un multclasificador de tipo *boosting* sobre un conjunto de árboles de decisión creados mediante el algoritmo C5.0, a partir de un conjunto de ejemplos o muestras de aprendizaje. Además de la clase asignada por el clasificador a cada parcela se obtiene un valor de la confianza con la que el clasificador hace la asignación de la clase, el cual proporciona información objetiva sobre la fiabilidad en la clasificación de cada objeto.

La metodología de clasificación propuesta se ha evaluado en un conjunto de subparcelas del área de estudio, considerando un total de 10 clases. La fiabilidad global obtenida es del 78.4% cuando se tiene en cuenta el uso previo, frente al 74.7% cuando no se tiene en cuenta.

Por último, se evalúa la metodología propuesta en el contexto de un problema real de actualización, en el cual se compara la clasificación de las subparcelas con la clase contenida en la base de datos que se pretende actualizar, de forma que se detecten las discordancias entre ambas fuentes. En estos casos, es necesaria una revisión por parte de un fotointérprete con el fin de determinar si ha existido un cambio real o un error de clasificación, definiendo la clase final de asignación.

La metodología presentada en esta tesis se ha utilizado con éxito en varios trabajos de producción como la actualización del SIG Citrícola de la Comunidad Valenciana en la provincia de Castellón, en la actualización del Inventario de Cultivos de la Región de Murcia y en la elaboración de cartografía de usos del suelo para el *Banco de Terras de Galicia*. Las fiabilidades obtenidas en las clasificaciones de estos trabajos oscilan entre el 78% y el 93%, siendo paisajes, leyendas y datos de partida muy distintos entre sí. En todos los casos, la aplicación de esta metodología supone una reducción significativa en los tiempos de actualización de las bases de datos al reducirse en gran medida el número de parcelas a revisar por los fotointérpretes.

ABSTRACT

In the last years, the needs of obtaining reliable and updated information of land use/land cover have increased. Several local, national and international projects are carried out to obtain and update land use/land cover geospatial databases. Nowadays, the existing methodologies require a high amount of human intervention, because they are mainly based on image interpretation or on the comparison of an image with other image or with a database.

Recent advances in quality and quantity of airborne and satellite sensors have entailed an important increase in the availability of high resolution images. Besides, Spanish public administrations are working jointly in the National Plan for Territory Observation (PNOT) to acquire and to distribute satellite and aerial imagery. At the same time, new methodologies are being developed to analyze these data. Tests and developments included in this Thesis aims for contributing to the progressive automation of land use information extraction by combining image analysis of data provided by PNOT with information contained in databases.

The aim of this Thesis is the study and evaluation of methodologies for cartographic updating of land use/land cover databases in agricultural Mediterranean landscapes combining information usually available in Spain for updating cartography projects: images of the update date, the cartographic database to be updated and ancillary information. Different data sources like LIDAR, multi-temporal images, hyper-spectral images, microwaves images, etc. haven't been considered because their cost would limit their use in the present Spanish situation and probably, they will not be available periodically and with coverage for the whole country.

The update is performed through integration and analysis of cartographic information in different formats: vector cartography, alphanumeric information contained in the database to be updated and high resolution aerial images. Specifically, an ortoimage mosaic with 0.5m/pixel has been used, generated combining the panchromatic band and the multi-spectral bands acquired with the DMC photogrammetric camera system. The cartographic database used in tests is the cadastral cartography with its alphanumeric information in eleven cadastral polygons located in the municipal district of Benicarló (Castellón). Ancillary information considered is: altitude, slope and coast distance that have been extracted from Digital Terrain Models with a spatial resolution of 1m. The data integration is made by means of feature extraction and object-based image classification. The cartography provides the boundaries to define the objects, which are the cadastral sub-parcels in our work. The land use of each object is determined with the analysis of its previous use, its shape and an exhaustive set of features extracted from the high resolution image.

Quantitative description of each object is carried out by means of a feature set specifically designed to describe agricultural parcels. Information provided by these features covers several aspects: spectral response, texture, planting pattern, objects contained in the parcel, shape of the parcel, etc. Development and application of these descriptive features are the core of this Thesis.

In several tests, the performance of these features to describe the characteristics of the uses in the parcels has been evaluated. For example, position of the first maximum point in the omnidirectional semivariogram calculated over the infrared band is a precise indicator of diameter of crown trees planted with regular planting patterns. Besides, the Hough transform applied over a binary image of tree locations allows determining the size of planting patterns in tree crops. An automatic method to segment and to describe trees in the parcels has been designed. This method gives information regarding tree area in the parcel and tree characteristics to determine the class of tree crops.

It has been proved, that the previous use of a parcel employed as an additional feature increases the accuracy of the classifications. This accuracy increase is related with the updating degree of the database and its value was around 4% in the tests done.

The multi-classifier boosting was employed over a set of decision trees, created with C5.0 algorithm from a set of training samples, to assign the class to each object. In addition to the assigned class, a confidence value is got that indicates the reliability of the outcome classification being correct.

The proposed parcel-based classification considered 10 classes, and was evaluated with a set of parcels in the working area. The overall accuracy, when the previous use was considered, was 78.4% and it was 74.7% without considering it.

To conclude, this methodology was tested in the context of a real updating problem. Comparing the classes assigned to the parcels with the information contained in the database to update, detected discrepancies are due to changes in the land use or to classification errors and must be checked by photo-interpreters in order to determine the actual class.

The described methodology has been successfully applied in some production works: detecting changes in the citrus inventory of Castellón, updating the crop inventory in the region of Murcia and mapping the land use for the Land Bank of Galicia. Overall accuracies obtained in these works, with different data, legends and landscapes, ranged between 78% and 93%. In all cases, the application of this methodology involves a substantial decrease in the amount of parcels to be reviewed by photo-interpreters which is reflected in a great reduction in the necessary time for updating databases.

RESUM

Al llarg dels últims anys ha augmentat l'interés i la necessitat de disposar d'una informació d'usos i cobertures del territori fiable i actualitzada, sent nombrosos els projectes de caràcter local, nacional i internacional l'objectiu dels quals és la creació i actualització de bases de dades d'usos i ocupació del sòl. Els procediments metodològics per a dur a terme estes tasques requereixen un alt grau d'intervenció humana, ja que estan basats quasi íntegrament en la fotointerpretació d'imatges o la seua comparació amb altres imatges o una altra base de dades. Els recents avanços en la qualitat dels sensors, tant aerotransportats com espacials, i en la seua quantitat, han suposat un increment significatiu en la disponibilitat d'imatges d'alta resolució. D'altra banda, des de les administracions públiques s'estan gestionant iniciatives conjuntes per a adquirir i facilitar la disponibilitat de dades i imatges aèries i satelital, com és el Pla Nacional d'Observació de la Terra (PNOT), alhora que es desenvolupen noves metodologies per a l'explotació d'estes dades. És en esta línia de treball on s'emmarca esta tesi. Els seus desenrotllaments i els seus assajos pretenen aportar una contribució a l'automatització progressiva dels processos d'obtenció d'informació relativa als usos del territori per mitjà de l'anàlisi de les imatges disponibles de forma regular pels plans d'observació a Espanya, així com la seua integració amb la informació continguda en les bases de dades cartogràfiques ja existents.

L'objectiu general d'esta tesi és el desenvolupament de metodologies per a l'actualització de bases de dades cartogràfiques d'ocupació del sòl, aplicades a zones agrícoles mediterrànies i basades en la utilització de dades geogràfiques i d'observació de la Terra i disponibles regularment a Espanya per als treballs d'actualització cartogràfica. Estes dades solen consistir en imatges aèries de la data en què es vol actualitzar la cartografia, la mateixa base cartogràfica que es va a actualitzar i un altre tipus d'informació auxiliar, variable en funció de cada cas concret. No s'han considerat altres fonts de dades que, si bé suposarien un complement eficaç a les dades bàsiques, com a informació de tipus altimètric (lidar), multitemporal, hiperespectral, microones, etc., el seu cost limitaria la seua aplicació en l'escenari actual espanyol, i que no és probable que estiguen disponibles de forma periòdica i amb una cobertura estatal.

Esta actualització s'aborda per mitjà de la integració i l'anàlisi d'informació cartogràfica en format vectorial, imatges aèries d'alta resolució, la informació alfanumèrica continguda en la base de dades a actualitzar i la informació auxiliar. En concret, s'ha utilitzat un mosaic d'ortoimatges aèries amb resolució espacial de 0.5m/píxel, obtingut després de la fusió de les bandes pancromàtica i multispectrals preses amb el sistema de càmeres fotogramètriques DMC. La base de dades cartogràfica utilitzada en els assajos correspon a la base cartogràfica de la D.G. de Cadastre, junt amb la seua informació

temàtica associada, en onze polígons cadastrals en el terme municipal de Benicarló (Castelló). Com a informació auxiliar s'ha utilitzat l'altitud mitjana, el pendent mig i la distància a la costa extreta de models digitals del terreny amb una resolució espacial de 1m. La integració de les dades es realitza per mitjà de l'extracció de característiques i la classificació d'imatges orientada a objectes. En primer lloc, la cartografia aporta els límits espacials que delimiten els objectes d'estudi, que en el nostre cas es corresponen amb la subparcel·la cadastral. En segon lloc, l'ús de les subparcel·les s'assigna per mitjà de l'anàlisi d'un conjunt de característiques, com són les extretes a partir de l'anàlisi d'una imatge d'alta resolució, o les definides per la seua forma, el seu ús previ, etc.

Així, la descripció quantitativa de cada objecte es fa per mitjà d'un conjunt de característiques dissenyades específicament per a la descripció de parcel·les fonamentalment agrícoles. La informació que proporcionen estes característiques es referix a la resposta espectral de cada objecte o parcel·la, a la textura, a l'existència d'elements amb una estructura o patró determinat (marcs de plantació,...), així com a les propietats d'alguns d'eixos elements i, finalment, a la pròpia geometria de les parcel·les o característiques de forma. El desenvolupament i aplicació d'estes característiques descriptores constituïx el nucli central d'esta tesi.

S'han avaluat, per mitjà d'una sèrie d'assajos, la utilització i el rendiment d'estes característiques com a descriptors de les propietats que defineixen els usos de les parcel·les. Així, per exemple, s'ha comprovat que la posició del primer màxim del semivariograma omnidireccional calculat sobre la banda de l'infraroig és un indicador precís del diàmetre de la copa dels arbres disposats segons un marc de plantació regular. Així mateix, la transformada d'Hough sobre una imatge binària amb la localització d'arbres permet determinar les dimensions dels marcs de plantació en cultius arboris. S'ha dissenyat un mètode de segmentació automàtica i caracterització d'arbres per parcel·la per a determinar la superfície coberta per arbres en una parcel·la i, al mateix temps, la classe de cultiu present, dins de la variació existent en la zona d'estudi. També s'ha comprovat que l'ús previ d'una parcel·la, introduït com una característica descriptora més de les parcel·les, incrementa la fiabilitat de la classificació de manera molt relacionada amb el grau d'actualització de la base de dades. En els assajos realitzats este increment està pròxim al 4%.

Com a mètode de decisió per a l'assignació de classes s'ha utilitzat un multiclassificador de tipus *boosting* sobre un conjunt d'arbres de decisió creats per mitjà de l'algoritme C5.0, a partir d'un conjunt d'exemples o mostres d'aprenentatge. A més de la classe assignada pel classificador a cada parcel·la s'obté un valor de la confiança amb què el classificador fa l'assignació de la classe, el qual proporciona informació objectiva sobre la fiabilitat en la classificació de cada objecte.

La metodologia de classificació proposada s'ha avaluat en un conjunt de subparcel·les de l'àrea d'estudi, considerant un total de 10 classes. La fiabilitat global

obtinguda és del 78.4% quan es té en compte l'ús previ, enfront del 74.7% quan no es té en compte.

Finalment, s'avalua la metodologia proposada en el context d'un problema real d'actualització, en el qual es compara la classificació de les subparcel·les amb la classe continguda a la base de dades que es pretén actualitzar, de manera que es detecten les discrepàncies entre ambdós fonts. En estos casos, és necessària una revisió per part d'un fotointèrpret a fi de determinar si ha existit un canvi real o un error de classificació, definint la classe final d'assignació.

La metodologia presentada en esta tesi s'ha utilitzat amb èxit en diversos treballs de producció com l'actualització del SIG Citrícola de la Comunitat Valenciana en la província de Castelló, en l'actualització del Inventari de Cultius de la Regió de Múrcia i en l'elaboració de cartografia d'usos del sòl per al *Banco de Terras de Galicia*. Les fiabilitats obtingudes en les classificacions d'estos treballs oscil·len entre el 78% i el 93%, sent paisatges, llegendes i dades de partida molt distints entre si. En tots els casos, l'aplicació d'esta metodologia suposa una reducció significativa en els temps d'actualització de les bases de dades al reduir-se en gran manera el nombre de parcel·les a revisar pels fotointèrprets.

ÍNDICE DE FIGURAS

| | |
|--|-----|
| Figura 2-1. Información alfanumérica de una parcela catastral..... | 20 |
| Figura 2-2. Consulta descriptiva y gráfica de una parcela catastral | 20 |
| Figura 2-3. Información alfanumérica de una parcela | 27 |
| Figura 2-4. Información alfanumérica de los recintos contenidos en la parcela anterior .. | 27 |
| Figura 2-5. Informe gráfico generado por la aplicación SIGPAC..... | 28 |
| Figura 2-6. Fragmento del Mapa Forestal Español..... | 30 |
| Figura 2-7. Fragmento del Mapa de Cultivos y Aprovechamientos con su leyenda correspondiente..... | 32 |
| Figura 2-8. Matriz de cambios del CLC2000 respecto al CLC90 | 35 |
| Figura 3-1. Clasificadores de contexto | 50 |
| Figura 3-2. Segmentación de imágenes por parcelas..... | 62 |
| Figura 3-3. Ejemplo de red neuronal artificial | 66 |
| Figura 3-4. Flujo de trabajo en la aplicación del conocimiento inductivo en la clasificación de imágenes..... | 71 |
| Figura 3-5. Clasificación cuadrangular realizada por un árbol de decisión con dos atributos numéricos..... | 73 |
| Figura 3-6. Árbol de decisión | 74 |
| Figura 3-7. Estructura de un árbol de clasificación en Erdas Imagine Expert System | 75 |
| Figura 3-8. Estructura de un árbol de clasificación en ENVI..... | 75 |
| Figura 3-9. Módulo de creación y aplicación de árboles de decisión en IDRISI | 76 |
| Figura 3-10. Poda de un árbol de decisión | 86 |
| Figura 3-11. Diagrama de estados de transición | 96 |
| Figura 4-1. Mapa de situación | 99 |
| Figura 4-2. Zona de estudio..... | 100 |
| Figura 4-3. Modelo digital de elevaciones de la zona de estudio | 100 |
| Figura 4-4. Parcelario superpuesto sobre imagen falso color infrarrojo | 102 |
| Figura 4-5. Muestras de la clase AGUA..... | 105 |
| Figura 4-6. Muestras de la clase ALGARROBOS..... | 105 |
| Figura 4-7. Muestras de la clase CÍTRICOS ADULTOS ALINEADOS | 106 |
| Figura 4-8. Muestras de la clase CÍTRICOS ADULTOS INDEPENDIENTES | 106 |
| Figura 4-9. Muestras de la clase CÍTRICOS IRREGULARES..... | 107 |
| Figura 4-10. Muestras de la clase CÍTRICOS JÓVENES | 107 |
| Figura 4-11. Muestras de la clase EDIFICIOS | 108 |
| Figura 4-12. Muestras de la clase JARDINES | 108 |
| Figura 4-13. Muestras de la clase MATORRAL..... | 109 |
| Figura 4-14. Muestras de la clase OLIVOS..... | 109 |

| | |
|---|-----|
| Figura 4-15. Muestras de la clase PLANTONES DE CÍTRICOS..... | 110 |
| Figura 4-16. Muestras de la clase REGADÍO | 110 |
| Figura 4-17. Muestras de la clase SUELO DESNUDO | 111 |
| Figura 4-18. Muestras de la clase VÍAS DE COMUNICACIÓN | 111 |
| Figura 5-1. Flujo de procesos, datos y ensayos..... | 115 |
| Figura 5-2. Media de los niveles digitales por clase | 118 |
| Figura 5-3. Desviación típica de los ND por clase | 119 |
| Figura 5-4. Ejemplos de distintos marcos de plantación..... | 124 |
| Figura 5-5. Carácter mixto de una función aleatoria | 125 |
| Figura 5-6. Semivariograma experimental | 127 |
| Figura 5-7. Parámetros del semivariograma experimental..... | 127 |
| Figura 5-8. Semivariograma con efecto agujero..... | 128 |
| Figura 5-9. Interpretación del semivariograma con efecto agujero | 130 |
| Figura 5-10. Parcelas agrícolas con sus correspondientes semivariogramas..... | 134 |
| Figura 5-11. Puntos máximos y mínimos en el semivariograma | 136 |
| Figura 5-12. Localización de plantones mediante la búsqueda de mínimos locales | 140 |
| Figura 5-13. Localización de árboles adultos mediante la búsqueda de máximos locales | 140 |
| Figura 5-14. Parámetros de la ecuación normal de la recta..... | 143 |
| Figura 5-15. Representación de un punto en el dominio de Hough..... | 144 |
| Figura 5-16. Representación de una recta en el dominio imagen y en el dominio de Hough..... | 144 |
| Figura 5-17. Nube de puntos en el espacio imagen y su representación en el dominio de Hough | 146 |
| Figura 5-18. Nube de puntos en el espacio imagen y su representación en el dominio de Hough | 146 |
| Figura 5-19. Histograma de frecuencias normalizado correspondiente a las 180 direcciones posibles..... | 147 |
| Figura 5-20. Detección de alineaciones en una parcela..... | 147 |
| Figura 5-21. Detección de líneas en una parcela..... | 148 |
| Figura 5-22. Separación entre árboles en un marco de plantación..... | 149 |
| Figura 5-23. Obtención de distancias entre rectas paralelas..... | 150 |
| Figura 5-24. Proceso de obtención de los coeficientes de filtrado | 153 |
| Figura 5-25. Aplicación iterativa del método de filtrado ponderado..... | 154 |
| Figura 5-26. Perfil espectral sobre la imagen original y las imágenes filtradas..... | 155 |
| Figura 5-27. Aplicación iterativa del método de filtrado ponderado..... | 155 |
| Figura 5-28. Perfil espectral sobre la imagen original y las imágenes filtradas..... | 156 |
| Figura 5-29. Ejemplo de evolución de los prototipos u grupos formados con el algoritmo K medias | 157 |

| | |
|---|-----|
| Figura 5-30. Ejemplos de la clasificación por el método K medias..... | 158 |
| Figura 5-31. Triángulo de color HSI. Color e intensidad en el modelo HSI | 160 |
| Figura 5-32. Detección de sombras | 160 |
| Figura 5-33. Máscara de filtro laplaciano..... | 161 |
| Figura 5-34. Aplicación del filtro laplaciano sobre una imagen binaria | 162 |
| Figura 5-35. Selección automática de píxeles de árbol y de suelo | 163 |
| Figura 5-36. Selección automática de píxeles de árbol y de suelo..... | 163 |
| Figura 5-37. Determinación de umbrales para la parcela de la figura 5-35 | 163 |
| Figura 5-38. Regla de clasificación | 164 |
| Figura 5-39. Segmentación de árboles..... | 164 |
| Figura 5-40. Valores de dirección del código cadena | 165 |
| Figura 5-41. Estimación del perímetro mediante el conteo de los lados de un objeto | 167 |
| Figura 5-42. Ajuste de una elipse..... | 170 |
| Figura 5-43. Ajuste de elipses..... | 171 |
| Figura 5-44. Modelo digital de elevaciones de la zona de estudio | 173 |
| Figura 5-45. Modelo de distancias a la costa | 174 |
| Figura 6-1. Árbol de decisión para la separación de las parcelas con marcos de plantación regulares | 181 |
| Figura 6-2. Proporción de parcelas con una diferencia inferior a la indicada en la determinación de cada dimensión de los marcos de plantación | 183 |
| Figura 6-3. Parcelas con marcos de plantación incorrectamente detectados | 184 |
| Figura 6-4. Delineación manual de copas | 185 |
| Figura 6-5. Delineación manual de copas | 186 |
| Figura 6-6. Delineación manual de copas | 186 |
| Figura 6-7. Áreas segmentadas frente a áreas delineadas..... | 188 |
| Figura 6-8. Media aritmética de las características de tamaño | 190 |
| Figura 6-9. Media aritmética de las características de forma | 191 |
| Figura 6-10. Media aritmética de las características espectrales | 192 |
| Figura 6-11. Árbol de decisión creado a partir de 20 características..... | 193 |
| Figura 6-12. Árbol de decisión creado a partir de 12 características..... | 195 |
| Figura 6-13. Fiabilidades de clasificación para las clases secano y regadío | 200 |
| Figura 6-14. Árbol de decisión | 204 |
| Figura 6-15. Fiabilidades globales obtenidas en los ensayos | 208 |
| Figura 6-16. Fiabilidades de productor y de usuario obtenidas en las clasificaciones | 208 |
| Figura 6-17. Comparación de errores entre clasificaciones..... | 209 |
| Figura 6-18. Porcentaje medio de parcelas de entrenamiento clasificadas considerando el uso previo | 210 |
| Figura 6-19. Árboles de clasificación creados en el ensayo con la BBDD actualizada al 90%..... | 212 |

| | |
|---|-----|
| Figura 6-20. Árbol de decisión para la extracción de vías de comunicación..... | 218 |
| Figura 6-21. Caminos desaparecidos y no eliminados en la cartografía | 219 |
| Figura 6-22. Cursos fluviales clasificados como vías de comunicación | 220 |
| Figura 6-23. Parcelas irregulares clasificadas como vías de comunicación | 220 |
| Figura 6-24. Caminos no detectados | 221 |
| Figura 6-25. Fiabilidad global estimada para las variables espectrales..... | 223 |
| Figura 6-26. Fiabilidad global estimada para las variables de textura y de la transformada de Hough..... | 223 |
| Figura 6-27. Fiabilidad global estimada para las variables del semivariograma y la segmentación de árboles | 224 |
| Figura 6-28. Fiabilidad global estimada para las variables topográficas y de la clasificación por píxel..... | 225 |
| Figura 6-29. Fiabilidad global estimada con las 37 variables seleccionadas..... | 226 |
| Figura 6-30. Árbol de decisión creado con 37 variables | 228 |
| Figura 6-31. Árbol de decisión creado con 37 variables más el uso catastral..... | 232 |
| Figura 6-32. Comparación de las fiabilidades de usuario y de productor..... | 234 |
| Figura 6-33. Parcelas de la clase <i>Agua</i> clasificadas como <i>Suelo desnudo</i> y <i>Edificios</i> | 237 |
| Figura 6-34. Parcelas de la clase <i>Algarrobos</i> clasificadas como <i>Matorral</i> | 238 |
| Figura 6-35. Parcelas de la clase <i>Algarrobos</i> clasificadas como <i>Suelo desnudo</i> | 238 |
| Figura 6-36. Parcelas de la clase <i>Cítricos</i> clasificadas como <i>Plantones</i> | 239 |
| Figura 6-37. Parcelas de la clase <i>Cítricos</i> clasificadas como <i>Jardín</i> | 240 |
| Figura 6-38. Parcelas de la clase <i>Cítricos</i> clasificadas como <i>Algarrobos</i> | 240 |
| Figura 6-39. Parcelas de la clase <i>Cítricos</i> clasificadas como <i>Olivos</i> | 241 |
| Figura 6-40. Tipologías de edificios en la zona de estudio..... | 242 |
| Figura 6-41. Parcelas de la clase <i>Edificios</i> clasificadas como <i>Jardín</i> | 242 |
| Figura 6-42. Parcelas de la clase <i>Jardín</i> clasificadas como <i>Algarrobos</i> | 243 |
| Figura 6-43. Parcelas de la clase <i>Jardín</i> clasificadas como <i>Cítricos</i> | 243 |
| Figura 6-44. Parcelas de la clase <i>Jardín</i> clasificadas como <i>Suelo desnudo</i> | 244 |
| Figura 6-45. Parcelas de la clase <i>Matorral</i> clasificadas como <i>Algarrobos</i> | 244 |
| Figura 6-46. Parcelas de la clase <i>Matorral</i> clasificadas como <i>Suelo desnudo</i> | 245 |
| Figura 6-47. Parcelas de la clase <i>Olivos</i> clasificadas como <i>Algarrobos</i> | 245 |
| Figura 6-48. Parcelas de la clase <i>Olivos</i> clasificadas como <i>Suelo desnudo</i> | 246 |
| Figura 6-49. Parcelas de la clase <i>Plantones</i> clasificadas como <i>Suelo desnudo</i> | 247 |
| Figura 6-50. Parcela de la clase <i>Plantones</i> con su semivariograma correspondiente | 247 |
| Figura 6-51. Parcelas de la clase <i>Regadío</i> clasificadas como <i>Suelo desnudo</i> | 248 |
| Figura 6-52. Parcelas de la clase <i>Regadío</i> clasificadas como <i>Cítricos</i> | 248 |
| Figura 6-53. Aplicación SIG para la fotointerpretación de parcelas con clases no coincidentes | 255 |
| Figura 7-1. Interfaz gráfico de FETEX 2.0..... | 265 |

ÍNDICE DE TABLAS

| | |
|--|-----|
| Tabla 2-1. Fragmento de la leyenda jerárquica del Corine Land Cover | 18 |
| Tabla 2-2. Grupos de cultivos en la cartografía catastral..... | 21 |
| Tabla 2-3. Códigos de usos empleados en el SIGPAC | 26 |
| Tabla 2-4. Matriz de eventos posibles | 35 |
| Tabla 2-5. Matriz de transiciones posibles | 35 |
| Tabla 4-1. Coordenadas extremas de la zona de estudio | 100 |
| Tabla 4-2. Características técnicas básicas del sistema de cámaras digitales DMC. | 102 |
| Tabla 4-3. Distribución de clases en la zona de estudio | 104 |
| Tabla 5-1. Resultados del filtrado con distintos parámetros de ponderación | 154 |
| Tabla 6-1. Comparación de datos medidos y obtenidos con el semivariograma..... | 180 |
| Tabla 6-2. Matriz de confusión | 182 |
| Tabla 6-3. Evaluación de la segmentación automática de árboles..... | 187 |
| Tabla 6-4. Evaluación por clase de la segmentación automática de árboles..... | 188 |
| Tabla 6-5. Nombre y descripción de las características descriptivas de los objetos | 189 |
| Tabla 6-6. Parámetros de las clasificaciones realizadas..... | 190 |
| Tabla 6-7. Relevancia de las características en la clasificación..... | 194 |
| Tabla 6-8. Relevancia de las características en la clasificación..... | 195 |
| Tabla 6-9. Relevancia de las características en la clasificación..... | 196 |
| Tabla 6-10. Relevancia de las características en la clasificación..... | 196 |
| Tabla 6-11. Matriz de confusión del ensayo 1: Un árbol de clasificación y 20 variables .. | 198 |
| Tabla 6-12. Matriz de confusión del ensayo 2: Un árbol de clasificación y 12 variables .. | 198 |
| Tabla 6-13. Matriz de confusión del ensayo 3: 10 árboles de clasificación y 20 variables | 199 |
| Tabla 6-14. Matriz de confusión del ensayo 4: 10 árboles de clasificación y 12 variables | 199 |
| Tabla 6-15. Grado de error de los árboles de decisión sobre las muestras de entrenamiento | 201 |
| Tabla 6-16. Nombre y descripción de las características calculadas | 203 |
| Tabla 6-17. Matriz de confusión de la clasificación de parcelas | 205 |
| Tabla 6-18. Fiabilidades de usuario y de productor de la clasificación de parcelas | 205 |
| Tabla 6-19. Contribución de las características en la clasificación de parcelas | 206 |
| Tabla 6-20. Porcentaje de parcelas clasificadas en cada árbol considerando el uso previo | 210 |

| | |
|---|-----|
| Tabla 6-21. Tipos de combinaciones posibles de datos..... | 213 |
| Tabla 6-22. Parcelas de evaluación por categoría | 214 |
| Tabla 6-23. Matriz de confusión de la extracción de vías de comunicación | 218 |
| Tabla 6-24. Número de muestras seleccionadas de cada clase..... | 222 |
| Tabla 6-25. Precisión de los árboles de decisión | 227 |
| Tabla 6-26. Matriz de confusión correspondiente a las muestras de entrenamiento..... | 229 |
| Tabla 6-27. Matriz de confusión de la clasificación con 37 variables..... | 230 |
| Tabla 6-28. Fiabilidades de usuario y de productor de la clasificación con 37 variables.. | 230 |
| Tabla 6-29. Matriz de confusión de la clasificación considerando el uso catastral | 233 |
| Tabla 6-30. Fiabilidades de usuario y de productor de la clasificación considerando el uso catastral | 233 |
| Tabla 6-31. Intervención del uso catastral en la clasificación..... | 234 |
| Tabla 6-32. Porcentajes de parcelas clasificadas empleando cada variable en los 10 árboles de decisión | 236 |
| Tabla 6-33. Comparación de leyendas | 249 |
| Tabla 6-34. Tipos de combinaciones posibles de datos | 252 |
| Tabla 6-35. Identificación de las parcelas a revisar..... | 253 |

ÍNDICE

Capítulo I: INTRODUCCIÓN

| | | |
|-------|------------------------------|----|
| 1.1.- | Introducción | 1 |
| 1.2.- | Objetivos | 7 |
| 1.3.- | Estructura de la tesis | 10 |

Capítulo II: LAS BASES DE DATOS CARTOGRÁFICAS

| | | |
|-----------|---|----|
| 2.1.- | Introducción | 13 |
| 2.2.- | Conceptos básicos | 15 |
| 2.2.1.- | Modelo de datos | 15 |
| 2.2.2.- | La leyenda | 16 |
| 2.2.2.1.- | Descripción de las clases o categorías | 17 |
| 2.2.2.2.- | Leyendas simples y leyendas jerárquicas | 17 |
| 2.2.2.3.- | Codificación | 18 |
| 2.3.- | Resumen de bases de datos cartográficas oficiales sobre uso y cobertura del suelo | 19 |
| 2.3.1.- | Cartografía de la Dirección General del Catastro | 19 |
| 2.3.1.1.- | La parcela catastral en la directiva INSPIRE | 22 |
| 2.3.2.- | Sistema de información geográfica de identificación de parcelas agrícolas - SIGPAC | 24 |
| 2.3.3.- | Mapa Forestal de España a escala 1:50000 | 29 |
| 2.3.4.- | Mapa de Cultivos y Aprovechamientos de España a escala 1/50000 | 31 |
| 2.3.5.- | Corine Land Cover | 33 |
| 2.3.6.- | SIOSE | 36 |
| 2.3.7.- | Conclusiones | 40 |
| 2.4.- | El Plan Nacional de Observación del Territorio (PNOT) | 41 |

Capítulo III: LA CLASIFICACIÓN DE IMÁGENES Y LA ACTUALIZACIÓN DE BASES DE DATOS CARTOGRÁFICAS

| | | |
|---------|---|----|
| 3.1.- | Introducción | 45 |
| 3.2.- | Métodos de clasificación según la unidad espacial considerada | 46 |
| 3.2.1.- | Clasificadores por píxel | 47 |
| 3.2.2.- | Clasificadores sub-píxel | 48 |
| 3.2.3.- | Clasificadores de contexto | 49 |
| 3.2.4.- | Clasificadores orientados a objetos | 51 |
| 3.2.5.- | Clasificadores orientados a parcelas | 57 |
| 3.3.- | Métodos de clasificación no paramétricos | 64 |

| | | |
|-------------|---|----|
| 3.3.1.- | Introducción..... | 64 |
| 3.3.2.- | Redes neuronales artificiales..... | 65 |
| 3.3.3.- | Sistemas de clasificación basados en conocimiento..... | 66 |
| 3.3.3.1.- | Introducción..... | 66 |
| 3.3.3.2.- | Obtención de datos de entrenamiento..... | 72 |
| 3.3.3.3.- | Árboles de decisión..... | 72 |
| 3.3.3.3.1.- | Algoritmo C5.0..... | 77 |
| 3.3.3.3.2.- | Ruido, sobreajuste y poda..... | 80 |
| 3.3.3.4.- | Conversión de árboles de decisión en reglas..... | 81 |
| 3.3.3.5.- | Clasificación mediante árboles de decisión..... | 83 |
| 3.3.3.5.1.- | Clasificación con un solo árbol de decisión..... | 83 |
| 3.3.3.5.2.- | Métodos multclasificadores..... | 83 |
| 3.3.3.6.- | Medida del rendimiento del aprendizaje..... | 85 |
| 3.4.- | Actualización de bases de datos cartográficas mediante análisis de imágenes..... | 86 |
| 3.4.1.- | Introducción..... | 86 |
| 3.4.2.- | Métodos automáticos de detección de cambios en una base de datos.. | 88 |
| 3.5.- | Incorporación de la información de una base de datos en la clasificación de imágenes..... | 91 |

Capítulo IV: DATOS Y ZONA DE ESTUDIO

| | | |
|---------|---|-----|
| 4.1.- | Zona de estudio..... | 99 |
| 4.2.- | Datos de partida..... | 101 |
| 4.3.- | Selección de muestras y definición de la leyenda..... | 103 |
| 4.3.1.- | Descripción de las clases temáticas..... | 105 |

Capítulo V: METODOLOGÍA

| | | |
|-------------|---|-----|
| 5.1.- | Introducción..... | 113 |
| 5.2.- | Extracción de características..... | 117 |
| 5.2.1.- | Características espectrales..... | 117 |
| 5.2.2.- | Características texturales..... | 119 |
| 5.2.3.- | Características estructurales..... | 124 |
| 5.2.3.1.- | Estudio de la regularidad de las parcelas mediante análisis del semivariograma..... | 124 |
| 5.2.3.1.1.- | Introducción..... | 124 |
| 5.2.3.1.2.- | Variables aleatorias regionalizadas..... | 125 |
| 5.2.3.1.3.- | El semivariograma experimental..... | 126 |
| 5.2.3.1.4.- | Pasos para la construcción del semivariograma experimental en una imagen..... | 131 |

| | | |
|---------------|---|-----|
| 5.2.3.1.5.- | Aplicación del semivariograma a la determinación de los marcos de plantación | 132 |
| 5.2.3.1.5.1.- | Extracción de índices | 135 |
| 5.2.3.2.- | Identificación de árboles individuales | 138 |
| 5.2.3.3.- | Identificación de marcos de plantación mediante la transformada de Hough | 141 |
| 5.2.3.3.1.- | Introducción..... | 141 |
| 5.2.3.3.2.- | La transformada de Hough | 141 |
| 5.2.3.3.3.- | Descripción del algoritmo..... | 145 |
| 5.2.3.3.4.- | Aplicación de la transformada de Hough en el reconocimiento de marcos de plantación..... | 146 |
| 5.2.4.- | Segmentación de árboles | 151 |
| 5.2.4.1.- | Introducción | 151 |
| 5.2.4.2.- | Preprocesado de imágenes | 152 |
| 5.2.4.3.- | Clasificación no supervisada | 156 |
| 5.2.4.4.- | Asignación de significado a las clases generadas en la clasificación no supervisada | 158 |
| 5.2.4.5.- | Características extraídas de los objetos segmentados | 165 |
| 5.2.4.5.1.- | Características espectrales | 166 |
| 5.2.4.5.2.- | Características relativas al tamaño de los sub-objetos | 166 |
| 5.2.4.5.3.- | Características relativas a la posición de los sub-objetos . | 167 |
| 5.2.4.5.4.- | Características relativas a la forma de los sub-objetos | 169 |
| 5.2.4.5.4.1.- | Ajuste de una elipse | 169 |
| 5.2.4.5.4.2.- | Índices descriptores de la forma del objeto..... | 171 |
| 5.2.5.- | Características topográficas | 172 |
| 5.2.6.- | Clasificación a nivel de píxel | 174 |
| 5.2.7.- | Características de forma de la parcela | 175 |

CAPÍTULO VI: RESULTADOS

| | | |
|---------|--|-----|
| 6.1.- | Introducción | 177 |
| 6.2.- | Identificación del tamaño medio de los árboles mediante el análisis del semivariograma..... | 179 |
| 6.3.- | Determinación de características descriptivas del marco de plantación con la transformada de Hough | 181 |
| 6.4.- | Extracción de árboles mediante segmentación de imágenes | 185 |
| 6.5.- | Clasificación de parcelas con cultivos arbóreos | 189 |
| 6.5.1.- | Ensayo 1: Un árbol de decisión con 20 características | 193 |
| 6.5.2.- | Ensayo 2: Un árbol de decisión con 12 características | 194 |
| 6.5.3.- | Ensayo 3: Diez árboles de decisión con 20 características | 195 |

| | | |
|---|--|-----|
| 6.5.4.- | Ensayo 4: Diez árboles de decisión con 12 características | 196 |
| 6.5.5.- | Evaluación de las clasificaciones | 197 |
| 6.6.- | Clasificación de parcelas agrícolas | 201 |
| 6.7.- | Incorporación del uso previo contenido en una base de datos en la clasificación de parcelas | 207 |
| 6.8.- | Actualización de una base de datos cartográfica | 216 |
| 6.8.1.- | Cálculo de las características descriptivas para cada parcela | 217 |
| 6.8.2.- | Extracción de vías de comunicación | 218 |
| 6.8.2.1.- | Análisis de los errores cometidos en la extracción de vías de comunicación | 219 |
| 6.8.3.- | Selección de características..... | 221 |
| 6.8.4.- | Clasificación con 37 variables | 226 |
| 6.8.5.- | Incorporación de la clase contenida en la base de datos..... | 231 |
| 6.8.6.- | Contribución de las características en la clasificación | 235 |
| 6.8.7.- | Análisis detallado de los errores cometidos en la clasificación con 37 variables | 237 |
| 6.8.8.- | Comparación de la clase asignada con la contenida en la base de datos catastral | 249 |
| 6.8.9.- | Revisión mediante fotointerpretación y visitas de campo | 254 |
| CAPÍTULO VII: CONCLUSIONES Y LÍNEAS DE INVESTIGACIÓN FUTURAS | | |
| 7.1.- | Conclusiones..... | 257 |
| 7.2.- | Líneas futuras de investigación | 267 |
| ANEJO I | | |
| | Fichas de revisión en campo | 271 |
| ANEJO II | | |
| | Clasificación por píxel..... | 275 |
| BIBLIOGRAFÍA | | |
| | | 277 |

Capítulo I

INTRODUCCIÓN

1.1.- Introducción

En la actualidad, el consumo de información cartográfica digital crece de forma continuada. La disponibilidad de dispositivos capaces de gestionar los grandes volúmenes de información, los nuevos sensores que aportan información cada vez más detallada, el auge de las aplicaciones cartográficas por internet, el desarrollo de los receptores GPS, etc. ha popularizado el uso de la información cartográfica y ha aumentado su demanda de forma que se ha convertido en un bien de consumo para una parte de la población. Para satisfacer esta demanda la cartografía debe estar actualizada y con la mayor calidad métrica y temática.

Las distintas bases de datos cartográficas, tanto públicas como privadas, almacenan cantidades ingentes de información en formatos distintos que son mostradas a los usuarios a través de soportes e interfaces variadas. Las principales fuentes de datos para las bases de datos cartográficas son las imágenes tanto aéreas como satelitales. Estas imágenes deben tener un cierto grado de procesamiento antes de ser suministradas a los usuarios. En ciertos casos, el procesado se limita a la realización de correcciones a las imágenes, bien sean radiométricas, geométricas, etc. mientras que en otros casos se realiza un proceso de extracción de información de las imágenes bien por técnicas fotogramétricas, por fotointerpretación, o bien, mediante teledetección.

La extracción de información de las imágenes es un proceso costoso y fundamentalmente manual, aunque cada vez son mayores los esfuerzos para conseguir la automatización parcial o total en estos procesos con el fin de reducir los costes humanos y temporales, incrementar la productividad y en consecuencia, responder a la cada vez mayor demanda de información.

En el conjunto de bases de datos cartográficas, una de las tipologías más relevantes son las bases de datos que reflejan el uso o la cobertura del suelo. La información sobre el uso del suelo tiene una importancia fundamental en la ordenación del territorio, en la predicción de producciones agrarias, en la gestión del impuesto de bienes inmuebles, etc.

El uso del suelo es un criterio socioeconómico que hace referencia a la actividad dominante que se da en un determinado lugar, e incluye usos como residencial, comercial, industrial, agrícola, etc., pudiendo estar estas categorías divididas en niveles más específicos. La cobertura del suelo es un indicador biofísico que describe los materiales que cubren el territorio, como por ejemplo, asfalto, vegetación, suelo desnudo, agua, etc. Según Comber *et al.* (2005), la cobertura del suelo es entendida de forma diferente según las disciplinas científicas. Así, los ecólogos definen la cobertura del suelo según la presencia y abundancia de especies vegetales, mientras que para los edafólogos es un indicador de la composición y los tipos de suelos. Por otra parte, en la bibliografía en castellano existe el término ocupación del suelo que según López González *et al.* (2002) hace referencia a la cobertura, entendida como los materiales que cubren el territorio, mientras que otros autores la consideran como una combinación de los conceptos uso y cobertura (Del Bosque *et al.*, 2005). Es muy habitual la utilización conjunta de los términos uso y cobertura, ya que, en función del objetivo final de la cartografía, se definen leyendas donde coexisten clases que corresponden a usos con otras que corresponden a coberturas.

Hay numerosos proyectos tanto nacionales (SIOSE) como europeos (CORINE) e incluso globales (MODIS Land Cover) para cartografiar el uso o la cobertura del territorio a distintas escalas. En la mayor parte de estos proyectos, la delimitación de los distintos usos del suelo se obtiene mediante la fotointerpretación asistida por ordenador por parte de un operador de imágenes de satélite con resoluciones espaciales decamétricas (Landsat, SPOT, etc.) o superiores (MODIS). La clasificación de imágenes sólo se utiliza como información auxiliar en el proceso fotointerpretativo, o bien, en la realización de cartografía de usos del suelo a escalas pequeñas.

La aparición de los sensores de alta resolución como Ikonos o Quickbird ha hecho posible la extracción de sus imágenes de información para cartografías a escalas mayores a 1/25.000; escalas sólo abordables mediante la fotografía aérea hasta hace pocos años.

La necesaria actualización de las bases de datos de usos y cobertura del suelo es un proceso que puede enfocarse desde dos puntos de vista distintos: La realización de una nueva base de datos cada un cierto periodo de tiempo, o bien, la detección e identificación de los cambios ocurridos desde la fecha de creación de la base de datos. La primera opción resulta más costosa al tener que repetir un mismo trabajo cada cierto número de años. En cambio, la identificación de los cambios ocurridos resulta más económica ya que

permite mantener la información que no ha variado, pero requiere de una metodología que permita detectar los cambios adecuadamente. En la actualidad, las imágenes necesarias para realizar la actualización frecuente de las bases de datos están disponibles. En cambio, el principal escollo que dificulta esta actualización es la falta de una metodología operativa que automatice total o parcialmente los procesos necesarios.

La automatización en la interpretación de imágenes debe abordarse con la incorporación al proceso de las fuentes de datos disponibles sobre el territorio a analizar. En estas fuentes se incluye la cartografía, las bases de datos alfanuméricas, las imágenes de una o varias fechas e incluso de distintos sensores, el conocimiento experto que se tenga sobre el territorio, etc. En un proceso fotointerpretativo tradicional, el fotointérprete antes de asignar el uso a una parcela, considera además de la representación de la parcela en la imagen, otros indicios como son la clase previa en una base de datos anterior, la posición geográfica del objeto, la representación en una segunda imagen, etc. El análisis combinado de la información disponible junto con el conocimiento que tenga sobre el territorio le permitirá dar un juicio de valor sobre la clase de la parcela. Del mismo modo, al pretender obtener resultados similares de forma semiautomática, el sistema debe disponer de la mayor cantidad posible de información sobre el territorio así como de las herramientas necesarias para tratar con esos diversos tipos de información.

La combinación entre las técnicas de la teledetección y los SIG, materializada por el análisis integrado de las fuentes de datos de cada una de estas disciplinas, las imágenes y las bases de datos cartográficos, da lugar a una metodología nueva de clasificación de imágenes conocida como Clasificación de Imágenes Orientada a Objetos. En este enfoque de clasificación de imágenes, el análisis de la imagen no se realiza considerando el píxel como unidad, sin considerar la pertenencia a un objeto ni sus características ni el contexto espacial en que se encuentra como es habitual en el tratamiento de las imágenes de resolución decamétrica. Sino que se analizan y clasifican los objetos generados como agrupaciones de píxeles según un determinado método de segmentación de imágenes. El algoritmo a emplear en la segmentación de la imagen tiene una importancia fundamental en las características de los objetos generados y es la principal debilidad que tiene la aplicación de esta metodología, ya que en función del algoritmo y los parámetros utilizados, los resultados, es decir, los objetos creados, serán distintos.

En esta Tesis se propone una variante de este enfoque conocida como Clasificación de Imágenes por Parcelas, en la cual, la cartografía existente aporta los límites para crear los objetos, de forma que, la interpretación de los píxeles que forman un objeto proporciona la información temática, es decir, la clase que le corresponde a esa porción del espacio. La cartografía vectorial aporta la información métrica en tanto que la imagen proporciona la información temática. Esta división de la imagen permite crear subimágenes más reducidas y por tanto más sencillas de interpretar, a la vez que se

incorpora en el análisis de la imagen la interpretación previa realizada por un cartógrafo y la información alfanumérica contenida en la base de datos. De esta forma, se elimina de la creación de los objetos la influencia de un determinado algoritmo de segmentación. Esta metodología es especialmente adecuada para paisajes altamente humanizados, como son los paisajes agrícolas, ya que en estos casos, las unidades del paisaje están limitadas por bordes nítidos y relativamente estables en el tiempo.

Una vez dividida la imagen según los límites cartográficos y definidos, por tanto, los objetos de estudio, se describen de la manera más completa posible utilizando para ello todas las características que puedan ayudar a discriminar el uso que se da en cada objeto. Esta descripción puede conseguirse por medio de características extraídas de la imagen, como el color, la textura, el tono, etc., con características relativas a la forma de la parcela, con información auxiliar como es el uso que tenía dicha parcela en una fecha anterior, sus características topográficas, etc. Estas características descriptivas de las agrupaciones de píxeles son la base para la correcta asignación a una de las clases informacionales de la leyenda. Al igual que ocurre en fotointerpretación, los objetos presentes en la imagen son comparados con los prototipos representativos de cada clase, de forma que serán asignados a la clase más similar. Cuanto más completa sea la descripción de los objetos, mayor será la probabilidad de que el objeto sea asignado a la clase que le corresponda.

La asignación de una clase a cada parcela a partir de sus características descriptivas se realiza por medio de un método de clasificación. En esta tesis se propone la utilización de un sistema basado en conocimiento. Un sistema basado en conocimiento es aquel sistema que usa conocimiento humano para resolver problemas que normalmente requieren inteligencia humana, es decir, un sistema que puede resolver cuestiones de forma parecida a como lo haría una persona experta en ese tema. La construcción de un sistema basado en conocimiento está condicionada a la adquisición del conocimiento necesario a partir de la información disponible mediante técnicas de extracción de conocimiento en bases de datos. La extracción de conocimiento en bases de datos se define como el proceso no trivial de identificar patrones válidos, novedosos, potencialmente útiles y comprensibles a partir de los datos. Una de las fases principales del proceso de extracción de conocimiento en bases de datos se conoce como minería de datos. La minería de datos consiste en analizar los datos para extraer el conocimiento implícito en esos datos y expresarlo en forma de relaciones, patrones, reglas, etc. Es un campo multidisciplinar que utiliza herramientas desarrolladas en otras tecnologías con las que está íntimamente relacionado, como por ejemplo, la estadística, el aprendizaje automático, los sistemas gestores de bases de datos, etc. En un proceso de minería de datos se analizan una serie de ejemplos del concepto que se pretende aprender y a partir de ese análisis se induce una definición que sirva para describir ese concepto. Entre las

ventajas que poseen estos métodos destaca el hecho de que los procesos de clasificación son inteligibles para el usuario y éste puede comprobar las reglas o condiciones establecidas por el sistema para asignar los objetos a una u otra clase; con lo que el conocimiento extraído por el sistema para realizar la clasificación también redundaría en el usuario que puede comprender el razonamiento utilizado en la clasificación.

La metodología que se desarrolla en esta tesis para la actualización de una base de datos cartográfica de usos del suelo está estructurada según el siguiente flujo de trabajo:

En primer lugar, se debe disponer de un mosaico de imágenes de alta resolución correspondiente a la fecha en la que se quiere actualizar la base de datos. La calidad radiométrica de este mosaico es un factor clave para los análisis posteriores. Así mismo, es necesaria la mayor exactitud geométrica y posicional del mosaico para lograr una correcta superposición espacial con la cartografía temática a actualizar.

A continuación, se superpone la cartografía vectorial de la base de datos sobre ese mosaico y se definen los objetos de estudio como los polígonos más reducidos, con un uso homogéneo respecto a la leyenda, contenidos en la base de datos. En nuestro caso, el objeto de estudio es la subparcela catastral.

Cada uno de los objetos de estudio es descrito intensamente mediante un proceso de extracción de características. Las características descriptoras se obtienen de forma automática mediante el software desarrollado en esta tesis y definen las propiedades espectrales, texturales, estructurales, de forma, topográficas, relativas a los objetos contenidos en su interior, etc.

Por otra parte, la intervención humana es necesaria en la selección de ejemplos o prototipos necesarios para la correcta definición de las clases de la leyenda. Con estas muestras de entrenamiento y sus correspondientes características extraídas, se crean los árboles de decisión que clasificarán el conjunto de objetos de la base de datos.

Una vez extraídas las características para todos los objetos y construidos los árboles de decisión, se aplican éstos y se obtiene para cada objeto tanto la clase predicha por el clasificador como un estimador de la confianza con la que se hace la asignación de la clase. El resultado de la clasificación es un mapa de usos del suelo donde cada subparcela está asignada a uno de los usos de la leyenda.

Tras la asignación de una clase de la leyenda a cada uno de los objetos se procede a la comparación con la información contenida en la base de datos. Como resultado de esta comparación se obtienen las subparcelas cuyo uso coincide, que se admite que no han variado su uso, y las discrepancias entre ambas fuentes de datos que pueden ser debidas a cambios en el uso ocurridos en el periodo de tiempo transcurrido

desde la creación de la base de datos hasta su actualización, o bien, a errores contenidos en la base de datos o cometidos en la fase de clasificación. Estas discrepancias respecto al uso de las subparcelas deben ser revisadas por un fotointérprete de modo que sea éste el que confirme su uso real y modifique, en caso de ser necesario, el uso contenido en la base de datos.

Esta metodología permite reducir significativamente el número de parcelas a revisar por un fotointérprete sin que esto suponga una merma en la precisión de la base de datos actualizada.

1.2.- Objetivos

El objetivo principal del conjunto de la Tesis es: **Establecer una metodología para la actualización de bases de datos cartográficas de usos del suelo en paisajes agrícolas mediante la detección automática de los cambios** existentes entre la información contenida en las bases de datos a actualizar y el uso representado en imágenes de alta resolución. Esta Tesis está orientada hacia las bases de datos de usos del suelo a nivel español como son el SIGPAC, la cartografía catastral, los inventarios de determinados cultivos que se hacen a nivel autonómico, etc. La metodología a desarrollar está condicionada por los medios y los datos de los que disponen las administraciones públicas encargadas del mantenimiento de estas bases de datos de forma que se consiga una reducción de los costes de actualización frente a los métodos tradicionales.

Los datos apropiados para la extracción de información de usos del suelo son de tipologías variadas y su disponibilidad aumenta de forma creciente. Entre las fuentes de datos con mayor utilidad están las imágenes multitemporales de alta resolución, los datos tridimensionales obtenidos con sensores LIDAR, las imágenes hiperespectrales, las imágenes rádar, etc. La mejora en las características técnicas de estos sensores y su mayor disponibilidad ha comportado un aumento en su aplicación en los trabajos de investigación relativos a la extracción de información topográfica a partir de imágenes, al aportar información novedosa, válida y complementaria entre sí. Sin embargo, el elevado coste de adquisición de los datos dificulta su utilización de forma operativa en áreas extensas.

El Plan Nacional de Observación del Territorio en España engloba el Plan Nacional de Ortofotografía Aérea que pretende proporcionar una cobertura global del territorio español con ortoimágenes digitales con una resolución espacial de 25 a 50 cm. con una frecuencia temporal de dos años. Ya que es la primera vez en España que existe un plan que confirma la disponibilidad de ortoimágenes para todo el territorio, en ciclos de dos años y con una resolución espacial elevada, resulta necesario el desarrollo de metodologías para la explotación de estas imágenes y, de esta forma, aprovechar al máximo estos datos. Dado el esfuerzo económico que están realizando tanto la Administración General del Estado como las Comunidades Autónomas en el desarrollo de este ambicioso plan, no resulta probable que la adquisición de otras tipologías de datos a nivel estatal sea factible en un corto plazo de tiempo.

La consideración de otros tipos de datos, que complementan eficazmente la información extraída de las imágenes de alta resolución, forma parte de las futuras y obligadas líneas de investigación a realizar tras esta Tesis, en la que se aborda la obtención de información de usos del suelo únicamente a partir de la información básica,

indispensable y disponible para el fin buscado, esto es, la base de datos cartográfica a actualizar, compuesta de la información vectorial y la información alfanumérica asociada, una ortoimagen de alta resolución y la información auxiliar existente.

Para lograr el objetivo principal con los datos disponibles, es necesario integrar en un sistema toda la información de forma que el territorio quede descrito de la forma más completa posible. Se requiere que la información esté en soporte digital y en cualquier formato, ya sea vectorial, ráster, alfanumérico, etc. Por lo tanto, el primer objetivo parcial es **desarrollar una sistemática para integrar información geográfica de distintos tipos en un mismo nivel de abstracción** que en nuestro caso es la subparcela catastral. Es decir, dada una porción del territorio, hay que desarrollar los pasos para extraer de cada fuente de datos la información relativa a la misma.

La información que se va a emplear para describir el territorio es:

- Cartografía vectorial con los límites de los objetos que componen la base de datos a actualizar.
- Ortoimagen de alta resolución que muestra los usos actuales en el territorio.
- Información alfanumérica contenida en una o varias bases de datos.
- Información cartográfica auxiliar en forma de modelos digitales del terreno.

La necesidad de describir los objetos contenidos en la base de datos lo más ampliamente posible, desde el mayor número de puntos de vista y aprovechando las fuentes de datos posibles, nos lleva a la definición de los objetivos parciales siguientes:

- **Definir un conjunto de características que describan profundamente la representación de una subparcela en una imagen de alta resolución.** La ortoimagen proporciona la información actual sobre el uso, por tanto, de ella debe ser extraída la mayor cantidad de información para que el uso existente quede descrito con la menor ambigüedad posible. Las características a desarrollar deben describir del objeto propiedades similares a las que analiza un fotointérprete para asignar un uso a una parcela.
- **Definir características que describan las propiedades geométricas de los objetos a partir de la representación vectorial del contorno del polígono.** La forma o el tamaño de las parcelas puede ser un indicador del uso que se da en las mismas. Por ejemplo, las vías de comunicación o los cursos fluviales suelen tener formas alargadas, las balsas de agua o los edificios tienen formas regulares y de tamaño reducido frente a las parcelas, etc. Por tanto, se han de desarrollar características que contribuyan a la descripción de los objetos con la información relativa a su forma y tamaño.

- **Analizar las posibles alternativas para incorporar la información alfanumérica y la información cartográfica auxiliar en la descripción de los objetos geográficos y en su posterior clasificación.** La información auxiliar puede completar la información extraída de las imágenes o de la cartografía para describir los elementos. Con este fin, se han de analizar las distintas formas de incorporar esta información en la descripción de los objetos y en la evaluación de la posterior clasificación.

Dado que el número de características descriptivas puede llegar a ser numeroso es necesario **identificar la relevancia de cada una de las características** extraídas de los objetos en el proceso de calificación.

Una vez descritos los objetos según todas las características y seleccionadas las características más relevantes, es necesaria la asignación de los objetos a una de las clases de la leyenda. Relativo a la fase de clasificación automática se propone el objetivo siguiente: **Evaluar la validez de los árboles de decisión deducidos mediante algoritmos de *data mining* para la clasificación de imágenes.** Es importante que las condiciones establecidas para la clasificación de cada objeto sean comprensibles para el usuario, de forma que se pueda determinar en base a qué criterios se ha asignado un objeto a una clase determinada, al mismo tiempo que se cree una base de conocimiento que pueda ser aplicada a la clasificación de zonas similares a las utilizadas para la creación de los árboles de decisión.

La metodología propuesta en esta Tesis, pretende ser operativa y aplicable a casos reales, por lo que se plantea la necesidad de **evaluar la aplicación de esta metodología a un caso real e identificar los problemas y las posibles soluciones que surjan en su aplicación.** La Tesis pretende ser un estudio experimental que debe tener una aplicación práctica, por lo que la metodología a desarrollar debe ser ensayada con una base de datos real y así detectar las potencialidades y las limitaciones de la aplicación del método al enfrentarse con las circunstancias propias de la actualización de una base de datos existente.

1.3.- Estructura de la tesis

Además del capítulo I dedicado a la introducción, el contenido de esta Tesis se estructura en los capítulos siguientes:

- El **capítulo II** tiene la función de mostrar los antecedentes sobre bases de datos cartográficos y los fundamentos del Plan Nacional de Observación del Territorio. En primer lugar, contiene una recopilación bibliográfica sobre distintos aspectos relativos a las bases de datos cartográficos de usos del suelo, como son el modelo de datos, la leyenda, etc. Se describen las bases de datos más utilizadas a nivel español y europeo, así como las estrategias para su realización y la actualización de algunas de ellas.
En la última sección de este capítulo se describe el Plan Nacional de Observación del Territorio, el cual es la fuente de datos más importante a nivel español para la generación de cartografía temática.
- El **capítulo III** explica los métodos de clasificación de imágenes desde distintos puntos de vista. En primer lugar, se dividen los métodos de clasificación según el elemento de la imagen que se clasifique, ya sea un píxel, una parte del mismo, un píxel considerando su contexto espacial, o bien, una agrupación de píxeles. Se hace hincapié en la descripción de la clasificación orientada a objetos y por parcela.
En segundo lugar, se describen los clasificadores no paramétricos, especialmente los árboles de decisión, su creación con el algoritmo C5.0 y su aplicación.
A continuación, se describen las distintas alternativas para la detección de cambios en el territorio mediante el análisis de imágenes
El último apartado de este capítulo detalla las variantes que existen para la incorporación de la información contenida en una base de datos en cada una de las fases de un proceso de clasificación de imágenes.
- En el **capítulo IV** se describe la zona de estudio sobre la que se realizan los diversos ensayos, los datos de partida y las clases temáticas de la leyenda.
- En el **capítulo V** se desarrolla la metodología propuesta para la descripción completa de los objetos mediante características que cuantifican numéricamente distintos aspectos de su representación en la imagen. La extracción de características es la parte fundamental del proceso ya que cuanto más completa sea la descripción de cada objeto mayor será la probabilidad de que el objeto sea asignado a la clase correspondiente en la leyenda. Algunas de estas

características definen el objeto considerándolo como una unidad, mientras que otras variables consideran las características de los elementos o subobjetos contenidos en su interior.

Las características descritas están englobadas en seis categorías: espectrales, texturales, estructurales, topográficas, basadas en una clasificación por píxel y de forma.

- El **capítulo VI** recoge los ensayos realizados para evaluar la adecuación de las características enumeradas en el capítulo anterior a la descripción exhaustiva de los objetos.

En el primer ensayo se analiza la precisión con la que se obtiene el tamaño medio de los árboles en parcelas de cultivos arbóreos mediante un parámetro extraído del semivariograma omnidireccional.

El segundo ensayo comprueba la precisión con la que se obtienen las características de los marcos de plantación de cultivos arbóreos por medio de la aplicación de la transformada de Hough sobre una imagen binaria con la localización de los árboles.

En el tercer ensayo se evalúa la calidad de una segmentación automática de árboles comparando la superficie segmentada con la realmente ocupada por los árboles de la parcela.

En el cuarto ensayo se realiza la clasificación en tipologías de cultivos arbóreos de los polígonos interiores a la parcela, correspondientes a árboles resultantes de la segmentación anteriormente evaluada, en función de las características extraídas de los mismos.

En el quinto ensayo se comprueba la eficacia de la metodología presentada para la clasificación de parcelas agrícolas.

En el sexto ensayo se estudia la conveniencia de incorporar al conjunto de variables descriptoras de las parcelas, la información relativa a su uso previo contenido en la base de datos a actualizar.

El séptimo ensayo consiste en la aplicación completa de un proceso de actualización de una base de datos catastral por medio de la descripción de los objetos contenidos en la base de datos mediante la extracción de características y su posterior clasificación. La clase asignada se compara con la contenida en la base de datos y las discrepancias entre ambas deben ser explicadas por un fotointérprete a fin de detectar si corresponden a cambios de uso o a errores en las informaciones comparadas.

- En el **capítulo VII** se detallan las conclusiones extraídas y se definen las futuras líneas de investigación.

- Con el objeto de disponer de una base de datos de verdad terreno con la que se pudieran evaluar los resultados de los distintos ensayos, se identificó mediante fotointerpretación el uso correspondiente a cada una de las subparcelas en la zona de estudio. Aquellas subparcelas cuyos usos no eran identificables mediante el análisis de las imágenes fueron revisadas en campo para determinar los usos correspondientes. En el **anejo I** se muestran dos ejemplos de las fichas realizadas en la revisión de campo.
- En el **anejo II** se muestran los resultados de una clasificación a nivel de píxel. Esta imagen clasificada se utilizó para determinar el porcentaje de píxeles pertenecientes a cada una de las clases de la leyenda en el interior de cada subparcela. Estos porcentajes, como se explica en la sección 5.2.6, se utilizaron como características descriptoras del contenido de las subparcelas.

Capítulo II

LAS BASES DE DATOS CARTOGRÁFICAS

2.1.- Introducción

En la gestión del territorio es fundamental disponer de datos espaciales que caractericen lo más fielmente posible los fenómenos que allí ocurren.

Existen numerosas bases de datos gráficas que almacenan las características del territorio con distintos objetivos, distintos tipos de información y con distintos enfoques. Según su objetivo final podemos distinguir, entre otros, los sistemas de información geográficos con fines agrícolas, catastrales, forestales, urbanísticos, etc.

La información cartográfica contenida en estas bases de datos puede variar desde imágenes aéreas o de satélite georreferenciadas, cartografía en formato ráster, cartografía vectorial sin topología o cartografía vectorial con topología donde cada uno de los objetos contenidos tienen información alfanumérica asociada en una o varias tablas. El modelo de bases de datos relacionales, es el más empleado en la actualidad por su versatilidad y semejanza al modelo de datos empleado en la cartografía tradicional.

La mayoría de estos Sistemas de Información Geográfica están gestionados e impulsados por organismos de la Administración Pública encargados de gestionar el territorio y los usos que en él se dan.

Una de las fases más costosas, económicamente hablando, en la implantación de un SIG es la incorporación de la información, tanto gráfica: los objetos geográficos, como literal: las características de los objetos a gestionar. Para que un SIG pueda dar respuesta

a los múltiples interrogantes que se le plantean, la información gestionada debe ser de gran calidad. Es decir, debe ser actual, completa, homogénea con precisión geométrica y corrección semántica.

Los datos desactualizados tienen un valor histórico para estudiar la evolución de un fenómeno, pero si se emplean en el estudio de un fenómeno actual, los resultados del mismo pueden llegar a ser inexactos o completamente erróneos.

Las bases de datos geográficas más relevantes para el presente estudio son aquellas que tienen estructura vectorial y proporcionan información de los usos y/o coberturas del territorio. Estas aplicaciones proporcionan información elaborada del territorio, siendo en la mayoría de los casos, de mayor aplicabilidad para el usuario final que las recopilaciones existentes de información en forma de imágenes, tanto aéreas como de satélite, que deben ser procesadas por parte del usuario para extraer la información buscada.

Un número elevado de estas aplicaciones está disponible, parcial o totalmente a través de internet.

Las bases de datos espaciales para las cuales se desarrolla en este trabajo una metodología de actualización son las que almacenan los usos del suelo. Ya que existe una gran necesidad de cartografía de usos del suelo actualizada para tareas diversas como gestión de subvenciones, estimaciones de producción, etc.

En la actualidad es muy numeroso el esfuerzo de las distintas Administraciones Públicas de carácter autonómico, estatal y europeo por la realización de inventarios agrícolas o forestales, bien enfocados en un determinado cultivo, como es el caso del SIG cítricola en la Comunidad Valenciana o el SIG oleícola de carácter estatal, o bien con un objetivo más amplio como es el caso del inventario catastral con función fiscal que realiza el Ministerio de Economía y Hacienda a través de la Dirección General del Catastro o el Sistema de Identificación de Parcelas Agrícolas (SIGPAC) que en cumplimiento del Reglamento (CE) nº 1593/2000 ha gestionado el Ministerio de Agricultura Pesca y Alimentación.

2.2.- Conceptos básicos

2.2.1.- Modelo de datos

El esquema conceptual con el que se traduce la realidad a una simplificación cartográfica se denomina **modelo de datos**. En la cartografía de usos del suelo predomina el modelo de datos en el que el territorio se organiza como un mosaico formado por teselas con límites netos entre sí. En el ámbito de los sistemas de información geográfica el significado de tesela es el de cada uno de los polígonos resultantes de dividir el territorio según una determinada característica.

Cada tesela pertenece a una clase, cuyo conjunto forma la leyenda del mapa. En el caso de usos del suelo poco influidos por la acción humana, este modelo de datos no se adapta bien a las peculiaridades de estos paisajes y se pueden dar dos tipos de errores:

- el primero se debe al proceso de clasificación que asigna cada tesela a una clase de la leyenda. En este proceso se asume que cada tesela es homogénea internamente en sus propiedades y en ciertos casos esta generalización no es real. El resultado es que existe un error inherente en la clasificación de un continuo (vegetación espontánea) como un mosaico discontinuo (vegetación segmentada en clases).
- el segundo se deriva de que los límites entre dos teselas no suelen ser netos, sino que se muestran como transiciones en las cuales hay una zona mezcla de las dos clases; en este caso la frontera debe ser representada mediante un límite de conveniencia que genera un error de posición.

En la cartografía catastral y agrícola, el territorio está dividido según propiedades no visibles en la realidad, como es el caso de términos municipales, tipologías urbanísticas de usos del suelo, límites de las distintas propiedades, etc. Además de estas divisiones del territorio basadas en características no perceptibles por parte del intérprete, se suele utilizar una partición del terreno basado en los usos y coberturas que se dan en el terreno. Así, por ejemplo, en la cartografía catastral se definen las subparcelas como áreas de una parcela con un uso (cultivo) distinto al resto de la parcela. En la cartografía agrícola, esta unidad recibe el nombre de recinto.

La calidad de un mapa de usos o coberturas del suelo depende de un proceso en el que intervienen múltiples factores; los más importantes son:

- la correcta elaboración de la leyenda, que debe estar formada por clases disjuntas y bien adaptada a la realidad territorial. Esta elaboración ha de ser una

labor previa a la elaboración del mapa y estar basada en un estudio adecuado del territorio.

- la correcta identificación de las teselas en el sentido geométrico, con un trazado de los límites afectado por un error posicional razonable.
- la correcta clasificación de cada tesela, asignándola a la clase más adecuada y reduciendo al mínimo el error atributivo.

Los conceptos básicos que se utilizan en este tipo de mapas son:

- tesela: cada unidad espacial homogénea en sus propiedades en que se divide el mapa; cada tesela está asignada a una de las clases de la leyenda.
- clase o categoría: tipo de cobertura definido por sus propiedades.
- leyenda: conjunto de categorías definidas para el mapa y que describe la realidad en un dominio espacial y temporal determinado.
- clasificación: conjunto de operaciones que permiten asignar cada tesela a una categoría de la leyenda.

2.2.2.- La leyenda

La leyenda representa el conjunto de valores válidos en el mapa y es equivalente a definir los valores posibles para un atributo en una base de datos. Debe construirse de forma previa a la toma de datos cartográfica y en muchos casos, es una tarea compleja que requiere un conocimiento profundo del territorio a cartografiar.

La leyenda está formada por el conjunto de categorías y su completa descripción que defina los criterios de clasificación.

Una leyenda debe cumplir una serie de requisitos:

- ha de ser completa, es decir, cualquier tesela presente en el territorio tiene que poder ser asignada a una de las clases de la leyenda.
- ha de ser disjunta, de modo que las clases no se superpongan entre sí y no exista la posibilidad de asignar una tesela a más de una clase.
- ha de ser estable: las propiedades que definen las categorías han de ser perdurables en el tiempo.

- ha de ser reconocible: las propiedades que definen las clases deben poder medirse objetivamente en las teselas para garantizar que los resultados sean independientes del observador.
- ha de ser coherente: las categorías representadas deben tener significados comparables semánticamente.

2.2.2.1.- Descripción de las clases o categorías

Todas las clases de la leyenda deben estar descritas por sus propiedades principales y características evitando ambigüedades y errores en la definición. La incorporación de ejemplos y fotografías de cada clase puede ser muy útil tanto para el proceso de clasificación como para la correcta interpretación del mapa resultante por parte del usuario final.

2.2.2.2.- Leyendas simples y leyendas jerárquicas

Describir la totalidad de usos o coberturas existentes en un territorio no es fácil debido a la complejidad de la realidad. En ocasiones, una leyenda simple puede ser suficiente y abarcar todas las clases presentes en la realidad, pero frecuentemente es preferible construir leyendas jerárquicas. Las leyendas jerárquicas están basadas en estructuras de niveles donde cada nivel inferior representa una subclase del nivel superior en el que está englobado. Un ejemplo de leyenda jerárquica es el utilizado en el Corine Land Cover en el que se han definido 5 niveles.

Las ventajas de las leyendas jerárquicas frente a las leyendas simples son:

- permiten representar la información con diferentes grados de generalización temática
- permiten gestionar información con diferentes grados de conocimiento
- permiten planificar la captura de datos de forma flexible
- permiten organizar la simbolización gráfica para representar tipos de información diferentes.

2.2.2.3.- Codificación

Una vez definida la leyenda debe definirse un código para cada categoría, de forma que a cada tesela se le asigna el código correspondiente a la clase a la que pertenece. Esta codificación es imprescindible cuando se hace un tratamiento informático de la información.

En el caso de utilizar leyendas jerárquicas, esta codificación permite reflejar de forma intuitiva la estructura en niveles. A continuación se muestra un fragmento de la codificación empleada para la realización del Corine Land Cover en el Instituto Geográfico Nacional, estableciendo una jerarquía de cinco niveles (tabla 2-1).

| Nivel 1 | Nivel 2 | Nivel 3 | Nivel 4 | Nivel 5 | Código | Categoría |
|---------|---------|---------|---------|---------|--------|----------------------------------|
| 1 | | | | | 1 | Zonas agrícolas |
| 1 | 1 | | | | 11 | Tierras de labor |
| 1 | 1 | 1 | | | 111 | Tierras de labor en secano |
| 1 | 1 | 2 | | | 112 | Terrenos regados permanentemente |
| 1 | 1 | 2 | 1 | | 1121 | Cultivos herbáceos en regadío |
| 1 | 1 | 2 | 2 | | 1122 | Otras zonas de irrigación |
| 1 | 1 | 3 | | | 113 | Arrozales |
| 1 | 2 | | | | 12 | Cultivos permanentes |
| 1 | 2 | 1 | | | 121 | Viñedos |
| 1 | 2 | 1 | 1 | | 1211 | Viñedos en secano |
| 1 | 2 | 1 | 2 | | 1212 | Viñedos en regadío |
| 1 | 2 | 2 | | | 122 | Frutales |
| 1 | 2 | 2 | 1 | | 1221 | Frutales en secano |
| 1 | 2 | 2 | 2 | | 1222 | Frutales en regadío |
| 1 | 2 | 2 | 2 | 1 | 12221 | Cítricos |
| 1 | 2 | 2 | 2 | 2 | 12222 | Frutales tropicales |
| 1 | 2 | 2 | 2 | 3 | 12223 | Otros frutales en regadío |

Tabla 2-1. Fragmento de la leyenda jerárquica del Corine Land Cover

2.3.- Resumen de bases de datos cartográficas oficiales sobre uso y cobertura del suelo

2.3.1.- Cartografía de la Dirección General del Catastro

El ejemplo más importante a nivel español de Sistema de Información Geográfica accesible mediante internet es la cartografía catastral digitalizada del Ministerio de Hacienda, que puede consultarse a través de su página web www.catastro.meh.es. Esta aplicación pone a disposición de los usuarios la información disponible de los bienes inmuebles como referencia catastral, superficie, uso, intensidad, etc.

Esta cartografía supone la base fundamental para la gestión del padrón del Impuesto de Bienes Inmuebles y tiene una gran importancia en el desarrollo de otras cartografías temáticas, ya que en numerosos proyectos cartográficos se toma como cartografía base por ser la cartografía con una escala de detalle mayor que cubre todo el territorio español.

La Dirección General del Catastro dispone de cartografía catastral urbana y rústica de los 7584 municipios incluidos en su ámbito competencial que corresponde a todo el territorio nacional excepto País Vasco y Navarra. Estando la mayor parte, pero no la totalidad, de esta cartografía disponible en internet.

Las características técnicas de esta cartografía son:

- Proyección U.T.M. en husos 27,28,29,30 y 31.
- Sistema geodésico ED50 para la península y las Islas Baleares y WGS84 para las Islas Canarias.
- Ámbito de unidad de proceso: Término municipal dividido en Cartografía Catastral de Urbana (Escala 1/500 y 1/1000) y Cartografía Catastral de Rústica (Escala 1/2000 y 1/5000).

La cartografía tiene topología de polígonos de modo que al seleccionar una parcela en la cartografía se puede acceder a su información alfanumérica asociada, facilitando la información contenida en el padrón del impuesto de bienes inmuebles a excepción de los datos protegidos correspondientes al titular (Fig.2-1). Del mismo modo, se puede seleccionar un inmueble urbano o rústico mediante una consulta a la base de datos por medio del nombre de propietario, referencia catastral, dirección, etc. y acceder inmediatamente a la cartografía

| RÚSTICOS | | | | |
|--------------------------------|--|---------------------|------------|-----------------|
| Datos del Bien Inmueble | | | | |
| Referencia catastral | 46204A037000610000GW Copiar referencia al portapapeles | | | |
| Provincia | VALENCIA | | | |
| Municipio | LA POBLA DE VALLBONA | | | |
| Paraje | PARETETES | | | |
| Polígono | 37 | | | |
| Parcela | 61 | | | |
| Superficie | 0,6156 Ha | | | |
| Subparcelas | | | | |
| | Subparcela | Cultivo | Intensidad | Superficie (Ha) |
| | a | O- Olivos secano | 01 | 0,4205 |
| | b | G- Algarrobo secano | 01 | 0,1127 |
| | c | G- Algarrobo secano | 01 | 0,0824 |

Figura 2-1. Información alfanumérica de una parcela catastral

También se puede obtener la representación gráfica del bien inmueble de que se trate.

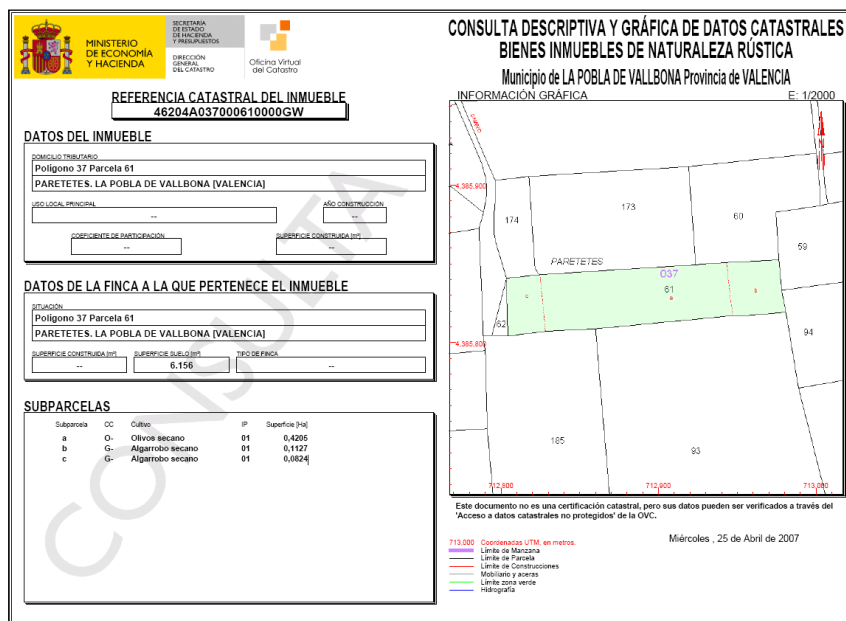


Figura 2-2. Consulta descriptiva y gráfica de una parcela catastral

La cartografía catastral contiene:

- a) Los polígonos catastrales, determinados por las líneas permanentes del terreno y sus accidentes más notables, como ríos, canales, arroyos, pantanos, fuentes, lagunas, vías de comunicación, límites de término municipal y clases de suelo.

b) Las parcelas o porciones de suelo que delimitan los bienes inmuebles, así como las construcciones emplazadas en ellas y, en su caso, las subparcelas o porciones de sus distintos cultivos o aprovechamientos.

Esta cartografía parcelaria recoge para cada subparcela su cultivo o aprovechamiento además de estar clasificada cada subparcela según su intensidad productiva de acuerdo a su calidad y aptitud para la producción agraria.

La leyenda para los grupos de cultivos que se utiliza en la cartografía catastral se muestra en la tabla 2-2.

| Código | Grupos de cultivos |
|--------|---|
| 0 | No existe |
| 1 | Labor secano |
| 2 | Labor Regadío |
| 3 | Pastos y terrenos incultos |
| 4 | Olivar |
| 5 | Viña |
| 6 | Cítricos |
| 7 | Frutales |
| 8 | Frutos secos |
| 9 | Plantas subtropicales y mediterráneas |
| 10 | Especies maderables de crecimiento lento |
| 11 | Especies maderables de crecimiento rápido |
| 12 | Otros cultivos |

Tabla 2-2. Grupos de cultivos en la cartografía catastral

Actualización de la cartografía catastral

Para mantener este inventario actualizado, los propietarios están obligados a presentar una declaración de alteración catastral, informando del tipo de cambio que ha experimentado el bien inmueble, ya sea un cambio en su geometría o en sus características de uso o propietario. También se puede modificar el catastro por medio de comunicaciones realizadas por notarios, registradores, ayuntamientos u otras administraciones. Por último, la Dirección General del Catastro y las entidades gestoras del impuesto de bienes inmuebles pueden realizar actuaciones inspectoras para detectar cambios no declarados.

En el Real Decreto 1/2004 de 5 de marzo por el que se aprueba el texto refundido de la Ley del Catastro Inmobiliario, se define la Renovación del Catastro de Rústica como

el procedimiento administrativo mediante el cual se actualizan todos los datos físicos y jurídicos de los inmuebles de naturaleza rústica de un término municipal. Comprende la sustitución de la documentación gráfica existente por otra más avanzada que permita una perfecta identificación parcelaria para realizar una rectificación general de las características catastrales de los inmuebles, es decir, superficies, usos, cultivos, intensidades productivas, etc.

Se entiende que se trata de una renovación catastral cuando como consecuencia del largo tiempo transcurrido desde que se efectuó la última conservación masiva de la base de datos catastral de un determinado municipio, la información existente es muy diferente de la realidad que se pretende reflejar. Mientras que se denominan trabajos de actualización, a los que hay que realizar en aquellos otros municipios cuya información no se encuentra tan desfasada como en los anteriores, pero sin embargo, precisa una cierta depuración antes de proceder a la obtención de la nueva cartografía (Manzano Agugliario *et al.*, 2003). Al ser análoga la naturaleza de los trabajos de renovación y de actualización, solamente diferirán en la manera de llevar a campo los trabajos de campo, por lo que los pasos citados a continuación son comunes para ambas situaciones.

Los pasos a seguir para hacer una renovación catastral son:

- a) Obtención de ortofotografías
- b) Volcado de parcelario existente sobre la ortofotografía
- c) Realización de trabajos de campo para investigar titulares, cultivos, delimitación de parcelas y subparcelas, construcciones existentes, etc.
- d) Traspaso de la información obtenida en campo a la ortofotografía.
- e) Cálculo de los nuevos valores catastrales a partir de las nuevas superficies y cultivos.

En toda renovación catastral se debe conservar la división de polígonos y de parcelas existente anteriormente, a fin de facilitar la identificación catastral de las fincas descritas en el Registro de la Propiedad y mantener la permanencia de la Referencia Catastral (Manzano Agugliario *et al.*, 2003).

2.3.1.1.- La parcela catastral en la directiva INSPIRE

La Directiva Europea INSPIRE, aprobada recientemente por el Parlamento Europeo y el Consejo de la Unión Europea, tiene como objetivo fijar normas generales con vistas al establecimiento de una Infraestructura de Información Espacial en la Comunidad Europea, orientada a la aplicación de las políticas comunitarias de medio ambiente y de otras políticas o actuaciones que, en una interpretación cada vez más amplia por parte de la UE, puedan incidir en el medio ambiente (Velasco, 2007).

En sus anexos I, II, y III, la directiva recoge la división en temas de los conjuntos y servicios de datos espaciales a los que se refiere.

La parcela catastral está incluida en el Anexo I y se le reconoce como parte de la información básica sobre la que se generará toda la infraestructura de datos espaciales.

La definición actual de la parcela en la Directiva es general y breve: "Las áreas definidas en los registros catastrales o su equivalente".

La directiva obliga a establecer una coordinación entre los catastros de los estados miembros. Con este objetivo se formó un grupo de trabajo conjunto del Grupo de Expertos en Catastros y Registros de la Propiedad para elaborar un informe sobre el papel de la parcela catastral en las Infraestructuras de Datos Espaciales Europeas. Este informe se realizó en base a dos encuestas enviadas a las organizaciones catastrales de todos los países miembros, que han permitido obtener una completa información sobre la parcela catastral. El tema de la primera encuesta fue definir el papel de la parcela catastral y elaborar un inventario general de sus principales características. La segunda encuesta, basada en los resultados de la primera, se enfocó a determinar el uso de la parcela catastral en las infraestructuras de datos espaciales de cada país y evidenciar su creciente importancia en la sociedad.

Las conclusiones de este trabajo son las siguientes (Velasco, 2007):

- Los cuestionarios confirman la importancia de la parcela catastral y refuerzan lo justificado de su inclusión en el Anexo I de la Directiva INSPIRE.
- Existen cinco elementos clave que definen la parcela catastral.
 - Identificador único
 - Área
 - Límites catastrales
 - Geo-referencia
 - Origen y antecedentes
- La parcela catastral puede utilizarse como localizador. No obstante las diferencias entre países en la definición, cobertura y calidad de los elementos de la parcela catastral, la parcela constituye básicamente el objeto espacial más reducido utilizado ampliamente en toda Europa para numerosas aplicaciones en las infraestructuras nacionales de datos espaciales.
- La parcela catastral tiene múltiples usos; mercado inmobiliario, impuesto de bienes inmuebles, planificación urbanística, control medioambiental, etc.
- La información catastral está disponible en la mayoría de países. Es el acceso a dicha información lo que puede mejorarse.

2.3.2.- Sistema de información geográfica de identificación de parcelas agrícolas - SIGPAC

Con objeto de dar cumplimiento al mandato reglamentario de la Comisión Europea establecido en el Reglamento nº 1593/2000, de 17 de julio de 2000, por el que se establece un Sistema Integrado de Gestión y Control (SIGC) de determinados regímenes de ayuda comunitarios y se obliga a crear un Sistema Gráfico Digital de Identificación de Parcelas Agrícolas (conocido por sus iniciales en inglés, LPIS), utilizando las técnicas informáticas de Información geográfica, en España se ha elaborado un Sistema de Información Geográfica de parcelas agrícolas, SIGPAC, que permite identificar geográficamente las parcelas declaradas por los agricultores en cualquier régimen de ayudas relacionado con la superficie (<http://www.mapa.es/es/sig/pags/sigpac/intro.htm>). En este reglamento se recomienda la utilización de ortoimágenes aéreas o espaciales para la creación del sistema de identificación de parcelas.

La reglamentación europea define la parcela agrícola como una porción continua de terreno, con un único tipo de cultivo y cultivada por un solo agricultor. La parcela catastral española, presenta una serie de ventajas sobre otro tipo de divisiones del terreno para adaptarse a la unidad mínima establecida a nivel europeo. La parcela catastral proporciona una información precisa de cada porción de terreno como su propietario o superficie, además de ser un inventario detallado sobre los usos agrarios del terreno, que aunque no coinciden exactamente con los previstos en las ayudas comunitarias, pueden relacionarse entre sí de forma sencilla (Mirón, 2005). Esos diferentes usos se reflejan dentro de cada parcela en forma de subparcelas que son asimilables a la división en parcelas agrícolas, o recintos, de la Comisión Europea. Si toda la parcela tiene el mismo uso o cultivo sólo existirá un recinto, en cambio, si dentro de la parcela de un propietario coexisten varios cultivos, la parcela estará dividida en tantos recintos como usos se den en la misma. Sin embargo, la analogía directa entre recinto y subparcela se rompe por las diferentes categorías de usos empleadas en el Catastro y en el SIGPAC que ha sido solventada mediante la conversión de las categorías catastrales, mucho más detalladas, en las categorías del SIGPAC. Este es el motivo principal por el que el SIGPAC está basado en el inventario de la D.G. de Catastro.

Dicho reglamento, también establece que, a 1 de enero de 2005, cada Estado miembro debía disponer de una base de datos gráfica de todas las parcelas de cultivo digitalizadas, con una precisión equivalente, al menos, a una cartografía a escala 1:10.000.

Los requisitos del LPIS son los siguientes:

- Entre la información que debe contener se incluye el número de identificación de la parcela, su superficie y su uso, delimitando los usos con derechos a ayudas.

- Debe cubrir todo el espacio rural de forma regular, bajo un mismo sistema.
- En términos de precisión de la cartografía, exige equivalencia a escala 1:10.000, indeterminación en campo entre 0.5 y 1 m y tamaño máximo de píxel de las ortofotos de 1 m.
- El sistema debe permitir el enlace entre las bases de datos gráficas y alfanuméricas, la distribución masiva de información a los agricultores y la conexión con la base de datos del Sistema Integrado.
- Su actualización debe ser al menos anual, las ortofotos no deben tener más de cinco años y debe ser posible realizar cruces inmediatos de toda la información.

El sistema de identificación de parcelas SIGPAC consta de un mosaico de ortofotos digitales que abarcan todo el territorio nacional, sobre las que, inicialmente, se superponen los planos parcelarios de catastro de rústica, de forma que, para cada referencia concreta, el sistema proporciona automáticamente la imagen en pantalla de la parcela referenciada, permitiendo asimismo su impresión en papel.

Entre los objetivos más importantes del Proyecto SIGPAC figuran los siguientes:

- Facilitar a los agricultores la presentación de solicitudes, mediante la producción de los soportes gráficos necesarios para las declaraciones de superficie.
- Facilitar los controles administrativos ya que, la información digital ayudará a la Administración a identificar mejor el origen de los errores derivados de las declaraciones de los agricultores o de la grabación de los datos, y servirá de soporte documental para la resolución de casos dudosos detectados como resultado de estos controles.
- Facilitar los controles sobre el terreno, agilizando la localización de parcelas y permitiendo la realización de "visitas rápidas" tanto en los controles clásicos como de teledetección.

La información cartográfica disponible en el SIGPAC está formada por los datos gráficos vectoriales (parcelas, recintos y olivos), mapas raster del Instituto Geográfico Nacional a escalas 1:25.000, 1:200.000, 1:250.000 y 1:2.000.000, ortofotos con una resolución de 0.5m., etc.

Los pasos principales para la realización del SIGPAC son:

- 1.- Realización de ortofotos con resolución equivalente al menos a escala 1:5000.

- 2.- Incorporación del parcelario catastral y superposición y ajuste del mismo sobre el ortofotomapa continuo.
- 3.- Incorporación de la información sobre ayudas.
- 4.- Delimitación de recintos dentro de cada parcela, a través de fotointerpretación y de la información sobre calificaciones catastrales.
- 5.- Instalación del sistema en Internet.

La actualización del SIGPAC se realiza anualmente, por medio de declaraciones que presentan los agricultores a la información contenida en el Catastro de forma obligatoria cuando se produce una alteración en los bienes inmuebles (Mirón, 2005).

En la tabla 2-3 se describen los distintos usos utilizados en la realización del SIGPAC.

| Código | Descripción |
|--------|---|
| AG | Corrientes y superficies de agua |
| CA | Viales |
| CI | Cítricos |
| CO | Contorno olivar |
| ED | Edificaciones |
| FL | Frutos secos y olivar |
| FO | Forestal |
| FS | Frutos secos |
| FV | Frutos secos y viñedo |
| FY | Frutales |
| IM | Improductivos |
| IS | Islas |
| IV | Invernaderos y cultivos bajo plástico |
| OV | Olivar |
| PA | Pasto con arbolado |
| PR | Pasto arbustivo |
| PS | Pastizal |
| TA | Tierras arables |
| TH | Huerta |
| VF | Viñedo - frutal |
| VI | Viñedo |
| VO | Viñedo olivar |
| ZC | Zona concentrada no incluida en la ortofoto |
| ZU | Zona urbana |
| ZV | Zona censurada |

Tabla 2-3. Códigos de usos empleados en el SIGPAC

Las comunidades autónomas de Navarra y País Vasco tienen su propio SIGPAC con funcionalidades muy similares a las del SIGPAC estatal.

En la dirección <http://www.mapa.es/es/sig/pags/sigpac/intro.htm> se pueden visualizar los diversos Sistemas de Información Geográfica de todas las comunidades autónomas.

Si se selecciona sobre la cartografía a nivel de parcela, se muestran los datos de la parcela con todos los recintos SIGPAC que contiene. En las figuras 2-3 y 2-4 se muestra la información proporcionada por el SIGPAC para una parcela con varios recintos.

| Fecha de vuelo: | 00/2004 | Año de renovación catastral: | 2001 | | | |
|-----------------|------------------------------|------------------------------|------|----------|---------|-----------------|
| PROVINCIA | MUNICIPIO | AGREGADO | ZONA | POLIGONO | PARCELA | Superficie (ha) |
| 46 - VALENCIA | 204 - POBLA DE VALLBONA (LA) | 0 | 0 | 37 | 61 | 0,6157 |

Figura 2-3. Información alfanumérica de una parcela

| RECINTO | Superficie (ha) | USO | COEF. PASTOREO | COEF. REGADIO | INCIDENCIAS | PENDIENTE (%) | ELEGIBILIDAD |
|---------|-----------------|-----|----------------|---------------|-------------|---------------|--------------|
| 1 | 0,4206 | OV | | | 7 | 2,1 | NO |
| 2 | 0,0824 | FY | | | | 2,2 | NO |
| 3 | 0,1127 | FY | | | | 2,9 | NO |

Figura 2-4. Información alfanumérica de los recintos contenidos en la parcela anterior

En la figura 2-5 se muestra la ficha generada por la aplicación SIGPAC correspondiente a la parcela de la consulta anterior.

Con fecha 13 de noviembre de 2004 se publicó el Real Decreto 2128/2004, de 29 de octubre, por el que se regula el sistema de información geográfica de parcelas agrícolas, que atribuye al Fondo Español de Garantía Agrícola (FEGA) el carácter de autoridad competente, a nivel nacional, al estar facultado para la coordinación de los controles a realizar en el ámbito del sistema de gestión y control de las ayudas, así como para llevar a cabo el seguimiento de las actuaciones que, en esta materia, realicen las Comunidades Autónomas, con objeto de garantizar la aplicación armonizada en el territorio nacional de la reglamentación comunitaria

En la metodología propuesta para hacer el control de las ayudas (AGRIFISH Unit, 2007) se establece que la revisión de todas las parcelas para las que se solicita ayuda en determinadas zonas de control establecidas por la administración, se realizará mediante fotointerpretación asistida por ordenador de imágenes muy alta resolución (aéreas o de satélite con una resolución espacial menor a 1m) y con visitas de campo en caso de asignación dudosa.

Se han presentado mejoras a la metodología global establecida por parte de los organismos involucrados en la realización de este control. Escudero y Galiano (2007) desarrollan la metodología seguida por la empresa TRAGSATEC e incorporan como banda adicional al proceso fotointerpretativo una clasificación espectral realizada con el algoritmo ISODATA y el conjunto de imágenes disponibles. La asignación de las clases radiométricas a las clases temáticas (cultivos) se hace a partir de la construcción de una Matriz de Contingencia entre las clases obtenidas y los cultivos comprobados en campo.

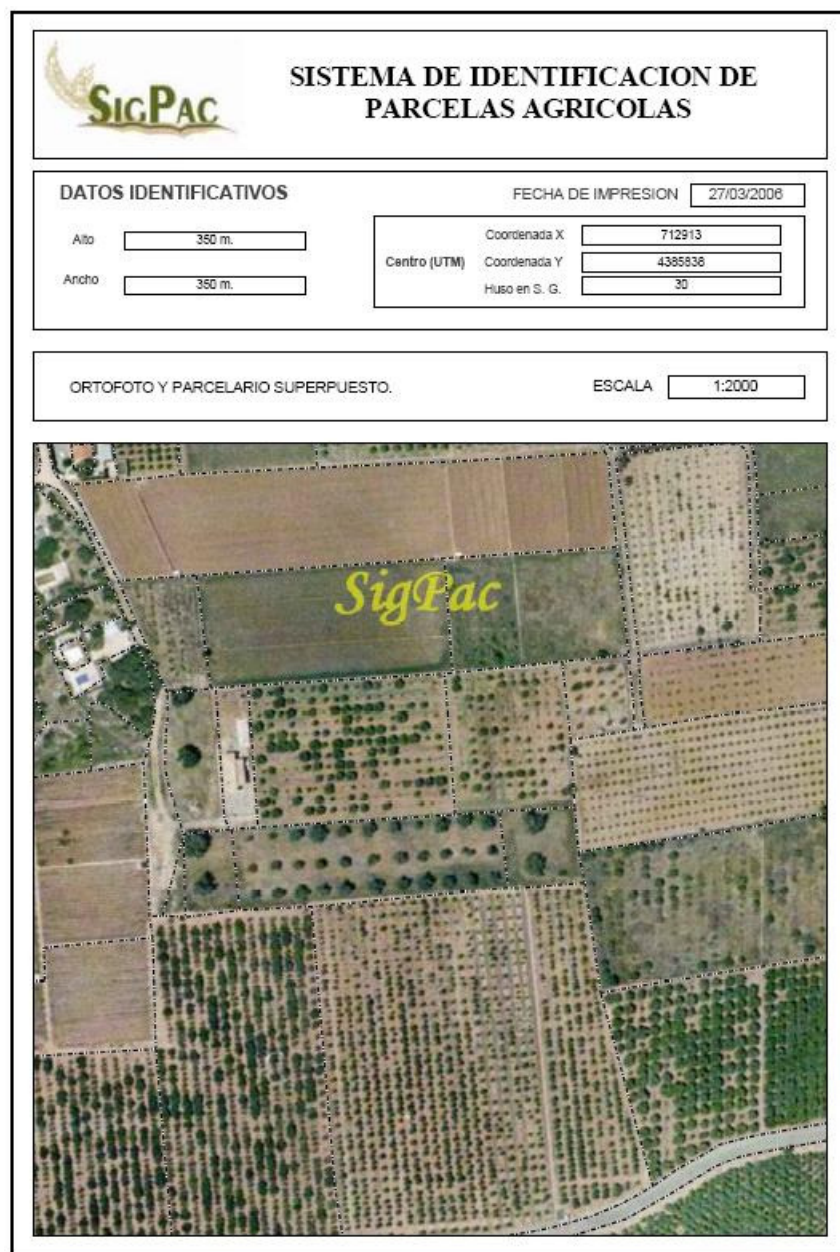


Figura 2-5. Informe gráfico generado por la aplicación SIGPAC

Blaes *et al.* (2005) proponen para agilizar este proceso de revisión por fotointerpretación y visitas de campo, detectar las parcelas sospechosas de ser

declaraciones erróneas por medio de la clasificación basada en parcelas de 3 imágenes ópticas de fechas distintas y una serie de 12 imágenes SAR. Las parcelas sospechosas son aquellas cuya clase asignada en la clasificación no coincide con la declarada y serían las únicas a revisar por el fotointérprete.

2.3.3.- Mapa Forestal de España a escala 1:50000

El mapa forestal de España a escala 1:50000 (MFE50) es la cartografía de la situación actual de las masas forestales, realizada siguiendo un modelo conceptual de usos del suelo jerarquizados, con especial atención en las clases arboladas. (http://www.mma.es/portal/secciones/biodiversidad/banco_datos/info_disponible/mfe50.htm)

La escala elegida, 1:50.000 determina la precisión cartográfica y se tradujo en una tesela mínima de 6.25 hectáreas de manera general y de 2.5 hectáreas para los terrenos arbolados que estuvieran rodeados de usos diferentes a éste. Los elementos lineales se consideraron cuando tuvieran una anchura mínima de 25 metros.

La técnica utilizada consiste en la digitalización sobre pantalla en una imagen georreferenciada, con apoyo de la información digital existente y la utilización de la fotointerpretación clásica con visión estereoscópica para los casos en que no es posible identificar correctamente la cubierta por medio de la fotointerpretación en una única imagen.

A lo largo de la realización del proyecto han variado las imágenes sobre las que se hacía la fotointerpretación. Se comenzó con imágenes del sensor pancromático IRSC1 de 5.6 m de resolución espacial. Posteriormente se utilizaron ortofotos pancromáticas de 1 m de resolución. Finalmente se utilizaron las ortofotos de color y 0.5 m de resolución espacial del proyecto SIGPAC.

Las dudas de interpretación se resuelven mediante abundantes visitas de campo.

La base de datos se compone de un total de quince campos descriptores de la ecología y estructura de las masas. Para cada una de las teselas delimitadas se recogen las tres especies forestales arbóreas principales, cada una con su estado de desarrollo (replado, monte bravo, latizal y fustal), ocupación (porcentaje que la especie ocupa en el total de los árboles) y la fracción de cabida cubierta para el total del arbolado (porcentaje de suelo cubierto por la proyección horizontal de las copas de los árboles).




Figura 2-6. Fragmento del Mapa Forestal Español

2.3.4.- Mapa de Cultivos y Aprovechamientos de España a escala 1/50000

En la década de los 70 se realizó la colección de Mapas de Cultivos y Aprovechamientos (M.C.A.) a escala 1:50.000. Su actualización se inició en 1999 y se está llevando a cabo mediante fotointerpretación en pantalla de ortofotos digitales elaboradas a partir de un vuelo a escala 1:40.000 realizado para el SIG oleícola. Sobre estas ortofotos se delimitan los distintos usos y aprovechamientos. El tamaño mínimo de las teselas es de 2 ha. mientras que para los objetos lineales como ríos y carreteras su ancho mínimo es de 12m (MAPA,2001). De esta forma se crean los recintos o teselas con un uso homogéneo y se les asigna la codificación correspondiente

La fotointerpretación es completada con el apoyo de imágenes del sensor Landsat Thematic Mapper de dos fechas distintas, con los datos del antiguo M.C.A. y de un importante trabajo de campo, visitando aquellas zonas que no pueden ser fotointerpretadas con certeza. La fotointerpretación conjunta de ortofotografías aéreas e imágenes de satélite permite una mayor precisión tanto en la discriminación de los distintos cultivos como en su delimitación.

La actualización del M.C.A. comienza con la obtención de la información de partida, formada por la hoja previa del M.C.A., la ortofotografía correspondiente y las composiciones en "falso color" de imágenes Landsat TM de primavera y verano. Esta información es revisada e integrada en un software propio de la empresa adjudicataria. Previamente a la fotointerpretación se realiza una visita a campo para comprobar los cultivos y aprovechamientos predominantes en la zona, y así disminuir el número de dudas que pudieran surgir durante la identificación de usos a partir de la ortofoto y las imágenes en la fase de fotointerpretación. A continuación, se realiza la fotointerpretación a partir de toda la información disponible. Esta fase se compone de la teselación del territorio, mediante digitalización en pantalla sobre la ortofoto por su mayor resolución espacial, en recintos donde se observa un uso homogéneo y su posterior codificación. La problemática encontrada en la teselación y codificación de los nuevos recintos, da como resultado recintos cuya codificación es dudosa y que se confirma mediante una visita a campo.

A continuación se describen los tipos de cultivos utilizados en la codificación del M.C.A.:

- Los cultivos de **regadío** se han dividido en: arroz, huerta, cultivos forzados, otros cultivos herbáceos, cítricos, frutales, viñedo, olivar, distintas asociaciones de los anteriores y prados y praderas naturales.

- Los cultivos de **secano** se definen en labor intensiva, labor extensiva, frutales de secano, viñedo de secano, olivar en secano, prados o praderas naturales.
- La superficie **forestal** se divide en prados de alta montaña, pastizal, matorral, espartizal y superficie arbolada.
- Los suelos **improductivos** se dividen en terrenos que no son susceptibles de ningún aprovechamiento agrario y terrenos con agua.

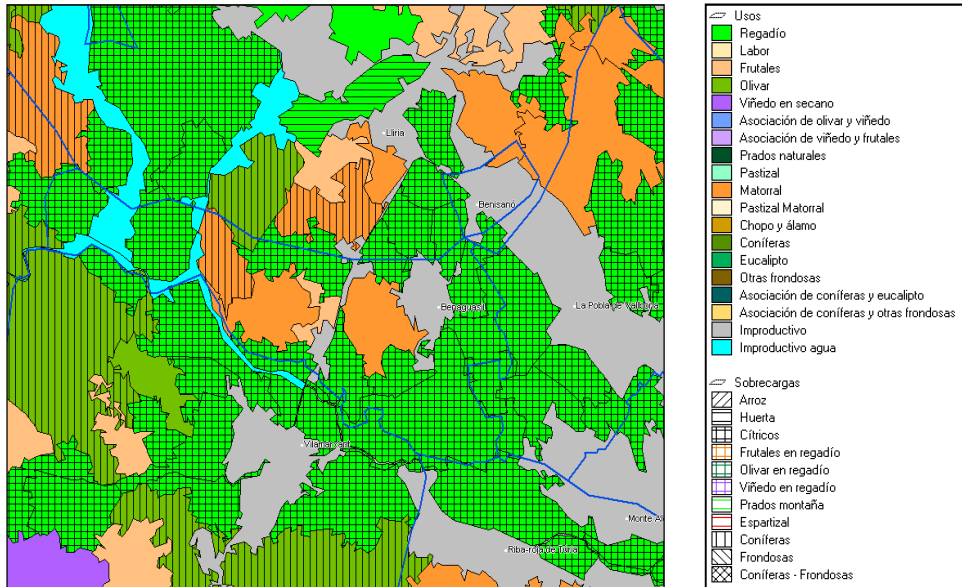


Figura 2-7. Fragmento del Mapa de Cultivos y Aprovechamientos con su leyenda correspondiente

2.3.5.- Corine Land Cover

El Corine Land Cover (CLC) es un inventario de la ocupación del suelo para todo el territorio de la Unión Europea. Su objetivo fundamental es la captura de datos de tipo numérico y geográfico para la creación de una base de datos europea a escala 1:100.000 sobre ocupación del suelo. Hasta el momento, se han realizado dos inventarios CLC correspondientes a las fechas 1990 y 2000. La base de datos correspondiente al año 2006 y la detección de cambios respecto al inventario anterior se está realizando en España de forma integrada con el SIOSE.

Las características básicas del Corine Land Cover son:

- Escala 1/100.000
- La unidad mínima cartografiable es un polígono con una superficie mínima de 25 ha y con un ancho mínimo de 100 m. Esta unidad espacial se define como un área de cobertura homogénea, o como una agregación de pequeñas áreas homogéneas que representan una estructura considerada dentro de la leyenda del CLC. Debe ser estable en el tiempo, ser distinguible de otras unidades vecinas y representar una superficie significativa en relación a la escala de trabajo.
- La nomenclatura o leyenda del CLC es jerárquica y distingue 44 clases en el tercer nivel, 15 en el segundo y 5 en el primero. En España se definieron 5 niveles con 64 clases en el CLC90 y con 85 clases en el CLC2000. Estos niveles adicionales deben agregarse en los del nivel 3 para permitir la integración de los datos a nivel europeo. La leyenda utilizada no define clases espectralmente homogéneas, por lo que no se puede hacer directamente mediante clasificaciones espectrales.

La metodología utilizada en la elaboración del primer inventario Corine Land Cover (CLC90) se basó en la fotointerpretación sobre imágenes del satélite Landsat 5, en falso color, a escala 1/100.000 y su posterior digitalización. La fotointerpretación estuvo asistida por métodos de procesado de imágenes para facilitar la interpretación de algunas zonas complicadas, así como para generar información adicional como índices de vegetación.

La información cartográfica, documental o fotográfica relativa a la cobertura del suelo que no está incluida en la base de datos de imágenes de satélite, se considera información complementaria. Esta información complementaria está compuesta por mapas topográficos, mapas temáticos de usos del suelo, información estadística, fotografías

aéreas, etc. Por tanto, una unidad espacial se asigna a una clase, no sólo con la interpretación de las imágenes de satélite sino con la consideración de la información complementaria disponible.

Detección de cambios respecto a CLC90

El CLC2000 está formado por una base de datos de ocupación del suelo en el año 2000 y por el conjunto de cambios ocurridos durante los diez años transcurridos entre la realización de los dos inventarios (Büttner *et al.*, 2002). Por cambio se entiende tanto la creación de una unidad nueva, como la modificación de los límites de la unidad existente.

Para la realización del inventario del año 2000, se utilizaron imágenes del satélite Landsat 7 y el inventario anterior como referencia. Se comprobaron tanto los cambios ocurridos, como los errores contenidos en el primer inventario. La detección de cambios y su cartografiado se realizó mediante comparación de imágenes, empleando herramientas de fotointerpretación asistida por ordenador (Perdigao y Annoni, 1997). El análisis de las imágenes se realizó mediante un entorno multiventana. Mientras en una ventana se mostraba la imagen utilizada para la creación del CORINE Land Cover y superpuesta la base de datos original, en otra ventana, se mostraba la nueva imagen y una copia de la base de datos del CORINE Land Cover donde se delimitaron y codificaron los cambios (IGN, 2001).

Aunque la detección de cambios se hizo manualmente, se planteó la posibilidad de hacerla de forma automática mediante dos enfoques posibles:

- a) Comparación de dos clasificaciones de las imágenes en ambas fechas.
La principal limitación de este enfoque es que en la leyenda del CLC existen clases que no pueden ser reconocidas sólo por su signatura espectral, bien porque existen varias clases con las mismas propiedades espectrales, o bien, porque necesitan otra información como el contexto o la forma.
- b) Reconocimiento automático de cambios en píxeles contenidos en un polígono usando una imagen. Esta metodología está basada en el análisis por objetos y consiste en determinar si dentro de un polígono hay áreas anómalas o en comprobar si los límites del objeto deben variarse para conseguir un mejor ajuste con la imagen. Los cambios así detectados deben ser validados por un intérprete que será el que decida el código a asignar al cambio detectado de forma automática.

Los cambios automáticos de detección de cambios pueden utilizarse para cuantificar los cambios ocurridos en un periodo de tiempo y aunque no sean suficientemente precisos para usarlos directamente en la actualización de la base de datos,

sí que sirven de apoyo para el intérprete y para decidir el momento apropiado de realizar una actualización de la base de datos.

La combinación de los datos de ambos inventarios permite obtener una matriz de cambios para un espacio concreto (figura 2-8).

| año | 2000 | | | | | | | | | | | | | | | | | | | | Total | | | |
|------------------|------|------|-----|-----|-----|-----|-----|-----|-----|------|-----|-----|-----|-----|-----|------|-----|-----|-----|-----|-------|------|-----|--------|
| 1990 | 112 | 121 | 122 | 123 | 131 | 132 | 133 | 141 | 142 | 211 | 221 | 222 | 231 | 242 | 243 | 311 | 312 | 313 | 321 | 324 | 411 | 511 | 512 | 4062 |
| 112 | 4062 | | | | | | | | | | | | | | | | | | | | | | | 4062 |
| 121 | | 1502 | | | | | | | | 11 | | | | | | | | | | | | | | 1512 |
| 122 | | | 50 | | | | | | | | | | | | | | | | | | | | | 50 |
| 123 | | | | 127 | | | | | | | | | | | | | | | | | | | | 127 |
| 131 | | | | | 0 | | | | | | | | | | | | | | | | | | | 0 |
| 132 | | | | | | 0 | | | | | | | | | | | | | | | | | | 0 |
| 133 | 86 | | | | | | 0 | | | | | | | | | | | | | 59 | | | | 146 |
| 141 | | | | | | | | 27 | | | | | | | | | | | | | | | | 27 |
| 142 | | | | | | | | | 644 | | | | | | | | | | | | | | | 644 |
| 211 | 54 | 54 | 10 | | 31 | 22 | 114 | | | 6656 | | | 4 | | 247 | 42 | | | | | | | | 9 7243 |
| 221 | | | | | | | | | | 31 | 186 | | | | | | | | | | | | | 217 |
| 222 | | | | | | | | | | 80 | | 368 | | | | | | | | | | | | 448 |
| 231 | | 32 | 19 | | | | | | | | | | 412 | | 132 | 8 | | | | 38 | 56 | | 15 | 712 |
| 242 | 142 | | | | | | | | | | | | 427 | | | | | | | | | | | 569 |
| 243 | 16 | | | | | | | | 4 | | | 22 | | 188 | 50 | | | | | | | | | 279 |
| 311 | | | 16 | | | | | | | | | | 55 | | | 1715 | | | | | 23 | | | 1810 |
| 312 | | | | | | 14 | | | | 23 | | | | | | | 55 | | | | | | | 92 |
| 313 | | | | | | | | | | | | | | | | | | 184 | | | | | | 184 |
| 321 | | | | | | | | | | | | | | | | | | | 184 | | | | | 184 |
| 324 | | | | | | | | | | | | | | | | | | | | | | | | 0 |
| 411 | | | | | | | | | | | | | | | 13 | | | | | | 70 | | | 82 |
| 511 | | | | | | | | | | | | | | | | | | | | | | 1071 | | 1071 |
| 512 | | | | | | | | | | | | | | | | | | | | | | | 141 | 141 |
| Área total (ha): | 4360 | 1588 | 95 | 127 | 31 | 36 | 114 | 27 | 644 | 6804 | 186 | 368 | 493 | 427 | 579 | 1815 | 55 | 184 | 184 | 120 | 126 | 1071 | 165 | 19600 |

Figura 2-8. Matriz de cambios del CLC2000 respecto al CLC90 (adaptada de Büttner *et al.*, 2002)

El análisis de la matriz de cambios permite estimar las probabilidades de cambio entre diferentes ocupaciones del suelo, de forma que para cada clase original se establezca un orden de probabilidad de nuevas clases posibles (tabla 2-4), o bien, una matriz de transiciones posibles basadas en probabilidades (tabla 2-5).

| Clase original | Nuevas clases posibles en orden de probabilidad | | |
|----------------|---|-----|-----|
| 111 | | | |
| 112 | 111 | | |
| 121 | 112 | 111 | |
| 122 | 112 | 111 | 131 |

Tabla 2-4. Matriz de eventos posibles

| Clase original | Nuevas clases posibles | | | | | | |
|----------------|------------------------|-----|-----|-----|-----|-----|-----|
| | 111 | 112 | 121 | 122 | 131 | 211 | 212 |
| 111 | 100% | | | | | | |
| 112 | 50% | 50% | | | | | |
| 121 | 5% | 25% | 70% | | | | |
| 122 | 2% | 7% | | 90% | 1% | | |

Tabla 2-5. Matriz de transiciones posibles

Estas tablas pueden resultar útiles para el fotointérprete en la asignación de una nueva clase a un polígono, así como para detectar errores en la asignación de clases, ya que algunos cambios no son posibles. Por ejemplo, un cambio detectado de suelo urbano a forestal tiene pocas probabilidades de ser correcto. El uso de este enfoque era opcional para los países participantes, pero se recomendaba hacer estas tablas al principio del trabajo basándose en la información auxiliar, ya que permiten representar el nivel de conocimiento que se tiene del territorio y sintetizar la evolución que ha ocurrido. Al final de la actualización, se pueden comparar los resultados esperados y los obtenidos (Perdigao y Annoni, 1997).

2.3.6.- SIOSE

Se conoce por el acrónimo SIOSE al Sistema de Información sobre Ocupación del Suelo de España, cuyo objetivo es integrar la información de las Bases de Datos de coberturas y usos del suelo de las Comunidades Autónomas y de la Administración General del Estado (<http://www.ign.es/siose/presentacion.html>).

Sus **características técnicas** son las siguientes:

- Sistema de información geográfica con una única capa de geometría de polígono.
- Escala de Referencia: 1: 25.000.
- Sistema Geodésico de Referencia: ETRS 89.
- Proyección UTM: husos 28, 29, 30 y 31.
- Unidad mínima de superficie a representar, dependiendo de las clases:
 - Superficies artificiales y láminas de agua: 1 ha.
 - Playas, vegetación de ribera, humedales y cultivos forzados: 0,5 ha.
 - Zonas agrícolas, forestales y naturales: 2 ha.
- Periodicidad de actualización: 5 años.
- Imágenes de referencia: SPOT5 obtenida como la fusión de las imágenes pancromática y multiespectrales de 2,5 m de resolución espacial del año 2005, conjuntamente con dos coberturas de imágenes Landsat5 TM del año 2005 y ortofotos del PNOA de los años 2004 y 2006, como complemento.

SIOSE utiliza un **modelo conceptual de datos** normalizado, interoperable y armonizado de la ocupación del suelo:

- Multi-parámetro: varios atributos para un mismo polígono, entidad principal.
- Multicriterio: asociado al polígono su uso y cobertura.
- Extensible y compatible con otros proyectos nacionales y europeos.
- Asignación de metadatos según el Núcleo Español de Metadatos y la norma ISO19115.
- Orientado a objetos: utilizando como técnica fundamental el modelo entidad-relación realizado según notación UML.

Sus principales características son (IGN, 2007):

- La entidad de trabajo es el polígono, que es la unidad espacial del terreno que presenta una ocupación de suelo con cobertura homogénea. El polígono es la única entidad con geometría propia del modelo de datos SIOSE. Se definen por un conjunto de arcos que limitan su extensión superficial, separando dos entornos de coberturas o uso diferente.
- 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 2 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.

Las coberturas simples se clasifican en:

- **artificiales**
 - Edificación.
 - Zona verde artificial y arbolado urbano.
 - Lámina de agua artificial.

- Vial, aparcamiento o zona peatonal sin vegetación.
- Otras construcciones.
- Suelo no edificado.
- Zonas de extracción o vertido.

- **zonas agrícolas, forestales y naturales**

- Arbolado forestal: Frondosas y coníferas.
- Matorral.
- Pastizal.
- Terrenos sin vegetación: Playas, dunas, arenales, roquedo, ramblas, suelo desnudo, zonas quemadas, glaciares y nieves permanentes.
- Coberturas húmedas: Humedales continentales y humedales marinos.
- Coberturas de agua: Aguas continentales y aguas marinas.
- Cultivos: Arrozales, otros cultivos herbáceos distintos del arroz, cítricos, frutales no cítricos, viñedos, olivares, otros cultivos leñosos y prados.

Las coberturas compuestas, que pertenecen al tipo asociación se componen de distintos porcentajes de cualquiera de las coberturas simples. Se han establecido cinco grupos de asociaciones predefinidas que se describen a continuación:

Dehesa: Formada por arbolado forestal, matorral, pastizal, cultivos herbáceos y lámina de agua artificial.

Huerto familiar: Compuesto de cultivos herbáceos, cultivos leñosos, edificación, lámina de agua artificial y arbolado forestal.

Asentamiento agrícola residencial: Se compone de: edificación, lámina de agua artificial, cultivos herbáceos, cultivos leñosos, prados, matorral, arbolado forestal.

Olivar/viñedo: Se compone de las coberturas simples, olivar y viñedo.

Artificial Compuesto: Se compone de edificación, zona verde artificial y arbolado urbano, lámina de agua artificial, vial, aparcamiento o zona peatonal sin vegetación, otras construcciones, suelo no edificado y zonas de extracción o vertido.

Metodología de realización

La metodología de trabajo está basada en la fotointerpretación asistida por ordenador, apoyada por la utilización de herramientas que permitan realizar funciones básicas de tratamiento de imágenes, superposición de datos vectoriales sobre datos ráster, edición topológica de datos vectoriales y con un entorno multiventana que permita la visualización simultánea de datos provenientes de diferentes orígenes.

Para realizar dicha fotointerpretación, los equipos de producción cuentan con los siguientes conjuntos de datos como información de referencia y de apoyo temático:

- Cobertura de imágenes resultantes de la fusión de las imágenes pancromáticas y multiespectrales de SPOT5 de 2.5 m de resolución espacial.
- Cobertura de imágenes Landsat5 de su territorio de dos fechas (primavera y otoño).
- Ortofotos de su territorio de alta resolución (tamaño píxel ≤ 1 m) que estén disponibles en el momento de comenzar los trabajos.
- Datos vectoriales procedentes de la base de datos BCN25 del Instituto Geográfico Nacional
- Datos vectoriales procedentes de la cartografía catastral de la Dirección General del Catastro.
- Mapa de Cultivos y Aprovechamientos (MCA) de aquellas zonas en las que esté disponible y actualizado.
- Mapa Forestal de España (MFE) de aquellas zonas en las que esté disponible y actualizado.
- Mapa Geológico (MAGNA) de las Islas Canarias del Instituto Geológico y Minero de España (IGME).
- Otras bases de datos topográficas y/o temáticas en materia de ocupación de suelo, en formato vectorial o ráster, que puedan estar disponibles en cada comunidad autónoma.

Como resultado de la fotointerpretación se rellenará la base de datos SIOSE, cuya estructura corresponde al modelo de datos orientado a objetos diseñado para el proyecto.

Tras la fotointerpretación se efectuará una comprobación en campo tomando fotografías de campo digitales georreferenciadas con GPS.

El equipo de producción de cada comunidad autónoma debe realizar un control de calidad interno asegurándose de la calidad geométrica, topológica y temática de los datos producidos.

A nivel estatal se realiza una revisión detallada de la base de datos producida, con una consideración detallada de los procesos productivos, y de su adecuada documentación.

Por último, se integran los datos y la base de datos compondrá finalmente una unidad lógica sin desajustes ni geométricos ni semánticos entre comunidades autónomas limítrofes.

2.3.7.- Conclusiones

Del análisis de las bases de datos cartográficas presentadas, se deducen las siguientes conclusiones relativas a la generación y/o actualización de las bases de datos sobre usos y coberturas del suelo:

- En todos los casos, la unidad mínima de información es un **polígono**, denominado con terminología variable: tesela, recinto, subparcela; con características homogéneas respecto a la leyenda definida.
- La delimitación de los polígonos se realiza de forma manual por un operador.
- En todos los casos se realizó **fotointerpretación** sobre ortoimágenes, bien directamente sobre las imágenes en papel, o directamente en pantalla.
- En ningún caso se han utilizado métodos de clasificación de imágenes para la asignación de clases a los polígonos.
- La fotointerpretación estuvo complementada con **trabajos de campo**.
- La utilización de **información adicional** es fundamental para la generación de una cartografía fiable. La incorporación de esta información tanto en pasos intermedios del proceso de clasificación, como en la evaluación del mismo es imprescindible.

2.4.- El Plan Nacional de Observación del Territorio (PNOT)

El Ministerio de Fomento, a través del Instituto Geográfico Nacional (IGN) y el Centro Nacional de Información Geográfica ha desarrollado el Plan Nacional de Observación del Territorio (PNOT) para obtener coberturas de imágenes aéreas y de satélite a nivel nacional con las resoluciones espaciales y la periodicidad adecuada para dar respuesta a las distintas necesidades de información sobre el territorio que existen. Los productos obtenidos de la aplicación del PNOT, debido a sus características técnicas, su periodicidad y su cobertura espacial, constituyen la base que permite afrontar la actualización de las bases de datos de ocupación del suelo a nivel estatal.

Este plan está organizado en las siguientes fases (Arozarena *et al.*, 2008):

Primera fase: Obtención y tratamiento de las coberturas de imágenes

Esta primera fase tiene por objeto la obtención de coberturas de imágenes aéreas y de satélite, con resoluciones y ritmos de actualización optimizadas 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 y frecuencia temporal.

- 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 obtienen un modelo digital del terreno y otro de superficie con precisión altimétrica de 2 m (emc) y ortoimágenes 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 con un tamaño de píxel de 25 cm.

La producción del PNOA se inició en el año 2004 y se realiza por las Comunidades Autónomas, siendo la financiación compartida entre la Administración General del Estado (66%) y las comunidades autónomas (34%).

Las cámaras digitales, que se usan mayoritariamente desde 2005, tienen los tres canales del visible más uno de infrarrojo próximo.

- Plan Nacional de Teledetección (PNT)

El Plan Nacional de Teledetección pretende coordinar la obtención y el tratamiento de recubrimientos de imágenes de satélite sobre nuestro territorio, para ello se definen los siguientes objetivos (Villa *et al.*, 2008):

- Disminuir al máximo los costes del uso de las imágenes de satélite y las técnicas de Teledetección, de forma que se adquieran y se procesen una sola vez y puedan ser utilizadas por todos los organismos de las distintas administraciones.
- Facilitar la utilización de las imágenes y los datos derivados mediante especificaciones técnicas comunes, procesos y productos documentados clara y abiertamente.
- Disminuir al máximo los plazos entre la captación de la imagen y la disponibilidad de los datos derivados.
- La información obtenida debe satisfacer al máximo las necesidades de todos los usuarios.
- Fomentar la consolidación, mejora y expansión del tejido empresarial español en el sector de la Teledetección.
- Fomentar la Innovación en España mediante la sinergia entre: Administración, Universidades, OPIS y Empresas.

Estas coberturas están estructuradas en tres niveles de resolución espacial:

- Alta resolución:

Coberturas con imágenes de satélite de 2 a 10 m de resolución espacial en modo pancromático y de 10 a 30 m 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 2005 a 2009, el satélite escogido para la alta resolución ha sido SPOT5, con 2.5 m en pancromático y 10 m en multiespectral. Otras alternativas serían Formosat, y el satélite español INGENIO en el futuro próximo.

- Media resolución:

Coberturas con imágenes de satélites de 10 a 15 m en modo pancromático y de 20 a 50 m de resolución en modo multiespectral (satélites SPOT 4, Landsat 5, Landsat 7 , IRS, Aster, etc...). La periodicidad prevista inicialmente, era de al menos 4 coberturas al año, para cubrir adecuadamente los distintos períodos fenológicos (primavera, verano, otoño, invierno), pero desde mayo de 2008 se ha optado por una suscripción continua a los datos del satélite Landsat5, sensor TM (IGN, 2009). 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. Actualmente se está adquiriendo Landsat 5 Thematic Mapper, con un

periodo de revisita de 16 días y 30 m de resolución máxima. Otras alternativas serán los sensores: DEIMOS1 o Sentinel 2. Asimismo, se pretende recopilar e inventariar todas las imágenes Landsat históricas sobre el territorio español existentes en los distintos organismos de las Administraciones, de forma que se puedan compartir entre todos ellos.

- Baja resolución:

Coberturas con imágenes multiespectrales de 50 a 5.000 m de resolución (satélites NOAA AVHRR, MODIS, SPOT (Vegetation), etc...) con una periodicidad desde 30 días a 15 minutos. Las aplicaciones principales son: extracción de parámetros biofísicos y medioambientales (NDVI, temperatura del suelo, material combustible, riesgo de incendio, etc.). Los sensores propuestos son AQUA-TERRA Modis o ENVISAT Meris. Otras alternativas de muy baja resolución, son: NOAA AVHRR, SPOT Vegetation, etc.

Segunda fase: Extracción de la información

La extracción de información está dirigida en dos vertientes distintas. Por un lado la obtención del SIOSE, descrito en la sección 2.3.6 y por otro lado, la obtención de indicadores agroambientales y parámetros biofísicos que pueden ser obtenidos de forma periódica mediante imágenes de satélite de resolución espacial media y baja.

Tercera fase: diseminación de la información

Para poner a disposición de todos los usuarios la información generada se prevé su publicación en servidores de datos, internet, transmisión de ficheros por FTP, entrega en soportes físicos, etc.

Capítulo III

LA CLASIFICACIÓN DE IMÁGENES Y LA ACTUALIZACIÓN DE BASES DE DATOS CARTOGRÁFICAS

3.1.- Introducción

La clasificación digital de imágenes es el proceso por el que se asigna un píxel de una imagen multi-espectral a una de las categorías de la leyenda, generalmente sobre la base de similitudes entre los valores numéricos que las definen (Chuvieco, 1996).

La generación de cartografía temática a partir de imágenes aéreas o de satélite se realiza mediante fotointerpretación o por clasificación digital de la imagen. En ambas técnicas se siguen los mismos principios, aunque con variaciones en su aplicación. En primer lugar, del análisis de las imágenes se extraen las características definitorias de las diferentes clases a identificar. A continuación se comparan el total de elementos en las imágenes con las características obtenidas en el paso anterior. Por último, cada uno de los elementos que forman la imagen, píxeles individuales o grupos de ellos, se asignan a la clase correspondiente en función de su semejanza con las características que definen el total de las categorías.

La clasificación de imágenes es un proceso complejo que requiere considerar numerosos factores. Los pasos principales en la clasificación de imágenes incluyen la selección de un método de clasificación adecuado, selección de muestras de aprendizaje, pre-procesado de la imagen, extracción de características, post-procesado de la clasificación y evaluación de la precisión obtenida.

Tradicionalmente, los métodos de clasificación de imágenes se han dividido en dos categorías: métodos supervisados y métodos no supervisados; según la intervención del usuario en la selección de muestras de entrenamiento necesarias para obtener las características estadísticas descriptivas de cada clase. En los métodos supervisados, el usuario selecciona conjuntos de píxeles representativos de las distintas clases informacionales definidas en la leyenda. Mientras que en los métodos no supervisados, los algoritmos determinan las categorías resultantes de la clasificación mediante el análisis de los niveles digitales de todos los píxeles en la imagen a clasificar. En el primer caso, las clases resultantes tienen un significado claro para el operador pues han sido definidas por él. Mientras que en el segundo, las clases obtenidas no tienen un significado evidente ya que corresponden a agrupaciones de píxeles homogéneas y es el usuario el encargado de interpretarlas y dotarlas de significado.

Los métodos de clasificación también pueden agruparse según otros criterios, así por ejemplo, existen clasificadores paramétricos o no paramétricos, clasificadores duros o blandos y clasificadores por píxel, sub-píxel o por parcela u objeto (Lu y Weng, 2007).

En las secciones siguientes se describen los métodos de clasificación según distintos enfoques. En primer lugar, según la unidad espacial que se considera en la clasificación y en segundo lugar, según las condiciones que se establecen a las características descriptivas de los objetos a clasificar.

En la sección 3.4 se analiza la detección de cambios en una base de datos mediante el procesamiento de imágenes digitales, mientras que en la sección 3.5 se analizan las distintas posibilidades para incorporar la información contenida en una base de datos en un proceso de clasificación de imágenes.

3.2.- Métodos de clasificación según la unidad espacial considerada

La resolución espacial de una imagen es una característica de la misma determinada por las características del sensor y por las condiciones de adquisición de la imagen. Siendo una de las características básicas de la imagen, el tamaño del píxel no debe condicionar totalmente la metodología a utilizar ni el tamaño de los objetos a extraer del análisis de la imagen.

En algunos casos, el tamaño del píxel será demasiado grande en relación con el tamaño de los objetos a identificar, requiriendo la realización de una clasificación subpíxel

para obtener un grado de detalle superior al de la imagen. En cambio, en el caso de imágenes de alta resolución, el elevado grado de detalle de la imagen requiere un tratamiento de la misma, basado en la agrupación de los píxeles en regiones homogéneas. La simplificación de la imagen permite, en la mayoría de los casos, aumentar la fiabilidad de la información extraída.

A continuación, se describen los distintos enfoques de selección de la unidad espacial de clasificación, haciendo hincapié en la clasificación orientada a objetos.

3.2.1.- Clasificadores por píxel

Los clasificadores tradicionales por píxel obtienen un vector de características para cada clase a partir de las propiedades espectrales de todos los píxeles contenidos en sus respectivas áreas de entrenamiento. Cada píxel es asignado a una categoría que es exclusiva respecto al resto. Esta metodología da buenos resultados en las cubiertas espectralmente homogéneas, pero proporciona resultados menos satisfactorios en las cubiertas heterogéneas. Sus principales inconvenientes son que no considera la información espacial de la imagen (Blaschke *et al.*, 2004) y la existencia de píxeles mixtos, o de borde, que representan mezclas de dos o más tipos de coberturas.

Estos métodos son adecuados para extraer información de cobertura del suelo a partir de imágenes de satélite con resolución espacial decamétrica, especialmente con el método de clasificación supervisada de máxima probabilidad. Estas clasificaciones producen cartografía de cobertura del suelo en formato ráster y su calidad depende de las resoluciones espacial, espectral, radiométrica y temporal de las imágenes (Raclot *et al.*, 2005).

Aunque la clasificación por píxel se ha demostrado útil para la clasificación de cultivos, hay dos problemas de clasificación frecuentes que pueden deteriorar bastante los resultados de la clasificación por píxel de cultivos (Smith y Fuller, 2001). El primer problema es la variabilidad espectral de una cubierta dentro de una parcela agrícola debido a, por ejemplo, variaciones en la humedad del suelo, diferencias en nutrientes, enfermedades, etc. Esta heterogeneidad espectral en el interior de una parcela puede resultar en la asignación de diferentes clases a las regiones de una misma parcela, aún teniendo toda ella el mismo cultivo. El segundo problema es la aparición de píxeles mixtos situados en la zona de contacto de dos parcelas limítrofes. En algunos casos, la signatura espectral de los píxeles mixtos es más similar a un cultivo distinto a los dos presentes en esa superficie, con lo que su clasificación será incorrecta.

La aparición de las imágenes de alta resolución que se ha producido en los últimos años auguraba un aumento en la precisión de los resultados obtenidos en la realización de cartografía. Sin embargo, en muchas ocasiones los resultados no han sido tan fiables como se podría esperar, ya que el grado de detalle que proporcionan estas imágenes requiere un tratamiento distinto al empleado en las imágenes de media o baja resolución en las cuales los datos estaban suavizados por las propias características del sensor.

Directamente relacionado con la mayor disponibilidad de imágenes con resoluciones espaciales mayores, aparece un incremento en la variabilidad interna de las parcelas que se captan en las imágenes (Berberoglu y Curran, 2004). Esta variabilidad interna puede llevar a reducir la precisión de las clasificaciones basadas en datos espectrales utilizando el enfoque por píxel. En los últimos años, los algoritmos clásicos de clasificación de imágenes basados en píxeles están siendo cada vez menos utilizados en el procesamiento de imágenes de alta resolución, en las cuales los píxeles vecinos están muy correlacionados y en muchos casos pertenecen a la misma clase informacional (Antunes *et al.*, 2003). Además, producen un característico error de clasificación llamado efecto sal y pimienta debido a la alta heterogeneidad de los paisajes complejos.

3.2.2.- Clasificadores sub-píxel

La suposición de que cada píxel pertenece a una clase informacional no es correcta en muchos casos, especialmente cuando se trata de paisajes complejos y se emplean imágenes de resolución media o baja. La existencia de píxeles mixtos dificulta la aplicación de los clasificadores por píxel. Por esto, es necesario abordar la clasificación desde un punto de vista distinto. En lugar de un clasificador duro, entendido como el que asigna una única clase a cada píxel, se utilizan clasificadores blandos que determinan el grado de pertenencia de un píxel a cada clase. Entre estos métodos destaca la clasificación difusa o borrosa, conocida por el término inglés *fuzzy*, que determina para cada píxel el grado de pertenencia a las distintas clases a partir de las funciones de pertenencia definidas para cada una de ellas.

El Análisis de Mezclas Espectrales también es frecuentemente utilizado para determinar la proporción de un píxel correspondiente a cada clase. Este método asume que la radiancia captada por un sensor es una combinación lineal de la radiancia de los componentes básicos en el interior del píxel (Adams *et al.*, 1995). Como resultado de la aplicación de este método se obtiene una imagen por cada uno de los componentes

básicos indicando la fracción representada por ese componente en los píxeles de la imagen.

3.2.3.- Clasificadores de contexto

En la clasificación por píxel se utiliza el nivel digital del píxel en varias bandas espectrales; es decir, los valores que le corresponden a un píxel en un espacio multidimensional de características, pero no se considera el contexto espacial en que se encuentra. El contexto espacial ha tenido una importancia reducida en el análisis de imágenes basado en píxeles. Se ha centrado la atención en el análisis estadístico de los valores almacenados en los píxeles, más que en descubrir y entender los patrones espaciales que ellos siguen.

Entre los rasgos más importantes para la interpretación visual humana siempre se incluyen las características espaciales de la imagen como son la textura, la forma, el tamaño, la presencia de sombras, la localización, etc. Por tanto, la información espacial debe considerarse en la clasificación de imágenes.

Los algoritmos que emplean más datos además del nivel digital de un píxel se conocen como algoritmos de contexto.

De Jong *et al.* (2004) crean el clasificador espectral y espacial que consiste en separar en una imagen las zonas homogéneas, donde se aplica la clasificación por píxel, de las áreas heterogéneas que son más adecuadas para la aplicación de métodos de clasificación de contexto. Para determinar las regiones homogéneas en sus características espaciales y espectrales, se calcula un índice de semejanza entre cada píxel y sus cuatro vecinos. Estableciendo un umbral a este índice consiguen separar las zonas homogéneas de las heterogéneas.

La clasificación contextual puede clasificarse en tres tipos en función de la etapa en la que hacen uso de las características espaciales: pre-procesado, post-procesado y clasificador contextual (Gong y Xu, 2004).

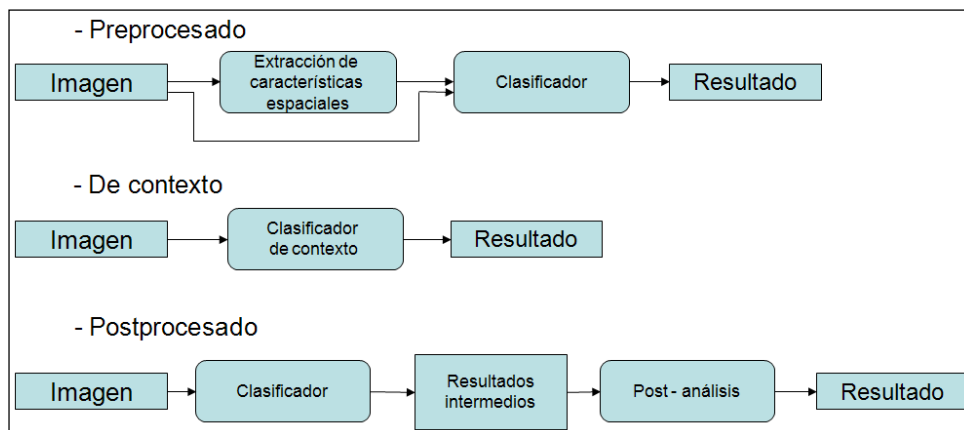


Figura 3-1. Clasificadores de contexto (adaptada de Gong y Xu, 2004)

- **Métodos de pre-procesado:** Consisten en extraer de la imagen una serie de características espaciales descriptivas del dominio circundante a cada píxel. Cada una de las características espaciales extraídas de la imagen se incorpora al espacio multidimensional de características, de modo que cada píxel tiene asociado un vector de características espectrales y espaciales o texturales. En el tratamiento de imágenes digitales se conoce con el término textura al conjunto de propiedades o características que describen la distribución espacial de los niveles de gris correspondientes a los píxeles de una determinada región. Posteriormente, cada píxel será asignado a una clase por un clasificador estadístico convencional como puede ser el clasificador de máxima probabilidad, el de mínima distancia o cualquier otro.

Existen en la bibliografía numerosos métodos diseñados para extraer información textural de la imagen como por ejemplo la matriz de coocurrencias de niveles de gris (Haralick *et al.*, 1973), los filtros de Gabor (Weldon *et al.*, 1998), la transformada wavelet (Ruiz *et al.*, 2004), el variograma (Chica-Olmo *et al.*, 2004), etc.

- **Métodos de post-procesado:** Estos métodos perfeccionan las imágenes ya clasificadas y son conocidos como reclasificadores contextuales. Los métodos de post-procesado evalúan una clasificación y la modifican según un determinado criterio. Un ejemplo de método de post-procesado sería la aplicación de un filtro de moda, que asigna a cada píxel la clase más frecuente en su vecindario. Otro ejemplo de método de post-procesado sería el método SPARK o *kernel* de reclasificación espacial (Sluiter *et al.*, 2004) que consiste en definir unas matrices que representan los patrones espaciales típicos de los distintos usos de suelo. Posteriormente el entorno o vecindario de cada píxel clasificado se compara con

las matrices correspondientes a los distintos usos de suelo y la clase asignada al píxel será aquella cuya matriz sea más similar al vecindario del píxel.

- Clasificadores de contexto: En lugar de extraer información contextual y almacenarla para usarla en la clasificación como ocurre en los métodos contextuales de pre-procesado, un clasificador contextual utiliza la información del entorno del píxel directamente en el proceso de asignar una etiqueta de clase al píxel.

Gong *et al.* (2004) proponen un clasificador basado en la frecuencia de los niveles digitales en el vecindario de un píxel. Este método puede aplicarse directamente a una imagen siempre que el rango de niveles digitales de la imagen no sea demasiado grande y puede considerarse como un clasificador de contexto. Consiste en obtener una tabla de frecuencias, un histograma, de los niveles digitales en el vecindario de un píxel. El píxel se asignará a la clase cuya tabla de frecuencias sea más similar. La distancia entre la tabla de frecuencias del píxel y la de cada una de las clases posibles se calcula haciendo el sumatorio de las diferencias en valor absoluto de las frecuencias de cada nivel digital en las dos tablas que se comparan.

3.2.4.- Clasificadores orientados a objetos

Entre los métodos clasificadores que consideran la distribución espacial existente en la imagen hay que incluir los clasificadores orientados a objetos.

El análisis de imágenes basado en objetos es una nueva sub-disciplina que está recibiendo una gran atención por parte de numerosos investigadores como Galli y Malinverni (2005), Benz *et al.* (2004), Blaschke *et al.* (2004) y firmas comerciales como Definiens Imaging AG o ITT VIS que han desarrollado aplicaciones específicas para este tipo de análisis. Recientemente, se ha celebrado la segunda conferencia internacional en Análisis de Imágenes Basado en Objetos celebrada en Calgary (Canada) en agosto de 2008, bajo la organización de la Agencia Espacial Canadiense, la Sociedad Internacional de Fotogrametría y Teledetección (ISPRS) y la Sociedad Americana de Fotogrametría y Teledetección (ASPRS).

Hay y Castilla (2006) definen el Análisis de Imágenes Basado en Objetos como una sub-disciplina de la ciencia de los Sistemas de Información Geográfica dedicada a dividir las imágenes en objetos con significado propio y al mismo tiempo, obtener sus características desde un punto de vista espacial, espectral y temporal. En esta metodología se considera la forma, la textura y las propiedades espectrales de los objetos que forman la imagen, así como las relaciones existentes con los objetos vecinos situados en un

contexto espacial más o menos cercano, aumentando de forma considerable las características descriptivas de los objetos que facilitarán su correcta clasificación. Siendo los objetos los que se clasifican y no los píxeles individualmente.

Según Lizarazo y Elsner (2008), el análisis de imágenes basado en objetos está basado en los datos captados por sensores y produce resultados aptos para los SIG. Por tanto, puede considerarse como el puente entre el dominio ráster de las imágenes y el dominio predominantemente vectorial de los SIG.

Los clasificadores por objetos están diseñados para abordar la clasificación de paisajes heterogéneos y han mostrado su efectividad incrementando la precisión de las clasificaciones (Aplin *et al.*, 1999).

En esta disciplina se considera que la información necesaria para interpretar una imagen no está representada en los píxeles considerados individualmente, sino en objetos o polígonos de la imagen con un significado implícito y en sus relaciones mutuas.

El objetivo principal de esta sub-disciplina (Hay y Castilla, 2006) es desarrollar métodos, teorías y herramientas para emular la interpretación humana de imágenes aéreas o espaciales, de una forma automática o semiautomática que permita aumentar la producción de cartografía temática, reduciendo los costes y la subjetividad propia de la interpretación humana.

La clasificación basada en objetos tiene su punto inicial y fundamental en la creación de objetos; definidos como agrupaciones de píxeles contiguos con niveles digitales similares y que tienen tamaño, forma y relación geométrica con el componente del mundo real que modela. Lizarazo y Elsner (2008) introducen el término *grixel* para referirse a los objetos formados como agrupaciones de píxeles.

El primer paso es la segmentación de la imagen que debe hacerse teniendo en cuenta la resolución de la imagen y el tamaño de los objetos a identificar. El objetivo de la segmentación es simplificar la representación de una imagen a una forma con más significado y más sencilla de analizar (Shapiro y Stockman, 2001). El resultado de la segmentación de una imagen es un conjunto de regiones que cubren completamente la imagen. Todos los píxeles de una región son similares con respecto a alguna característica, al mismo tiempo que son diferentes de los píxeles situados en regiones adyacentes. Dentro del tratamiento digital de imágenes existen numerosos algoritmos de segmentación basados en crecimiento de regiones, análisis del histograma, detección de bordes, agrupamientos basados en distancias, etc. Al no existir una solución general al problema de la segmentación de imágenes, estas técnicas deben combinarse con el conocimiento del problema a resolver. Una imagen puede segmentarse en objetos de mayor o menor tamaño, influyendo considerablemente el tamaño de la segmentación que se utilice, en las

características 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, da lugar 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 estructura jerárquica entre los objetos es especialmente útil para caracterizar el paisaje que también tiene una estructura jerárquica.

Hay y Marceau (2004) establecen que los paisajes son sistemas complejos con estructura jerárquica y definida en varios niveles de organización donde las interacciones o relaciones existentes son más fuertes en un nivel que entre niveles. Por esto, la definición de la escala es un punto central en la definición de la jerarquía y la organización de los paisajes.

Según la escala de observación que utilicemos para analizar el paisaje podremos distinguir las regiones que lo forman con diferentes tamaños de detalle. Por ejemplo, a una escala pequeña se puede delimitar un bosque, aumentando la escala de observación se distinguen las agrupaciones de árboles que lo forman y con una escala mayor se podrá identificar las copas de los árboles de forma individual. La consideración de varias escalas de segmentación permite hacer un análisis multiescala del paisaje representado, consiguiéndose una aproximación más cercana a la realidad. Ya que no existe una escala ideal a la que todos los elementos del paisaje sean identificables, es necesario segmentar a varios niveles de escala en la mayoría de aplicaciones. Las relaciones que se crean entre los polígonos existentes en niveles de escala distintos facilitan la clasificación más precisa de los mismos al aumentar la información contextual disponible.

La característica más valiosa de la clasificación de imágenes orientada a objetos es la posibilidad de obtener un gran número de características descriptivas de los objetos y de las relaciones existentes entre los mismos que permitirán describirlos mejor y por lo tanto, diferenciarlos y obtener resultados más precisos y específicos. El conjunto de características utilizadas para describir los objetos se pueden clasificar en las categorías siguientes:

- Características espectrales: Mediante parámetros estadísticos como la media aritmética, la desviación típica, valores máximos o mínimos, etc. se describe la distribución de los niveles digitales de los píxeles, que forman el objeto, en las bandas espectrales o índices utilizados. La descripción espectral del propio objeto se puede completar con su comparación con los objetos vecinos, con los objetos de menor tamaño incluidos en el objeto de estudio o con objetos de mayor tamaño que lo engloben.

- Características de forma: La descripción de la morfología y dimensiones de un conjunto de píxeles se realiza tanto con propiedades como el área, el perímetro, el largo o el ancho como con índices de forma que describen la elongación, compacidad, asimetría, etc. Estas características por sí solas, facilitan la discriminación entre objetos con formas aproximadamente lineales, como vías de comunicación o cursos de agua, de objetos más compactos.
- Características relativas a la posición: La posición de un objeto en el espacio puede ser relevante en el caso de paisajes cuya distribución siga un determinado patrón geométrico, como es el caso de los árboles ordenados según un marco de plantación, o bien, en un paisaje fragmentado en regiones con usos y coberturas distintos entre estas regiones.
La distancia a un determinado objeto puede ser un claro indicador de la clase a la que corresponde el objeto. Por ejemplo, la distancia a la línea de costa puede ser una variable interesante para clasificar objetos correspondientes a playas, marjales, albuferas, etc.
Propiedades como las coordenadas del centro del objeto, sus coordenadas extremas o la distancia existente a un objeto determinado aportan información significativa para la descripción del objeto.
- Características de textura: Existen numerosos métodos para describir las propiedades texturales en una imagen. Si bien, las variables más utilizadas para describir la textura de un objeto son las extraídas de la matriz de coocurrencias de niveles de gris (Haralick *et al.*, 1973) que cuantifican numéricamente propiedades como la homogeneidad, el contraste, la rugosidad, etc.
- Características relativas a objetos vecinos: En el caso de trabajar con clasificadores iterativos, en los cuales en la asignación de la clase a un objeto se consideran las clases asignadas a sus vecinos, es necesario definir propiedades que reflejen las relaciones de vecindad entre los objetos. Ejemplos de este tipo de propiedades serían el porcentaje de frontera común con una clase determinada, distancia a un objeto de una clase, existencia de una clase en el vecindario de un objeto, etc. Con estas características se puede, por ejemplo, clasificar las sombras según su posición respecto a los elementos que las pueden producir como edificios o árboles.
- Características relativas a objetos en un nivel de segmentación distinto al del objeto de estudio: Al realizar varias segmentaciones, con distintas escalas, en una imagen se crea una jerarquía entre los objetos de distintas segmentaciones ya que unos están englobados en otros de mayor tamaño, al mismo tiempo que engloban a objetos de menor tamaño. La consideración de esta jerarquía puede

aportar información eficaz para describir el objeto y su contexto. Así por ejemplo, una zona de vegetación incluida en un objeto mayor clasificado como zona urbana deberá clasificarse como parque o jardín. De igual modo, la clase correspondiente a los polígonos contenidos en una parcela agrícola, resulta básica para asignar el cultivo a la parcela.

Ejemplos de estos descriptores pueden ser la proporción de área de una clase en un objeto, la existencia de una clase en él, la clase del objeto que lo engloba, etc.

Esta metodología facilita la interpretación del paisaje mediante la implantación de sistemas de producción basados en reglas que aplican el conocimiento experto disponible, o bien mediante sistemas de extracción de conocimiento propios de la inteligencia artificial (Lang *et al.*, 2006). No obstante, aunque los métodos basados en reglas son los más frecuentes, este enfoque de clasificación puede aplicarse por medio de cualquiera de los clasificadores existentes.

Los motivos que han motivado la aparición de esta nueva metodología son:

- El aumento en la disponibilidad de imágenes de alta resolución.
- El incremento constante en las necesidades de los usuarios de SIG.
- Las limitaciones que tiene el análisis de imágenes per píxel.
- El desarrollo de las herramientas de programación orientadas a objetos.
- La opinión generalizada de que este enfoque puede aprovechar mejor la información espacial contenida en las imágenes.
- La adecuación de esta metodología al enfoque multiescala del análisis del medio ambiente.

A fin de describir más exhaustivamente esta metodología, se describen a continuación los resultados principales del análisis de debilidades, amenazas, fortalezas y oportunidades realizado por Hay y Castilla (2006):

Fortalezas

- La división de una imagen en objetos es un proceso similar a la forma que las personas tenemos de organizar el paisaje para comprenderlo.
- La utilización de objetos como elementos mínimos en la clasificación permite reducir enormemente el coste computacional de la clasificación, al mismo tiempo que permite usar técnicas más complejas.
- Los objetos tienen propiedades (forma, textura, relaciones con otros objetos) de las que los píxeles carecen.

- Los objetos pueden integrarse más rápidamente en un SIG vectorial que los resultados de una clasificación por píxel.

Debilidades

- La segmentación de grandes imágenes implica un tiempo de procesado elevado.
- La segmentación de imágenes necesaria para crear los objetos es una fase problemática en el sentido de que en función de los parámetros y el algoritmo utilizado, los resultados, es decir, los objetos creados, serán distintos.
- Existe un conocimiento pobre de las relaciones jerárquicas existentes entre los objetos obtenidos a diferentes escalas de segmentación.

Oportunidades

- Aunque es necesario continuar investigando en este campo, ya existen unas bases conceptuales que lo sustentan.
- Hay un número elevado de investigadores trabajando en este campo, por lo que es de esperar que conforme la disciplina madure, surjan nuevas aplicaciones en campos concretos como el agrícola, forestal, urbanismo, etc.

Amenazas

- Las atractivas posibilidades de esta metodología han promovido que aumente el número de programas comerciales que disponen de herramientas de segmentación. Este aumento en la oferta de métodos de segmentación puede provocar una cierta confusión y dificultar el logro de un consenso en la comunidad de investigadores.

Como se ha comentado, la principal debilidad de este enfoque de clasificación es la fase de generación de objetos mediante segmentación. Ya que los resultados de los algoritmos de segmentación son a menudo impredecibles, y en algunos casos, no discriminan todos los límites que podría diferenciar un operador. Además, las regiones que crea un algoritmo de segmentación no están relacionadas directamente con entidades con significado, ya que estos algoritmos no consideran la información contextual, como es la forma de la parcela o el patrón de ocupación. La definición de un factor de escala que determine el tamaño de los objetos generados por la segmentación es complicado para poder extraer todos los objetos de interés. Por otra parte, la aplicación de segmentación

automática de imágenes sin tener el apoyo de un mapa topográfico con escala grande, tiene el inconveniente de que ciertos elementos lineales, como caminos, acequias, setos o cursos de agua, se incluirían como parte de objetos mayores como son las parcelas agrícolas, con lo que se produciría una sobreestimación de la superficie de las parcelas, que será tanto más significativa cuanto más reducidas sean las dimensiones de las parcelas.

Además de los algoritmos de segmentación de imágenes propios del análisis de imágenes digitales, se puede utilizar información cartográfica para crear los objetos de interés en la imagen. En muchos países se están construyendo bases de datos topográficas en formato digital que permiten facilitar el análisis de las imágenes aéreas o de satélite (Blaschke *et al.*, 2004). Estas bases de datos incorporan a la clasificación geometría y predicción semántica de los objetos de la imagen. De esta forma, se consigue generar objetos en la imagen con un mayor significado geográfico que el que tienen los píxeles que realizan una división del espacio determinada por las características del sensor utilizado en lugar de por las características del territorio representado. Según De Wit y Clevers (2004) la forma más prometedora de aplicar las técnicas de segmentación para el cartografiado de cultivos es mediante la combinación de las técnicas de segmentación con los límites de parcelas existentes en las bases de datos cartográficas.

En numerosos trabajos se combina la clasificación orientada a objetos con la clasificación por píxel. Una de las combinaciones más utilizadas consiste en clasificar inicialmente la imagen a nivel de píxel, y una vez segmentada la imagen en polígonos o regiones, utilizar como atributo de los polígonos creados el porcentaje de píxeles clasificados en cada clase. De esta forma, se consigue conservar la heterogeneidad propia de cada parcela y no se enmascara por la utilización de los valores medios de los píxeles de los objetos en cada banda (Fuller *et al.*, 2004).

3.2.5.- Clasificadores orientados a parcelas

Esta metodología puede considerarse un tipo de clasificación de imágenes por objetos, en la que la creación de una categoría de objetos está dirigida por los límites existentes en una cartografía preexistente. En lugar de trabajar con objetos generados en un proceso de segmentación basado en la imagen y en un determinado algoritmo, los objetos son creados según una interpretación de la realidad realizada por un cartógrafo que debe ser más ajustada a la realidad que la realizada de una forma automática. No se utilizaría, en una primera fase de generación de los objetos de estudio, ningún método de segmentación de imágenes. Sin embargo, sí se podría aplicar la segmentación de imágenes, a fin de determinar los objetos superiores en los que están incluidas las

parcelas, así como los objetos inferiores, en términos de tamaño, que están englobados en las parcelas.

La clasificación de imágenes por parcelas está siendo ampliamente evaluada para la actualización de bases de datos de sistemas de información geográfica relativos a usos del suelo. Por ejemplo, Walter (2004) actualiza los usos del suelo en una región a partir de los datos vectoriales contenidos en la base de datos ATKIS a escala 1:25.000. La información vectorial es utilizada para delimitar los objetos de estudio y de ellos extraen propiedades espectrales y texturales que combinadas con los porcentajes de píxeles asignados a las distintas clases en una clasificación previa a nivel de píxel son las características empleadas para clasificar los objetos en sus clases correspondientes mediante el clasificador de máxima probabilidad. Las discrepancias entre las clases obtenidas y las contenidas en la base de datos son un porcentaje reducido que debe ser comprobado por un operador, reduciéndose en gran medida la intervención del operador.

Volante *et al.* (2007) comparan dos clasificaciones con el algoritmo ISODATA a nivel de píxel y a nivel de parcela, obteniendo una fiabilidad global superior en un 3.4% en la clasificación por parcelas.

De Wit y Clevers (2004) ensayan sobre la actualización de la base de datos ráster holandesa de usos del suelo, conocida como LGN, mediante la integración de cartografía a escala 1/10.000 con imágenes multi-temporales Landsat TM, IRS-LISS3 y ERS2-SAR. De la cartografía se extrajeron los límites de las parcelas y para cada una de ellas se calculó el NDVI medio para cada una de las fechas disponibles. Con esta información se pre-clasificaron las parcelas en cuatro grupos de cultivos dependiendo de las épocas en que tuvieran un mayor vigor vegetativo. Para determinar de forma concreta los cultivos en cada uno de estos grupos, se clasificaron de forma independiente los píxeles contenidos en cada uno de los grupos y a cada parcela se le asignó la clase más frecuente de los píxeles que contenía. Los autores afirman que la fiabilidad obtenida es similar a la obtenida en trabajos anteriores pero con una reducción importante del tiempo de procesado.

La adecuación de esta metodología a los paisajes agrícolas se debe, entre otros factores, al hecho de que en los paisajes agrícolas la unidad espacial principal es la parcela agrícola. Además, las fronteras entre campos adyacentes son relativamente estables mientras que los cultivos cambian.

La clasificación por parcelas proporciona incrementos en la precisión sobre las clasificaciones por píxel en la realización de cartografía de usos del suelo (Pedley y Curran (1991), Janssen y Molenaar (1995), Aplin *et al.* (1999), Berberoglu *et al.* (2000)). Existen numerosos ejemplos de trabajos donde se comparan, sobre un mismo conjunto de datos, la adecuación para la identificación de cultivos de la clasificación por píxel frente a la clasificación por parcela. Berberoglu *et al.* (2000) obtiene una precisión general en la

clasificación de una imagen Landsat TM mediante redes neuronales del 80.2% cuando aplica el enfoque por parcela y asigna a cada parcela la clase más frecuente entre los píxeles de la misma, mientras que el resultado de la clasificación por píxel es del 75.6 %. Aplin *et al.* (1999) clasificaron una imagen CASI, de una zona agrícola, de 4 m de resolución espacial, y obtuvieron un incremento de 7.5% en la precisión de la clasificación por parcela, frente a la clasificación por píxel.

Esta metodología no sólo es utilizada en la clasificación de datos ópticos sino que también se mejora la clasificación de imágenes radar ya que la existencia de *speckle* a nivel de píxel se elimina a nivel de parcela. (Blaes *et al.*, 2005)

La radiancia dentro de una parcela agrícola es tan variable espacialmente que los píxeles individuales tienen un significado reducido. Por esto, el enfoque de clasificación por parcelas en el que la variabilidad interna a una parcela se reduce o elimina totalmente al promediar los ND de los píxeles, tiene un gran potencial para el tratamiento de escenas agrícolas. Además que esta metodología permite la asignación de variables adicionales a cada unidad espacial. Esta información adicional puede venir de dos fuentes principales: del procesado de la imagen, como podrían ser las variables de textura, o bien, de la información contenida en la base de datos del SIG que contiene la definición de las parcelas.

En este enfoque, se asume que los límites existentes en la cartografía corresponden a objetos homogéneos respecto a la leyenda utilizada, por lo que no se pretende modificar los límites existentes sino averiguar los cultivos o usos de las parcelas.

La clasificación de parcelas según Berberoglu y Curran, (2004):

- reduce el tiempo de entrenamiento
- disminuye el coste computacional
- incrementa la precisión
- reduce el número de datos a clasificar
- produce resultados en un formato más adecuado para su presentación
- genera resultados más sencillos de interpretar
- no tiene el ruido que tienen las clasificaciones por píxel aún estando suavizadas con algún tipo de filtro.
- permite la integración de información multi-temporal y multi-sensor. (Volante *et al.*, 2007)
- permite la utilización de un mismo mapa de parcelas con pequeñas actualizaciones durante largos períodos de tiempo para confeccionar mapas de cultivos de forma rutinaria. (Volante *et al.*, 2007)

Los primeros ensayos de clasificación por parcela se hicieron con imágenes Landsat MSS con una resolución espacial de 57 m por 79 m (Catlow *et al.*, 1984). Los

investigadores siguientes utilizaron estas técnicas con imágenes con mayor detalle espacial. Janssen *et al.* (1990), Janssen y Molenaar (1995) y Lobo *et al.* (1996) realizaron clasificaciones por parcela con imágenes Landsat TM con una resolución espacial de 30 m, y Pedley y Curran (1991), Johnsson (1994) y Mégier *et al.* (1984) utilizaron estas técnicas con imágenes SPOT de 20 m de resolución espacial.

El éxito de las clasificaciones por parcela depende de varios factores: las propiedades espectrales y espaciales de la imagen, el tamaño y forma de las parcelas y las clases definidas en la leyenda (Janssen y Molenaar, 1995). Es de resaltar el posible error que se introducirá en el proceso en el caso de que los límites especificados en la cartografía no coincidan exactamente con los límites existentes en la imagen. Es decir, los resultados de una clasificación por parcelas son dependientes de la precisión métrica y temática de los datos cartográficos y de la correcta georreferenciación de la imagen a utilizar.

El requisito fundamental para la utilización de esta metodología es la disponibilidad de una cartografía base con una calidad métrica y un grado de actualización lo más alto posible. La integración de los datos cartográficos vectoriales con las imágenes ráster, se suele hacer rasterizando la cartografía vectorial con el mismo tamaño de píxel que las imágenes a utilizar.

La definición de regiones en la imagen según los límites de las parcelas existentes en la cartografía permite añadir toda la información contenida en las bases de datos a la información contenida en la imagen, así como a la que se extraiga de la misma. De esta forma, aumenta en gran medida el volumen de información disponible facilitando el proceso clasificatorio y su evaluación. La información contenida en la base de datos complementa la información extraída de la imagen permitiendo una interpretación más exhaustiva y con mayor rigor ya que aporta el conocimiento sobre la situación anterior de la parcela y se puede juzgar, en base a esto y el conocimiento del territorio analizado, si el nuevo uso detectado es lógico o probable o no lo es.

Algunos autores como Heipke *et al.* (1999), Fissette *et al.* (2006) o Walter (2004) utilizan la información respecto al uso de la parcela en la base de datos para elegir de forma automática, mediante un proceso de selección, las muestras de entrenamiento para la clasificación.

Walter (2000) para determinar las características espectrales y texturales típicas de cada clase, selecciona los píxeles correspondientes a cada una de las clases en la base de datos. Evitando utilizar los píxeles que se encuentran en zonas frontera entre clases. De esta forma, siempre que todas las clases estén representadas por un número mínimo de píxeles y los cambios ocurridos respecto a la base de datos sean pocos, se puede

determinar de forma automática las firmas de cada una de las clases, eliminando un paso laborioso en todo proceso de clasificación.

Los métodos de clasificación de imágenes basados en parcelas pueden agruparse en dos categorías (Turker *et al.*, 2006):

- a) Clasificación de los píxeles de la parcela (*post-field classification*): Se clasifican los píxeles de una parcela y a ella se le asigna una clase basado en un estadístico, como por ejemplo, la clase más frecuente para todos los píxeles de la parcela (Janssen *et al.*, 1990; Aplin *et al.*, 1999). En algunos casos, en lugar de utilizar la clase más frecuente para asignar la clase a la parcela, se puede utilizar las proporciones de cada clase en la parcela. Por ejemplo, Aplin *et al.* (1999) asignaban en la clase bosque mixto, aquellas parcelas en las que los píxeles de las clases bosque de coníferas y prados ocupaban una superficie mayor a una determinada proporción.

Cuando la proporción de superficie ocupada por la clase más frecuente es inferior a un umbral mínimo se puede señalar las parcelas susceptibles de estar clasificadas erróneamente (Aplin *et al.*, 1999) y que sería conveniente su revisión por un intérprete, o bien, ser procesada de un modo particular.

- b) Clasificación de las parcelas (*pre-field classification*): Consiste en obtener las características descriptivas de cada parcela a partir del cálculo de estadísticos (media, varianza, moda...) de las características de los píxeles incluidos en esa parcela. La imagen se clasifica con el clasificador elegido, teniendo en cuenta que los elementos a clasificar son parcelas en lugar de píxeles.

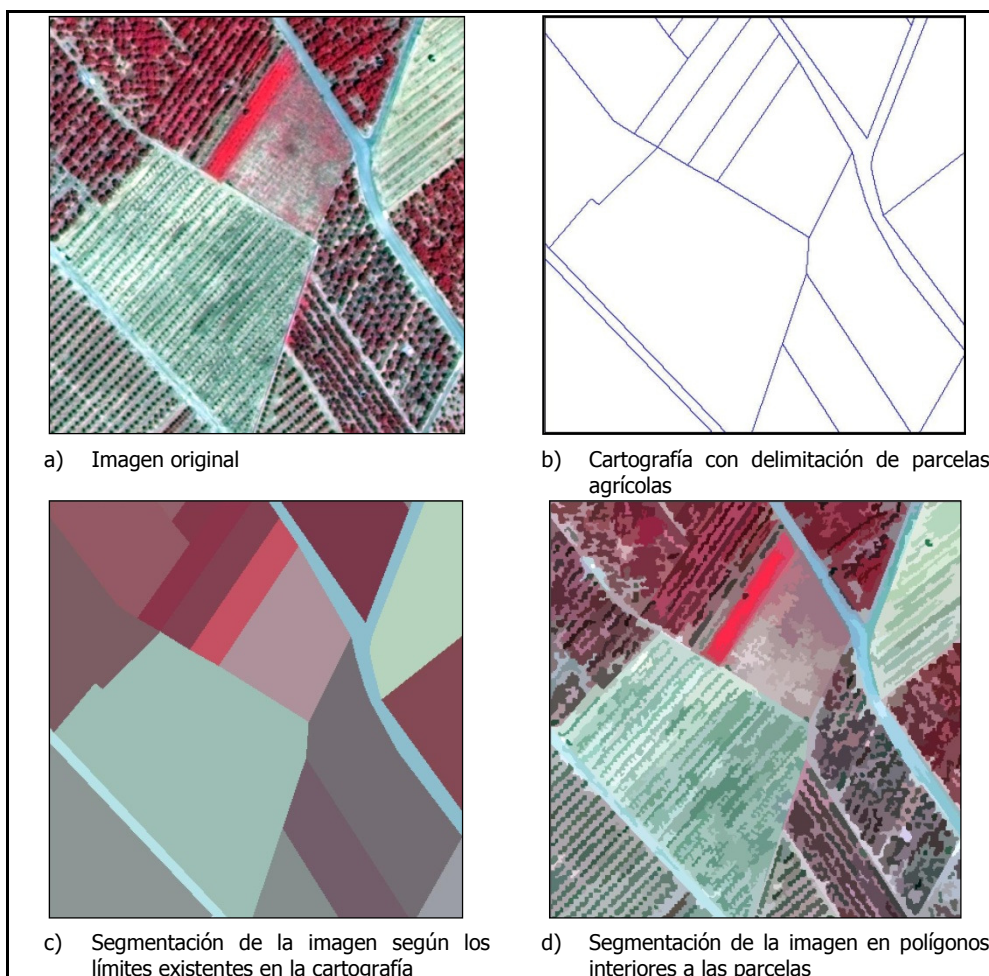


Figura 3-2. Segmentación de imágenes por parcelas

La definición de las parcelas según los límites presentes en la cartografía y su posterior análisis como objetos tiene una serie de ventajas sobre el enfoque de asignar a cada parcela la clase más frecuente entre los píxeles:

1. Se divide la totalidad de la imagen en conjuntos de píxeles de dimensiones reducidas; produciéndose una sustitución de un dominio de estudio heterogéneo por un conjunto de subdominios homogéneos, o al menos, de dimensiones reducidas y por lo tanto más sencillos de interpretar desde un punto de vista de procesado automático de la imagen. Esta división de la imagen permite establecer umbrales particulares para cada parcela según sus características, en lugar de utilizar uno común para toda la imagen cuya determinación será mucho más complicada y con resultados de menor calidad.

2. Permite incorporar la proporción de píxeles clasificados en una clasificación por píxel, como atributos correspondientes a las parcelas a clasificar (Walter, 2004). De esta forma, se consigue conservar la heterogeneidad propia de cada parcela y no se enmascara por la utilización de los valores medios de los píxeles de los objetos en cada banda (Fuller *et al.*, 2004).
3. Al limitar el procesado a los píxeles de cada parcela, se anulan los errores en las zonas limítrofes entre parcelas derivados del cálculo de variables en las que interviene el vecindario de un píxel, como por ejemplo, las variables de textura extraídas de la matriz de coocurrencias de niveles de gris o las extraídas del semivariograma.

Berberoglu *et al.* (2000) comparan ambos métodos sobre los mismos datos de partida y obtienen un incremento en la fiabilidad global del 9% en el segundo método frente al primero. En ambos enfoques se asume que las parcelas son homogéneas en su cultivo y no existen variaciones internas. Estos métodos eliminan los efectos de la variabilidad espectral dentro de los campos así como de los píxeles de mezcla situados en las fronteras de las parcelas. Un análisis más profundo implicaría la segmentación de la imagen en polígonos interiores a las parcelas que no traspasen los límites existentes en la cartografía (Figura 3-2.d), con el fin de detectar tanto las variaciones en la cobertura de la parcela como los subobjetos que la forman y de cuyo análisis se puede extraer información para la correcta descripción de la misma. Turker *et al.* (2006) proponen un método para segmentar los recintos homogéneos existentes dentro de una parcela. Los datos que usan son SPOT4 y 5 y cartografía vectorial para segmentar las parcelas. El mero hecho de limitar el fragmento de imagen a procesar simplifica en gran medida su interpretación.

Las características descriptoras de las parcelas son las mismas que se han comentado en la clasificación por objetos, ya que la diferencia principal entre ambos métodos radica en la definición de los objetos de estudio.

En la cartografía catastral española, las parcelas corresponden a divisiones jurídicas del espacio, es decir, representan las propiedades de uno o varios propietarios. Mientras que las subparcelas son los recintos integrantes de una parcela con un uso determinado. Por lo tanto, la parcela dedicada íntegramente a un cultivo estará formada por una única subparcela, mientras que aquella en la que se den varios usos estará dividida en tantas subparcelas como usos existan. El mayor grado de detalle, su total disponibilidad sobre el territorio español, así como la mayor adecuación de la subparcela a la realidad física representada hace más conveniente la utilización de la subparcela catastral como unidad mínima de estudio y, por lo tanto, como límites para la segmentación de la imagen.

3.3.- Métodos de clasificación no paramétricos

3.3.1.- Introducción

Los métodos de clasificación pueden ser paramétricos o no paramétricos. Los clasificadores paramétricos asumen que el conjunto de datos de una clase están distribuidos según una distribución normal y que los parámetros estadísticos, como la media y la varianza, obtenidos de las muestras de entrenamiento son representativos. Sin embargo, esta asunción no siempre es correcta, especialmente en áreas complejas, ya que, generalmente existe confusión espectral entre clases distintas, es decir, objetos dentro de una misma clase con propiedades espectrales distintas y clases diferentes con propiedades espectrales similares. Otro de los inconvenientes de los clasificadores paramétricos reside en la dificultad de combinar datos espectrales con otros datos auxiliares que permitan completar la información proveniente de la imagen, por no cumplir los requisitos estadísticos impuestos por estos métodos. El clasificador paramétrico más utilizado es el de Máxima Probabilidad por su robustez y su disponibilidad en todos los software de procesado de imágenes.

En cambio, los métodos no paramétricos no realizan ninguna asunción sobre la naturaleza de los datos ya que no emplean parámetros estadísticos para calcular la separabilidad entre clases. Además de ser especialmente adecuados para la incorporación de datos externos a las imágenes en el proceso de la clasificación. Los datos auxiliares como modelos digitales de elevación, mapas de suelo, temperaturas, precipitaciones, densidad de población etc. son cada vez más abundantes lo que facilita su incorporación en la clasificación de imágenes de diferentes formas. Una posibilidad sería desarrollar clasificaciones según la distribución espacial de las coberturas del suelo y los datos auxiliares disponibles. Por ejemplo, la pendiente, la orientación de las laderas y la altitud son parámetros directamente relacionados con la distribución de la vegetación en regiones montañosas. Del mismo modo, las temperaturas, las precipitaciones y la tipología de suelo son condicionantes de la distribución espacial de los cultivos. Se ha demostrado que la utilización de estas relaciones en la clasificación aumenta la fiabilidad de la misma. Por otra parte, el entrenamiento de los clasificadores clásicos a nivel de píxel basados en las características espectrales resulta complejo en las imágenes con gran detalle por la variación existente en la respuesta espectral de los píxeles que forman un objeto. Por esto, es necesario incorporar a las características espectrales otro tipo de información como relaciones espaciales, información de contexto, características extraídas de MDE, etc.

Por estos motivos, en los últimos años numerosos investigadores han evaluado los métodos no paramétricos para la realización de cartografía de usos del suelo mediante

clasificación de imágenes. Entre los clasificadores no paramétricos más utilizados están las redes neuronales artificiales (Veronez *et al.* (2007), Pozzobon Martins *et al.* (2002)) y los sistemas expertos basados en árboles de decisión (Huang y Jensen (1997), Li *et al.* (2000), Friedl *et al.* (2002)).

3.3.2.- Redes neuronales artificiales

Las redes neuronales artificiales son un método de aprendizaje cuya finalidad inicial era la de emular los procesadores biológicos de la información (Corchado y Fyfe, 2004).

En una red neuronal, cada una de las variables descriptoras de un objeto (capa de entrada) se multiplica por unos pesos (capa oculta) que van variando durante la fase de aprendizaje hasta llegar a la solución buscada (capa de salida). Una vez obtenidos los pesos correspondientes a las distintas variables, la red neuronal se puede aplicar a casos distintos de los utilizados en el aprendizaje para obtener la salida deseada.

Las ventajas principales de las redes neuronales frente a otros métodos de clasificación son que no requieren una distribución normal de los datos y su habilidad para adaptarse a patrones complejos y no lineales (Jensen, 2005).

La estructura de una red neuronal aplicada a la clasificación de imágenes está formada normalmente por tres capas (Fig. 3-3):

- una capa de entrada que puede estar formada por datos de reflectancia en unas determinadas bandas espectrales, datos de textura, características extraídas de un modelo de elevaciones, etc.
- una o varias capas ocultas que permiten la simulación de patrones no lineales en los datos de entrada
- una capa de salida que contiene las clases contenidas en la leyenda de la clasificación.

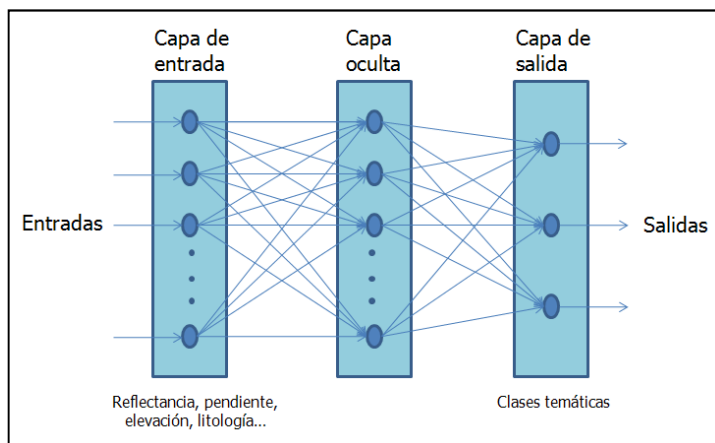


Figura 3-3. Ejemplo de red neuronal artificial

En una red neuronal ya entrenada, el conjunto de los pesos determina el conocimiento de esa red y permiten resolver el problema para el que ha sido entrenada. Aunque esta metodología ha sido frecuentemente analizada en la clasificación por píxeles, su uso no es muy frecuente en la clasificación por objetos o por parcelas, ya que presenta algunos inconvenientes frente a los métodos basados en conocimiento. En primer lugar, el conocimiento en la red está expresado en forma de pesos, lo que impide la inteligibilidad de las asignaciones de clase realizadas. Estos pesos son ocultos y no pueden ser modificados por el operador (Tullis y Jensen, 2003). Es decir, de las variables descriptoras no se extrae nuevo conocimiento para el usuario, sino que esa extracción de conocimiento es interna de la red y no revierte en el usuario salvo en la asignación de clases realizada. En segundo lugar, el conocimiento que pueda tener un experto sobre un fenómeno resulta complicado de introducir en la red.

3.3.3.- Sistemas de clasificación basados en conocimiento

3.3.3.1.- Introducción

En los últimos años se ha popularizado el uso de los sistemas basados en conocimiento para la clasificación de imágenes ya que permiten incorporar el conocimiento disponible y el razonamiento lógico. Estas técnicas incorporan los datos auxiliares directamente en los algoritmos de clasificación y son independientes de los pesos a utilizar. (Skidmore, 1989; Huang y Jensen, 1997; Li *et al.*, 2000; Hodgson *et al.*, 2003; Tullis y Jensen, 2003).

Se conoce por sistema basado en conocimiento al sistema que usa conocimiento humano para resolver problemas que normalmente requieren inteligencia humana, es decir, un sistema que puede resolver cuestiones eficazmente, de forma similar a como lo haría una persona experta en el tema considerado. Los sistemas expertos se caracterizan por dos componentes (Skidmore, 1989):

- Una base de conocimiento que contiene los datos y las reglas que relacionan los datos y las hipótesis que resuelve. En el caso de la clasificación de imágenes las hipótesis son las clases a asignar a los objetos
- Un algoritmo que deduce las relaciones entre los datos y las hipótesis o clases a resolver.

Estos sistemas representan el conocimiento del experto sobre un ámbito o tema expresado en forma de datos y reglas (Jensen, 2005). Por lo tanto, pueden aplicarse para resolver distintos problemas dentro de un mismo ámbito o tema, sin tener que modificar el conocimiento disponible de forma particular para cada problema al que se aplique.

La implementación de los sistemas basados en conocimiento en la clasificación de imágenes requiere la combinación de técnicas de procesamiento de imágenes y herramientas de análisis SIG con algoritmos automáticos de adquisición de conocimiento (Tullis, 2003). Los SIG pueden tener un papel importante en la clasificación de imágenes basada en conocimiento, ya que contienen información auxiliar útil para la clasificación y son adecuados para la gestión de información espacial en distintos formatos.

Independientemente de las diversas tipologías de datos que son capaces de tratar, existen múltiples variaciones en la forma de aplicar estos sistemas. Las dos maneras más habituales de aplicar los sistemas expertos en la clasificación de usos del suelo son: clasificación de una imagen incorporando en el proceso datos auxiliares o reclasificación de una clasificación existente considerando la información auxiliar.

Huang y Jensen(1997) comparan sobre un mismo conjunto de datos, formado por imágenes y datos temáticos, los resultados de tres clasificaciones realizadas mediante un sistema experto basado en conocimiento, ISODATA y Máxima Probabilidad. Los mejores resultados corresponden al sistema experto con incrementos de fiabilidad global del 13% y del 9% respecto a los otros métodos.

Cohen y Shoshany (2000) utilizan el conocimiento experto para mejorar una clasificación no supervisada de cultivos en Israel. Para ello, añaden información auxiliar como son los mapas de tipos de suelo y de pluviometría. Del análisis de las características de una serie de muestras, deducen reglas basadas en la información auxiliar con las que reclasifican las imágenes aumentando las precisiones obtenidas.

Li *et al.* (2000) perfeccionan una clasificación de Máxima Probabilidad mediante la utilización de reglas. En la creación de reglas utilizan como atributos la elevación, la posición y los valores de probabilidad obtenidos en la clasificación de Máxima Probabilidad; combinando así los dos métodos de clasificación. De esta forma, consiguen aumentar la fiabilidad de las clases más similares espectralmente.

La construcción de un sistema experto basado en conocimiento está siempre condicionada a la adquisición del conocimiento necesario. Esto es, a la definición de una serie de reglas que permitan clasificar el conjunto de objetos en sus correspondientes clases informacionales. Un experto puede disponer de conocimiento útil para el sistema que deberá ser expresado en forma de reglas o condiciones aplicables por el sistema. No obstante, este conocimiento del experto será limitado y deberá ampliarse para conseguir el objetivo propuesto. Por ejemplo, en un estudio agrícola, puede conocerse que un determinado cultivo esté limitado a un determinado rango altitudinal o de temperaturas, pero será complicado conocer las diferencias espectrales *a priori* entre los cultivos en una imagen.

La representación del conocimiento se hace habitualmente por medio de **reglas**, que pueden constar de una o varias condiciones unidas por medio de operadores lógicos: SI se cumple una condición ENTONCES ocurre una acción. Un ejemplo de la aplicación de reglas en teledetección sería:

SI (B1 > Umbral 1)
 Y SI (B2 < Umbral 2)
 O
 SI (B3 > Umbral 3)
 ENTONCES píxel = Clase X
 Siendo Bi el nivel digital del píxel en la banda i

Estos métodos de clasificación tienen la ventaja de que una vez creada una base de conocimiento, ésta puede ser aplicada a nuevos datos o lugares sin re-entrenamiento. Por tanto, los resultados obtenidos serán fiables y repetibles. Además, el resultado de una clasificación es justificable, ya que de forma sencilla se puede averiguar las reglas que un objeto ha cumplido para ser asignado a una clase. Este punto es de gran importancia ya que permite comprobar y ajustar una base de conocimiento en desarrollo.

La falta de conocimiento sobre las características de los objetos a clasificar conduce al problema fundamental de implantación de los sistemas expertos: la adquisición del conocimiento, citado en la bibliografía como "*knowledge acquisition bottleneck*". Por esto, el principal inconveniente de esta metodología es el establecimiento de las relaciones

mediante reglas. Según Hodgson *et al.* (2003) la creación de reglas se aborda de tres formas distintas:

- 1º.- obtener las reglas y el conocimiento sobre el medio a clasificar de expertos en los ámbitos implicados: forestal, agrícola, urbano, etc.
- 2º.- extraer reglas y variables usando métodos cognoscitivos que analicen la forma que emplean las personas de procesar la imagen para su interpretación.
- 3º.- generar reglas empíricamente a partir de los datos observados y métodos inductivos automáticos.

De estas tres alternativas, es la última, basada en métodos inductivos automáticos, la que más se está utilizando. Ya que estos métodos permiten extraer conocimiento de forma rápida, cómoda y eficaz a partir de un conjunto elevado de variables, con resultados razonables. Sin embargo, no se pueden descartar las dos primeras alternativas si se pretende que el sistema proporcione la misma respuesta que daría un operador.

Gran parte del conocimiento útil y necesario está disponible en las bases de datos de los SIG. En ocasiones, la extracción de esta información consistirá en la realización de consultas a la base de datos. Por ejemplo, obtener las parcelas con posibilidad de riego o con un tamaño determinado. En otros casos, el conocimiento a extraer también está contenido en las bases de datos, aunque no de una manera explícita y su extracción es más compleja, teniendo que recurrir a técnicas de extracción de conocimiento en bases de datos.

La extracción de conocimiento en bases de datos se define como el proceso no trivial de identificar patrones válidos, novedosos, potencialmente útiles y comprensibles a partir de los datos. Las fases que componen un proceso de extracción de conocimiento en bases de datos serían: (Hernández Orallo *et al.*, 2004)

1. Integración y recopilación de los datos iniciales.
2. Selección, limpieza y transformación de los datos.
3. Minería de datos
4. Evaluación e interpretación de resultados
5. Difusión y uso del conocimiento extraído

En ocasiones se utiliza erróneamente el término minería de datos (*data mining*) para referirse a todo el proceso completo. La minería de datos consiste en analizar los datos para extraer el conocimiento implícito en esos datos y expresarlo en forma de relaciones, patrones, reglas, etc. Es un campo multidisciplinar que utiliza herramientas desarrolladas en otras tecnologías con las que está íntimamente relacionada, como por

ejemplo, la estadística, el aprendizaje automático, los sistemas gestores de bases de datos, etc. El aprendizaje automático es una rama de la inteligencia artificial que se ocupa de desarrollar programas y algoritmos capaces de aprender un modelo a partir de ejemplos y lo aplica para resolver un problema (Hernández Orallo *et al.*, 2004). Permite adquirir conocimiento al sistema, utilizando técnicas inductivas o deductivas sobre un conjunto de datos de entrenamiento. Consiste en analizar una serie de ejemplos del concepto que se pretende aprender y a partir de ese análisis se construye, o induce, una definición que sirva para describir el concepto en cuestión. Esta definición pasa a formar parte de la base de conocimiento del sistema y se utiliza para clasificar nuevas instancias. Los ejemplos se representan mediante vectores de valores de los atributos. Los valores de los atributos o características pueden ser tanto valores numéricos como categóricos. Para los ejemplos se debe aportar también la clase a la que pertenecen. Del resto de elementos a clasificar con el modelo aprendido también es necesario disponer de los valores de los atributos. El resultado de este aprendizaje es un modelo que asigna la clase correspondiente a cada elemento por medio del análisis de los valores de los atributos (Quinlan, 1996c).

La aplicación de esta disciplina en la clasificación de imágenes es muy prometedora, ya que permite generar sistemas de clasificación basados en reglas en aquellos casos donde el conocimiento disponible sobre las clases sea insuficiente. Estos métodos usan datos de entrenamiento y algoritmos de aprendizaje automático para desarrollar una serie de reglas que definan cada clase, al mismo tiempo que no tienen limitaciones sobre la tipología de información auxiliar incorporada en el proceso de clasificación de imágenes. Por otra parte, la inclusión de información proveniente de los SIG permite descubrir relaciones no evidentes entre las clases y los atributos contenidos en los SIG que faciliten la clasificación de las imágenes.

Entre las ventajas que tiene la utilización de los métodos de aprendizaje inductivo para construir una base de conocimiento cabe destacar que sólo se necesita un conjunto de buenos ejemplos que funcionen como datos de entrenamiento. Esto es, en la mayoría de los casos, más sencillo de conseguir que la extracción de teorías generales que se cumplan para todos los datos a partir de la información que posea un experto.

Otras ventajas que afianzan la adecuación de estos métodos frente a otras alternativas de clasificación son:

- La utilización de datos auxiliares, para mejorar la discriminación entre clases, reduce el número de muestras de entrenamiento necesarias.
- No requieren que los datos estén distribuidos normalmente, ni que los atributos sean independientes.

- Pueden reconocer patrones no lineales en los datos de entrada que son demasiado complejos para los métodos estadísticos o demasiado sutiles para un intérprete.
- Una vez se han obtenido unas reglas de clasificación para un área; éstas pueden volver a aplicarse en la misma zona sin necesidad de entrenar al clasificador de nuevo.
- Las reglas extraídas de una zona pueden aplicarse con ligeras modificaciones a zonas de similares características. Representando un ahorro de tiempo sustancial en la fase de selección de datos de entrenamiento.
- Las reglas obtenidas son fácilmente interpretables aportando nuevo conocimiento útil para el intérprete.

Según Jensen (2005), la mejor forma de conceptualizar un sistema basado en conocimiento es mediante un árbol de decisión, donde los datos son evaluados mediante reglas para determinar las hipótesis. Los pasos a seguir para construir de forma automática una base de conocimiento para un sistema experto dedicado a la clasificación de imágenes de satélite, por medio de aprendizaje artificial inductivo serían:

- obtención de datos de entrenamiento
- creación del árbol de decisión (uno o varios)
- extracción de reglas
- clasificación por medio de reglas.
- evaluación del rendimiento del clasificador

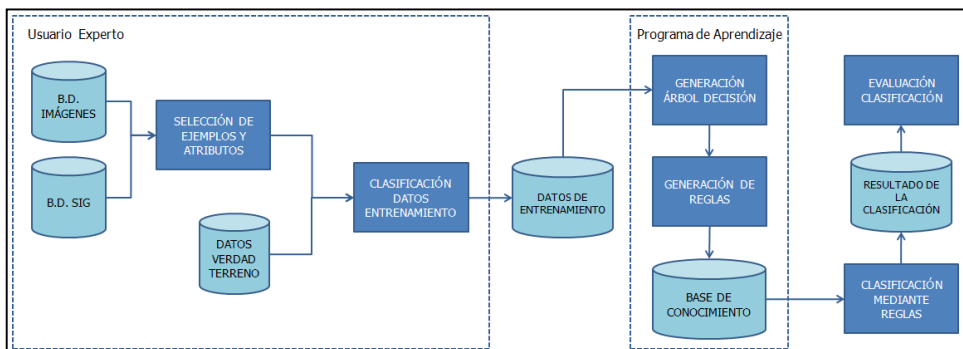


Figura 3-4. Flujo de trabajo en la aplicación del conocimiento inductivo en la clasificación de imágenes

3.3.3.2.- Obtención de datos de entrenamiento

El objetivo de esta fase es proveer al algoritmo de aprendizaje inductivo de muestras o ejemplos sobre los conceptos que debe aprender. La calidad y la cantidad de los datos de entrenamiento o aprendizaje que se faciliten al algoritmo va a condicionar, en gran medida, la calidad del modelo aprendido por el algoritmo. Es en este proceso donde interviene el usuario experto que selecciona el conjunto de muestras, el conjunto de atributos descriptores de los ejemplos y asigna a cada una de ellas la clase correspondiente según la información contenida en bases de datos, imágenes y/o visitas de campo.

El conjunto de datos seleccionado como muestras de aprendizaje ha de ser representativo de todas las clases presentes en el área de estudio. Un muestreo aleatorio no es el más adecuado para este propósito ya que las clases menos frecuentes pueden quedar poco representadas o incluso no representadas. Un muestreo aleatorio estratificado es más apropiado al garantizar que se seleccionan un número mínimo de muestras de cada una de las clases existentes.

Cada uno de los ejemplos estará descrito por un vector de atributos que expresa los valores de varias características del objeto. Una de las características que se debe especificar siempre para un dato de entrenamiento es la clase a la que pertenece:

(atributo-1, atributo-2,...atributo-n, clase X)

Las características que se pueden utilizar para describir los objetos pueden ser valores de reflectancia en distintas bandas, datos auxiliares derivados de modelos digitales de elevación, información de texturas, características de forma, etc.

3.3.3.3.- Árboles de decisión

Los árboles de decisión son una serie de condiciones organizadas en forma jerárquica a modo de árbol (Hernández Orallo *et al.*, 2004). Son muy útiles para encontrar estructuras en espacios de alta dimensionalidad y en problemas que mezclen datos categóricos y numéricos. La estructura de los árboles de decisión, donde las reglas son evaluadas para comprobar hipótesis, es la más adecuada para expresar un sistema experto (Jensen, 2005).

Un árbol de clasificación es una forma de representar el conocimiento obtenido a lo largo del proceso de aprendizaje inductivo. Puede interpretarse como la estructura resultante de la división del espacio de representación a partir de un conjunto elevado de ejemplos o prototipos.




Figura 3-5. Clasificación cuadrangular realizada por un árbol de decisión con dos atributos numéricos (Hernández Orallo *et al.*, 2004).

El objetivo es aprender cómo clasificar objetos, por medio del análisis de unos ejemplos cuyas clases son conocidas. Las clases son etiquetas exclusivas y los ejemplos se representan como vectores de atributos que almacenan los valores numéricos o nominales de una serie de propiedades. Los datos de entrada son un conjunto de vectores, cada uno de ellos perteneciente a una clase conocida mientras que la salida es una función que debe asignar de forma precisa una clase a cada uno de los objetos.

La clasificación de objetos se realiza en base a una serie de preguntas sobre los valores de sus atributos, empezando por el nodo raíz y siguiendo por el camino determinado por las respuestas de los nodos internos hasta llegar a un nodo hoja. La clase asignada a esta hoja es la que se asigna a los objetos que han cumplido las condiciones que llevan hasta ella. Las particiones que se imponen a los datos están basadas en condiciones exhaustivas, que se puedan aplicar a todos los datos y deben ser también excluyentes es decir, una regla se cumple o no se cumple.

El objetivo de estos métodos de clasificación no sólo es desarrollar clasificadores precisos, sino además conseguir que el modelo sea inteligible para las personas. Estos programas usan reglas del tipo SI (condición) ENTONCES (asignación a clase). La condición puede ser simple o compuesta donde se evalúe el valor de determinados atributos. Siempre se define una clase como clase por defecto, que es la que se asignará a aquellos objetos que no cumplan ninguna condición. Para clasificar un ejemplo con un modelo de reglas de producción, se comprueba de forma ordenada cada una de las reglas y cuando cumple la primera de ellas, se asigna a la clase predicha por esa regla y no se sigue comprobando el resto de reglas.

Según Hernández Orallo *et al.* (2004) los árboles de decisión en función del tipo de la variable que predicen, pueden clasificarse en árboles de clasificación y árboles de regresión. Los árboles de clasificación se utilizan para predecir variables categóricas mientras que los árboles de regresión se usan para predecir variables continuas.

En un árbol de decisión el problema a resolver sería el tronco del árbol, cada condición sería una rama que estaría situada entre dos nodos. Los nodos pueden ser atributos que se evalúan o nodos hojas que corresponden a la predicción del problema (ver figura 3-6). Un árbol también puede expresarse como el conjunto de reglas que lo forman.

Los árboles más pequeños son los más adecuados ya que son más sencillos de entender además de tener una mayor precisión en sus predicciones. (Quinlan, 1996c).

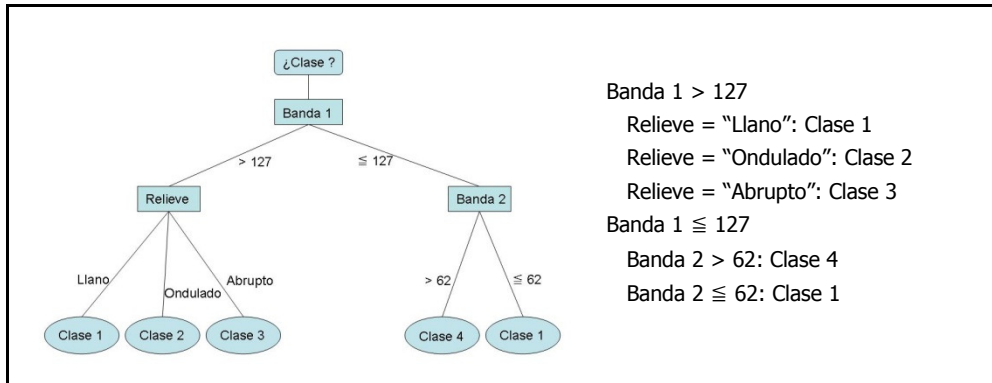


Figura 3-6. Árbol de decisión

Una de las ventajas de los árboles de decisión es que realizan de forma implícita un proceso de selección de las variables más significativas. Por lo tanto, una vez construido el árbol, aquellos atributos que no intervienen en ninguna condición pueden descartarse, reduciéndose el tamaño del espacio de características descriptivas de los objetos.

Las ventajas principales de los árboles de decisión son las siguientes: (Hernández Orallo *et al.*, 2004)

- Son aplicables a distintas tareas: clasificación, regresión, agrupamiento, etc.
- Tratan con atributos continuos y discretos.
- Son flexibles. No hacen ninguna suposición sobre la distribución de los datos, al contrario de lo que hacen algunos métodos estadísticos. Esta característica permite incorporar datos discretos a la clasificación de imágenes, independientemente de la distribución y la correlación que exista entre ellos.
- Son fáciles de usar.
- Son tolerantes al ruido, a atributos no significativos y a valores faltantes.
- Las condiciones extraídas son inteligibles por el usuario
- Existe software para su aplicación y en algunos casos es gratuito.
- Permiten tratar relaciones no lineales entre características y clases.

- Las muestras de aprendizaje de una misma clase no tienen que ser homogéneas entre sí como ocurre en un método estadístico. Con los árboles de decisión se pueden extraer reglas distintas para tipologías distintas dentro de una misma clase.

Algunos de los software comerciales de tratamiento de imágenes más utilizados en teledetección como son ERDAS IMAGINE, ENVI o IDRISI disponen de herramientas para crear clasificadores basados en árboles de decisión.

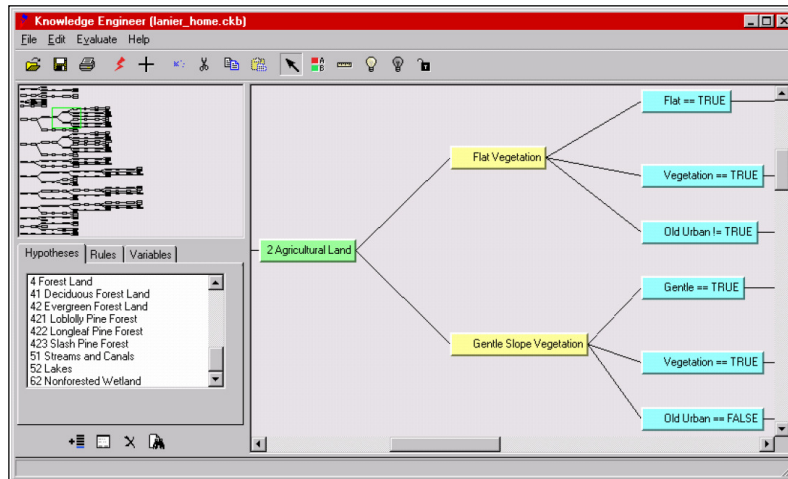


Figura 3-7. Estructura de un árbol de clasificación en Erdas Imagine Expert System

Tanto en ERDAS IMAGINE (Fig. 3-7), como en ENVI 4.2 (Fig. 3-8), la creación de los árboles se hace por medio de un interfaz gráfico donde se establecen las variables, reglas y clases que intervienen en el árbol. Ambos programas permiten utilizar como variables en las condiciones los valores de los píxeles en distintas bandas, así como índices entre imágenes u operaciones calculadas sobre modelos digitales del terreno. Estas variables pueden combinarse por medio de operadores lógicos o matemáticos para formar una regla.

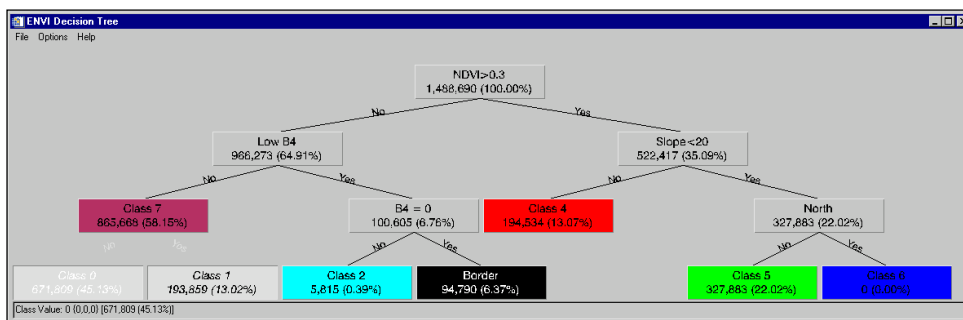


Figura 3-8. Estructura de un árbol de clasificación en ENVI

Una vez establecida la base de conocimiento expresada en forma de árbol, ambos programas clasifican la imagen de entrada obteniendo la imagen temática buscada.

El clasificador experto de Erdas Imagine permite que el usuario experto defina la confianza de cada regla. De modo que si un píxel cumple varias reglas, será asignado a la hipótesis cuyas reglas tengan una confianza mayor.

Estos programas no disponen de ninguna herramienta para extraer de forma automática las reglas que clasifiquen una imagen a partir del análisis de un conjunto de muestras de entrenamiento, sino que es el usuario el que ha de aportar ese conocimiento para la definición del árbol. Siendo el aporte de este conocimiento la fase más problemática de este enfoque.

IDRISI, en cambio, a partir de su versión Andes, incluye el algoritmo C4.5 que posibilita la creación de árboles de decisión a partir de unas muestras de entrenamiento proporcionadas por el usuario, con lo que la creación de la base de conocimiento resulta inmediata.

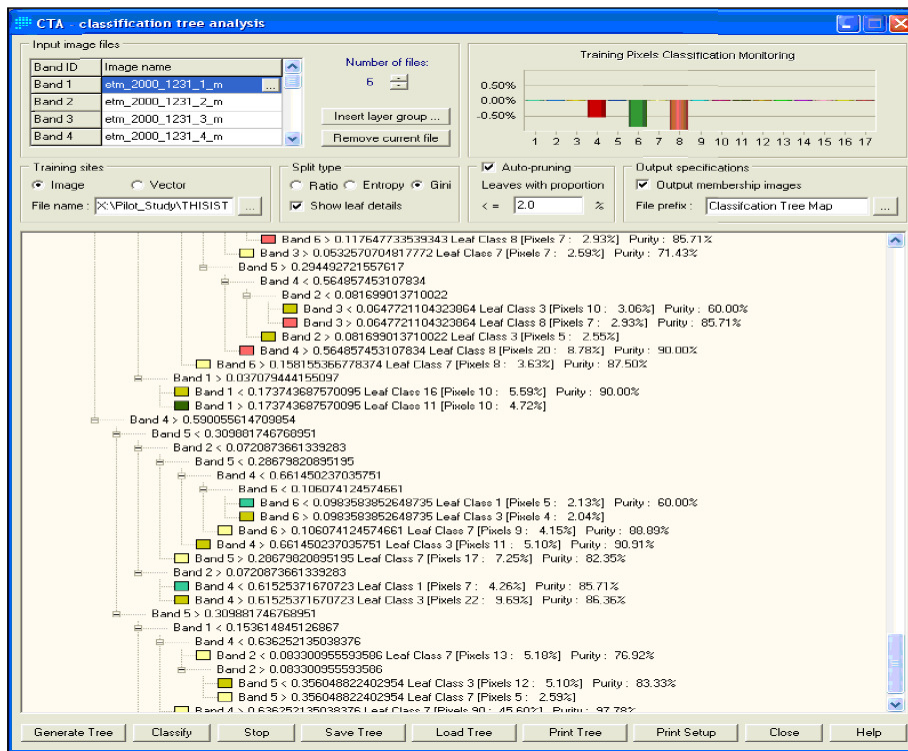


Figura 3-9. Módulo de creación y aplicación de árboles de decisión en IDRISI

Entre las desventajas de los árboles de decisión cabría citar que no son tan precisos como otros métodos como son las redes neuronales. Además son “débiles”, es decir, son bastante dependientes de las muestras de ejemplos que se les suministra para el aprendizaje. Dos muestras distintas sobre la misma distribución pueden dar lugar a árboles bastante diferentes.

La construcción del árbol de decisión constituye la fase de aprendizaje a partir de un conjunto de prototipos o muestras de aprendizaje. Constituye la fase más compleja y la que determina el resultado final. Es un proceso recursivo y cuyas líneas generales son:

1. El avance está basado en la partición de un nodo de acuerdo a alguna regla. Habitualmente se evalúa una condición sobre el valor de alguna variable.
2. Los prototipos que cumplen una condición se asignan a uno de los dos nodos hijo y los restantes, al otro. Cuando un nodo se divide, se convierte en un nodo intermedio.
3. La condición de parada se define para detener el proceso de partición de nodos. Si se cumple la condición de parada en un nodo, éste no se divide más y se convierte en un nodo hoja y se le asigna una clase a todos los prototipos en ese nodo.

Entre los algoritmos más utilizados para la generación de árboles de decisión destacan CART, ID3, C4.5 y C5.0.

3.3.3.3.1.- Algoritmo C5.0

El algoritmo C5.0 está basado en los algoritmos ID3 y C4.5 desarrollados por Ross Quinlan (Quinlan, 1993). Este algoritmo y sus versiones anteriores son los más empleados para el aprendizaje de árboles de decisión orientados a la clasificación de imágenes (Li *et al.*, 2000; Zhang y Liu, 2005).

Está implementado en los software See5 (www.rulequest.com), Clementine (<http://www.spss.com/clementine/>) y en la versión C4.5 en otros software y librerías como IDRISI (<http://www.clarklabs.org/>) o WEKA (<http://www.cs.waikato.ac.nz/ml/weka/>).

Este algoritmo requiere que cada uno de los datos de entrenamiento esté descrito por una tupla de atributos y por la clase a la que corresponde. Si se consideran los registros de una tabla como tuplas y los campos como atributos, se aprecia la adecuación de este algoritmo para tratar datos contenidos en bases de datos relacionales (Li *et al.*, 2000).

A continuación se describe este algoritmo que utiliza de forma iterativa una estrategia llamada "divide y vencerás":

Sea T el conjunto de casos de entrenamiento y las clases $\{C_1, C_2, \dots, C_k\}$. Hay dos posibilidades para construir el árbol de decisión:

- Todos los casos de T pertenecen a la misma clase C_j : El árbol de decisión para T es una hoja identificando la clase C_j .
- T contiene casos que pertenecen a varias clases: Se divide T en subconjuntos que tienden a ser lo más homogéneos posible. Se elige una condición basada en un atributo que tiene uno o varios resultados mutuamente exclusivos $\{O_1, O_2, \dots, O_n\}$. T se divide en subconjuntos T_1, T_2, \dots, T_n , donde T_i contiene todos los casos en T que tienen como resultado en la condición el valor O_i . El árbol de decisión para T consiste en un nodo de decisión que representa la condición, y una rama para cada posible resultado. Este proceso se aplica repetidamente a cada subconjunto de casos de entrenamiento hasta que se generan subconjuntos de datos pertenecientes a la misma clase, o hasta que no exista ninguna condición que mejore la clasificación.

Las condiciones utilizadas por el algoritmo C5.0 pueden ser de dos tipos:

- $A = v$ siendo A un atributo discreto y v cada uno de sus posibles valores. Obteniéndose un subconjunto de datos para cada uno de los valores de A .
- $A \leq t$ para un atributo continuo. Obteniéndose dos resultados posibles *verdadero* y *falso*.

Para encontrar el umbral t que maximiza el criterio de selección, se ordenan los casos en T según el valor de su atributo A . Cada par de valores consecutivos del atributo A , definen un posible umbral que sería la media de ambos. Se selecciona el umbral que da un mejor resultado en el criterio de selección. En el caso de dos casos cuyos valores del atributo A son consecutivos y pertenecen a la misma clase, el umbral entre ellos no puede generar una partición que maximice el criterio de selección, por lo que no sería necesario considerarlo (Quinlan, 1996b).

El criterio de selección del atributo está basado en la medida de la entropía. La entropía es una medida de la heterogeneidad de un conjunto de datos. En teoría de la información, este término se utiliza para cuantificar la cantidad media de información necesaria para codificar la clasificación de un ejemplo en T . Así, por ejemplo, un conjunto cuyos datos pertenezcan todos a la misma clase, tendrá por entropía el valor nulo, mientras que el conjunto que tenga el mismo número de elementos en cada una de las clases posibles, su entropía será 1.

Supongamos un conjunto T formado por p+n datos, donde P es el subconjunto de T formado por p elementos y cuya clase es "Positivo", mientras que N es el subconjunto de T formado por n elementos cuya clase es "Negativo". La entropía de T se calcula con la expresión (3-1).

$$Ent(T) = -\frac{p}{p+n} \cdot \log_2 \frac{p}{p+n} - \frac{n}{p+n} \cdot \log_2 \frac{n}{p+n} \quad (3-1)$$

Si en lugar de dos clases, hubiera k clases, la expresión de la entropía sería equivalente pero con un sumando para cada clase. Cuando el número de clases es 2, la entropía tiene valores entre 0 y 1. Mientras que si hay k clases, la entropía variará entre 0 y $\log_2 k$.

Se buscan árboles cuyos nodos tengan la menor entropía posible, es decir, la mayoría de sus ejemplos estarán incluidos en la misma clase.

Se determina la ganancia de información que se produce al utilizar un atributo. Es decir, se mide la diferencia en el contenido de información en un nodo y el contenido de información después de dividirlo según los posibles valores de un atributo. La entropía esperada después de usar un atributo A en el árbol es:

$$\sum_{v \in \text{Valores}(A)} \frac{|T_v|}{|T|} \cdot Ent(T_v) \quad (3-2)$$

donde T_v es el subconjunto de ejemplos de T con valor del atributo A igual a v.

Por tanto, la ganancia de información esperada después de usar un atributo A será:

$$\text{Ganancia}(T, A) = Ent(T) - \sum_{v \in \text{Valores}(A)} \frac{|T_v|}{|T|} \cdot Ent(T_v) \quad (3-3)$$

Desde el punto de vista de la entropía como medida de la heterogeneidad, la ganancia sería la reducción de la heterogeneidad en el conjunto global de datos al aplicar una división y se calcula como la diferencia entre la heterogeneidad del conjunto original T menos la heterogeneidad de cada uno de los subconjuntos creados ponderados por su representatividad en el conjunto original. Por tanto, el atributo seleccionado según este criterio será aquel que divida el conjunto de datos en subconjuntos más homogéneos.

El criterio que se utiliza para seleccionar el atributo más adecuado se conoce como "índice de ganancia" y se calcula como:

$$IG = \frac{Ganancia(T, A)}{\sum_{v=1}^{Valores(A)} \frac{|T_v|}{|T|} \cdot \log_2 \left(\frac{|T_v|}{|T|} \right)} \quad (3-4)$$

El conjunto de datos se va subdividiendo según el criterio especificado hasta que todos los subconjuntos sean homogéneos, o bien, se cumpla una condición de parada establecida por el usuario. Condiciones de parada podrían ser que el subconjunto final tenga un número mínimo de elementos o que no se reduzca el error de clasificación en las divisiones siguientes.

Existen numerosos ejemplos de la aplicación de los algoritmos C4.5 y C5.0 en la clasificación de imágenes. Levien *et al.* (1999) combinan un mapa de cambios con datos sobre el tipo y la densidad de la cobertura vegetal y datos extraídos de un MDE. Con el algoritmo C4.5 generan un mapa de cambios con una leyenda más exhaustiva que identificaba los tipos y causas de los cambios. También Friedl *et al.* (2002) generan mapas de usos del suelo globales clasificando imágenes MODIS combinadas con datos auxiliares mediante el algoritmo C4.5.

3.3.3.3.2.- Ruido, sobreajuste y poda

La calidad de los datos de entrada es fundamental para la creación de un árbol de clasificación. Los datos reales están afectados frecuentemente de *ruido* y se pueden identificar distintos tipos de ruido o de errores:

- Dos ejemplos con los mismos valores en los atributos y distinta clasificación.
- Errores en los valores de los atributos.
- Atributos irrelevantes para el proceso.

Este ruido en los datos de entrenamiento afecta al algoritmo produciendo un árbol bastante complejo y que se ajusta en exceso a los datos de entrenamiento. Este sobreajuste del modelo a los datos implica que el modelo aprendido será demasiado específico, poco general y probablemente, poco preciso con datos distintos de los usados en el aprendizaje. Este comportamiento se hace más significativo cuanto mayor sea el número de datos erróneos existentes en los atributos o en las clases de los datos de

aprendizaje, ya que el modelo se ajustará a los datos erróneos, perjudicando el comportamiento global del modelo.

Para reducir este problema, los algoritmos de aprendizaje se modifican para que obtengan modelos más generales, y por lo tanto, menos concretos. En la terminología del aprendizaje automático este procedimiento se conoce como *poda* del árbol de decisión.




Figura 3-10. Poda de un árbol de decisión (Hernández Orallo et al.,2004)

Dentro de los métodos de poda se puede distinguir entre los que se realizan durante la construcción del árbol o los que se hacen analizando el árbol ya construido. En el primer caso se trata de cambiar la condición de parada en la construcción del árbol. En el segundo caso, se trata de eliminar nodos de abajo a arriba hasta un límite determinado. El algoritmo C.5 utiliza una combinación de ambos métodos de poda.

3.3.3.4.- Conversión de árboles de decisión en reglas

Los árboles de decisión son difíciles de comprender, especialmente cuando los árboles son grandes. En la mayoría de los casos, es más sencillo la interpretación de reglas que la de los árboles completos. Por lo tanto, es conveniente convertir los árboles en reglas más aptas para su utilización en un sistema experto.

En un árbol de decisión, las condiciones que debe cumplir un caso para ser clasificado por una hoja se pueden obtener recorriendo el trayecto de condiciones que sigue el caso desde la raíz hasta la hoja. Si el camino hasta cada hoja se transforma directamente en una regla, el conjunto de reglas resultante clasificaría de igual forma que como lo hace el árbol y se mantendría el carácter exhaustivo y exclusivo del árbol y el

orden de aplicación de las reglas no sería relevante. Esta forma de convertir árboles en reglas no implica ninguna reducción del tamaño del árbol.

Se puede eliminar alguna de las condiciones que forman las reglas, es decir, hacer las reglas más generales, sin que el árbol pierda precisión. Para ello, se comienza cuantificando el error que comete la regla completa y a continuación el error que cometería la regla eliminando una de las condiciones. Si el error de la regla con una condición eliminada fuera inferior al error obtenido con la regla completa, esa condición se eliminaría de forma permanente. Este proceso se repite hasta conseguir la simplificación de la regla sin pérdida de precisión.

Las reglas así generadas ya no son mutuamente exclusivas y exhaustivas; por lo tanto, puede haber casos que satisfagan las condiciones de más de una regla, o de ninguna. Para solucionar el problema de asignar una clase a un objeto que cumple más de una regla, se plantean dos soluciones: la primera posibilidad es seleccionar la regla con un nivel de confianza mayor. La segunda alternativa es que cada una de las reglas que cumple el caso, emite un voto cuyo peso es el de su confianza. Se suman los pesos de las reglas que predicen la misma clase y la clase con más votos es la elegida como predicción. Esta segunda opción es la elegida por C5.0.

La clase por defecto se asignará a aquellos casos que no cumplan ninguna regla y se elige aquella clase que contiene el mayor número de casos sin clasificar por ninguna regla.

La confianza, o estimación de la precisión, de cada regla se expresa por medio del ratio Laplace, a partir del número de casos que cumplen la regla y del número de falsos positivos de la regla (casos que cumplen las condiciones de la regla pero que no pertenecen a la clase predicha por la regla):

$$\text{ratio Laplace} = \frac{n - m + 1}{n + 2} \quad (3-5)$$

donde: n es el número de casos que cumplen una regla

m es el número de falsos positivos de la regla

3.3.3.5.- Clasificación mediante árboles de decisión

3.3.3.5.1.- Clasificación con un solo árbol de decisión

Una vez creado un árbol de clasificación, la clasificación de un objeto se realiza mediante la comprobación de las condiciones que cumple según el valor de sus atributos en el itinerario de condiciones establecido en el árbol, desde el inicio hasta llegar al final del mismo cuando se le asigna una clase.

Cualquier objeto descrito por sus atributos será asignado a una clase final, ya que las condiciones del árbol son exhaustivas y todos los objetos cumplirán unas u otras. La precisión de la asignación realizada vendrá expresada por el ratio Laplace.

3.3.3.5.2- Métodos multclasificadores

Los métodos multclasificadores surgieron con la intención de mejorar la precisión de las predicciones realizadas por varios métodos de clasificación. Estos métodos se basan en la definición de varias hipótesis que se combinan, normalmente por votación para obtener la hipótesis más fiable. La combinación de varios árboles de decisión será más fiable cuanto más precisos y distintos sean los árboles entre sí.

El método *bagging* (Breiman, 1996 y Quinlan, 1996a) genera subconjuntos de entrenamiento seleccionando aleatoriamente una muestra de los elementos del conjunto original. Con cada uno de estos subconjuntos genera un árbol de decisión. Al disponer de un conjunto de clasificadores, la predicción de nuevos ejemplos se realiza por votación mayoritaria. Es decir, se elige la clase con mayor número de votos entre todos los clasificadores.

El método *boosting* (Freund, 1995) es un método multclasificador que con su aplicación permite aumentar la precisión de las clasificaciones. *Boosting* sirve para minimizar la sensibilidad de un algoritmo de clasificación, un árbol de decisión en nuestro caso, a los posibles errores existentes en las características de los datos de entrada al clasificador, así como a los posibles errores de clasificación en los datos de entrenamiento. Este método ha sido descrito por Friedman *et al.* (2000) como uno de los desarrollos recientes más importantes en la metodología de la clasificación.

La sistemática que sigue *boosting* (Freund y Schapire ,1997; Quinlan, 1996a) para construir el multclasificador consiste en asignar un peso a cada muestra del conjunto de entrenamiento. Cuanto mayor sea el peso de una muestra, mayor será su influencia en el clasificador. Tras cada iteración, es decir, en la construcción de cada modelo, 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. De esta forma se consigue que el modelo que se aprenda en la iteración siguiente dé más relevancia a las muestras erróneamente clasificadas anteriormente (Hernández Orallo *et al.*, 2004). La idea principal es que cada nuevo modelo trata de corregir los fallos de los modelos anteriores.

El algoritmo de *boosting* más utilizado en clasificación es el *AdaBoost* (Freund y Schapire ,1997). El algoritmo comienza aprendiendo un modelo a partir de un conjunto de muestras de entrenamiento en el que todas tienen el mismo peso y cuyo sumatorio es igual a la unidad. A continuación se estima el error del modelo como la suma de los pesos de las muestras mal clasificadas. Si el error es mayor a 0.5, es decir, más de la mitad de las muestras se ha clasificado erróneamente, el algoritmo se detiene por ser un error demasiado elevado y se descarta ese modelo. También se detiene el algoritmo si el error es 0 por ser un modelo exacto.

En el resto de casos, los pesos de las muestras correctamente clasificadas se modifican para la iteración siguiente, multiplicándose por el resultado de la expresión 3-6.

$$\frac{e}{1 - e} \tag{3-6}$$

Dado que el error del modelo e está comprendido entre 0 y 0.5, esta multiplicación reducirá los pesos de las muestras y será más grande esta reducción cuanto menor error tenga el modelo. Los pesos de todas las muestras se normalizan para que la suma de los pesos sea 1. Se vuelve a generar un nuevo modelo y se repite hasta que se cumple el número máximo de iteraciones especificadas por el usuario, o bien el error del modelo sea 0 ó 0.5.

La clasificación de nuevos objetos con el conjunto de modelos aprendidos se realiza teniendo en cuenta el error estimado de cada modelo. Se asigna a cada modelo un peso que es mayor cuanto menor sea su error estimado y que se calcula con la expresión 3-7.

$$-\log\left(\frac{e}{1 - e}\right) \tag{3-7}$$

Se suman los pesos de los modelos que eligen la misma clase, y aquella clase que acumule el mayor valor es la clase predicha para el nuevo objeto.

La mayoría del trabajo de investigación realizado sobre el método boosting proviene del campo del Aprendizaje Automático, pero trabajos recientes demuestran su aplicabilidad en la clasificación de imágenes (Homer *et al.*, 2004; Wardlow *et al.*, 2005).

Entre los ejemplos de su aplicabilidad en la generación de cartografía de usos del suelo destaca su amplia utilización en el algoritmo de clasificación de coberturas de suelo a escala global a partir de datos MODIS producido por la NASA (Friedl *et al.*, 2002).

Friedman *et al.* (2000) exponen que utilizando *boosting* con un algoritmo de clasificación como el C4.5, se puede asignar a cada píxel la probabilidad de pertenencia a cada clase. Partiendo de esta metodología, Friedl *et al.* (2002) proponen obtener para cada píxel un estimador de la confianza de la clasificación e incluir información auxiliar para resolver problemas de confusión entre clases con una separabilidad espectral reducida. Esta técnica también permite asignar una segunda clase (la segunda más probable) a aquellos píxeles que tienen un valor bajo de confianza para la primera clase.

En el método *boosting*, el valor de la confianza no es el ratio Laplace, sino que tiene en cuenta el peso aplicado a los casos de entrenamiento en cada una de las iteraciones y por lo tanto no refleja la precisión de la regla.

Tanto el método *bagging* como el *boosting* producen clasificadores más precisos que los métodos basados en un solo árbol.

El incremento de tiempo de cálculo necesario es conocido de antemano, ya que será el tiempo necesario para generar un clasificador multiplicado por el número de clasificadores.

La aplicación de estos métodos produce una disminución en los errores de clasificación entre el 10% y el 19% según Quinlan (1996a) y hasta el 26% según Bauer y Kohavi (1999).

En los estudios comparativos de ambos métodos (Quinlan, 1996a; Bauer y Kohavi, 1999; Dietterich, 2000) es el método *boosting* el que, generalmente, obtiene mejores resultados. En casos con ruido en los datos, *boosting* se muestra demasiado sensible y es *bagging* el más robusto ya que obtiene mejores resultados.

3.3.3.6.- Medida del rendimiento del aprendizaje

Las dos formas más empleadas para la evaluación del rendimiento de un clasificador consisten en:

- Utilizar un conjunto de datos de entrenamiento y un conjunto de evaluación: Los datos de entrenamiento se utilizan para aprender el árbol, mientras que el rendimiento del mismo se obtiene como la proporción de ejemplos bien clasificados en el conjunto de evaluación

- Dividir el conjunto de datos de entrenamiento en n partes y hacer n aprendizajes. En cada aprendizaje, para crear el árbol de decisión, se toma como conjunto de evaluación una de las partes y como datos de entrenamiento el resto de los datos. Con el conjunto de evaluación se obtiene el rendimiento obtenido. Finalmente se hace la media de los rendimientos para obtener el rendimiento global. Este método se conoce como **Validación Cruzada**

3.4.- Actualización de bases de datos cartográficas mediante análisis de imágenes

3.4.1.- Introducción

La interpretación automática de imágenes aéreas y de satélite es uno de los principales campos de investigación en fotogrametría y teledetección. Aunque en la actualidad es más un campo de investigación que un campo de aplicación real.

La revisión y actualización de información espacial es el principal esfuerzo que se ha de realizar en el mantenimiento de los SIG y las bases de datos espaciales a fin de conservar su aplicabilidad a lo largo del tiempo. La demanda de actualizar datos geográficos se incrementa debido a los cambios rápidos que se dan en el paisaje que modelan.

En la actualidad la disponibilidad de información geográfica es enorme frente a los recursos de los que se podía disponer hace unos años. Sin embargo, este gran volumen de datos disponible debe ser procesado antes de ser introducido como información útil en los SIG. Siendo éste el paso que queda pendiente en el caso de muchos inventarios. O al menos, no se realiza con la frecuencia que sería deseable y que nos permiten los datos disponibles.

El desarrollo de métodos efectivos de actualización automática de la información espacial se ha convertido en un objetivo de gran interés para la comunidad cartográfica internacional y son muy numerosas las investigaciones, publicaciones y grupos de trabajo dedicados a este fin.

La actualización cartográfica automática de todos los elementos presentes en una base de datos espacial es un proceso sumamente complejo y que en la actualidad permanece sin resolver. En la actualidad, las distintas aproximaciones a la solución del problema se están realizando dividiendo el conjunto de datos a actualizar según su tipología y buscando metodologías adecuadas para cada una de estas tipologías, ya sean edificios, carreteras, parcelas, etc.

La presente sección pretende mostrar las distintas aproximaciones a la actualización de bases de datos que se están realizando, centrando la atención en el caso de parcelas agrícolas.

La actualización cartográfica, según Ramírez (2005), se puede considerar bien como un proceso continuo, o bien, como un proceso cíclico.

La **actualización continua** se realiza cada vez que se tiene conocimiento de un cambio. Por lo que requiere tener implantado un sistema de comunicación de cada uno de los cambios ocurridos. Este sería el caso ideal, y al mismo tiempo real en algunas situaciones, en el que los responsables de un cambio lo comunican directamente al responsable de realizar la actualización de la cartografía. En la actualización de la cartografía catastral, por ejemplo, son los propietarios de los inmuebles en los que se ha producido un cambio los que tienen la obligación de comunicarlo. De esta forma, se conseguiría una cartografía actualizada, dependiente del ritmo de introducción de los cambios y del cumplimiento de la obligatoriedad a declarar por parte de los causantes del cambio. Esta misma estructura sería factible de implantar en el caso de inventarios agrícolas, cuyos propietarios declarasen los cambios de cultivos en sus parcelas.

Esta metodología tiene el inconveniente de que ciertos cambios que se producen de forma continua en el tiempo, no serían percibidos. La variación de la línea de costa o los cambios en el trazado del cauce de un río sólo pueden ser detectados mediante su comparación en instantes separados un periodo grande de tiempo.

La actualización **cartográfica cíclica** se basa en la premisa de que los datos geoespaciales deberían ser revisados cada un cierto número de años. Este intervalo de tiempo sería el ciclo de revisión y está en función de la naturaleza de las áreas cartografiadas, urbanas, agrícolas, forestales, etc.

La fotogrametría y la teledetección han demostrado desde el nacimiento de los SIG, que son técnicas adecuadas para obtener los datos fuente de los SIG, así como para su actualización. Los avances recientes en los sensores empleados en teledetección han permitido que las imágenes de alta resolución, como las adquiridas por los satélites SPOT5, IKONOS y Quickbird, estén ampliamente disponibles.

3.4.2.- Métodos automáticos de detección de cambios en una base de datos

Según Li *et al.* (2002) los dos enfoques principales para la actualización de bases de datos espaciales son:

- Establecer gradualmente una nueva base de datos que reemplace a la anterior. Éste sería un enfoque lento y con un coste económico alto.
- Detectar, identificar y actualizar sólo los cambios. Esta opción es más rápida y adecuada para las bases de datos ya existentes. Por tanto, la detección automática de cambios es el primer paso y el más importante para la actualización automática de bases de datos geográficos.

En función de los datos utilizados, se puede dividir este enfoque en tres categorías:

- a) Detección de cambios entre una imagen nueva y una imagen antigua.
- b) Detección de cambios entre una imagen nueva y una base de datos antigua.
- c) Detección de cambios entre imágenes nuevas y antiguas y una base de datos antigua.

Con el término imagen se hace referencia tanto a una imagen original como a la obtenida mediante la aplicación de un método de fusión de las imágenes captadas por distintos sensores y que combina las propiedades de ambos.

- a) Detección de cambios entre una imagen nueva y una imagen antigua.

Este es el método más usual para la detección de cambios cuando no se dispone de información previa del territorio. Consiste en comparar a nivel de píxel dos imágenes correctamente geo-referenciadas de distintas fechas. Las diferencias entre los niveles digitales de los píxeles, se supone que son debidas a cambios en las características de los objetos. Sin embargo, estas variaciones radiométricas pueden ser debidas a otros factores como diferentes condiciones atmosféricas, variaciones de iluminación, sombras, etc., por lo que es necesario un preprocesado radiométrico de las imágenes para homogeneizarlas. Según Chuvieco (1988) las distintas alternativas propuestas para homogeneizar radiométricamente las imágenes, se pueden resumir en dos grupos: (i) convertir los niveles digitales originales a variables físicas (reflectividad, temperatura del suelo, etc.) o (ii) equipararlos entre imágenes.

La comparación entre ambas imágenes puede ser pre-clasificación o post-clasificación.

En el primer caso se incluyen métodos como la sustracción de imágenes y su posterior umbralización (Caetano y Santos, 2001), ratios (Singh, 1989), índices normalizados (Peled, 1998), vector de cambios (Malila, 1980, Recio *et al.*, 2001), análisis de componentes principales, etc.

Un ejemplo de sustracción de imágenes es el trabajo de Caetano y Santos (2001), en el cual, calculan la diferencia en el valor del índice de vegetación en dos fechas distintas sobre un mismo territorio. Aquellos píxeles cuyo valor de diferencia del índice de vegetación es mayor a un umbral son los identificados como cambios y son sometidos a un procesado particular para determinar la clase existente tras el cambio.

En el trabajo de Bontemps y Defourny (2008) para detectar píxeles clasificados en clases forestales en Corine Land Cover y que han cambiado su cobertura, se realiza una segmentación de la imagen y para cada uno de los objetos se obtiene su reflectancia media en las bandas seleccionadas. Aquellos objetos cuya respuesta espectral difiera de la respuesta media de la clase espectral a la que corresponde en una cantidad mayor a un umbral fijado serán identificados como cambios.

En el segundo caso, se clasifican ambas imágenes y se comparan las clases asignadas a los píxeles en ambas clasificaciones. La comparación de las dos imágenes clasificadas resulta sumamente sencilla construyendo una tabla cruzada con las clases presentes en cada fecha. La diagonal indica las áreas estables y el resto de las celdas las áreas dinámicas.

b) Detección de cambios entre una imagen nueva y una base de datos antigua.

El empleo de imágenes, bien mediante fotointerpretación, de forma automática o de forma semiautomática, es la base en todo proceso de actualización de bases de datos geográficas sobre usos del suelo. Un proceso de actualización incluiría los pasos siguientes:

- Detección automática de cambios.
- Integración de la información alterada en la base de datos del GIS.
- Post-procesado y comprobación de la consistencia de los datos.

Siendo la fase más importante, la detección automática de cambios (Peled, 1998).

Los diferentes modelos de datos de la imagen y la base de datos impiden la comparación directa entre ambos documentos. En su lugar, es necesario extraer objetos

geográficos de la imagen y posteriormente, compararlos con los presentes en el mapa. La extracción automática de objetos es un tema ampliamente estudiado, pero con una evolución relativamente lenta debido a su complejidad (Baltsavias, 2004) y que suele abordarse mediante la integración de la información gráfica y alfanumérica contenida en la base de datos con la imagen que proporciona la información sobre el uso o cobertura del terreno en la fecha de la toma de la imagen. La comparación de los objetos extraídos con los existentes en la cartografía determinará los cambios ocurridos.

Un ejemplo de integración de la información de la imagen y la información cartográfica es el propuesto por Guijun (2004) que propone superponer la cartografía a actualizar con las imágenes y extraer de ellas las características descriptivas de cada una de las clases. Posteriormente, calculando la distancia existente entre las características de cada parcela y las de la clase en la que están clasificadas en la cartografía se determina si ha existido un cambio en el uso de las parcelas.

Walter (2004) en la actualización de la base de datos alemana ATKIS (www.atkis.de) a escala 1/25.000, emplea los límites de los objetos existentes en la cartografía para segmentar la imagen. Los objetos así obtenidos son caracterizados mediante la extracción de características de los píxeles que los forman. Posteriormente, las agrupaciones de píxeles son clasificadas de forma que los cambios se detectan mediante la comparación de la clase asignada en la clasificación con la contenida en la base de datos.

Olsen *et al.* (2002) para detectar nuevos edificios, realizan una máscara de edificios a partir de la información contenida en la base de datos. Los píxeles que corresponden a edificios según la base de datos son clasificados en categorías de edificios homogéneos espectralmente. Finalmente, el resto de píxeles de la imagen son asignados a una de las clases de edificios, en caso de ser similares a alguna de ellas, o en caso contrario, quedan sin clasificar. Una vez procesados los resultados de la clasificación, aquellas agrupaciones de píxeles clasificadas como edificios son comprobadas por un operador para determinar si realmente corresponden a un cambio a actualizar en la base de datos.

c) Detección de cambios entre imágenes nuevas y antiguas y una base de datos antigua.

Este caso puede considerarse como una combinación de los casos planteados en los dos apartados anteriores. La disponibilidad de la imagen antigua con la que se realizó la base de datos aporta valiosa información sobre el proceso de interpretación que se realizó en la fase de producción de la base de datos.

En el caso de disponer de imágenes nuevas y de imágenes correspondientes a la fecha de realización de la base de datos, el proceso de actualización requiere integrar toda

la información disponible. La comparación de ambas imágenes permite detectar tanto las áreas que han permanecido estables como las que han sufrido variaciones en los niveles digitales de los píxeles que pueden estar motivadas por cambios en el uso o la cobertura. La clase asignada a las zonas que han permanecido estables viene recogida en la base de datos.

El hecho de conocer la clase en la base de datos y las características en ambas imágenes de un conjunto de elementos que han permanecido estables, permite utilizarlos como muestras de entrenamiento de un proceso de clasificación. De esta forma, los elementos de los que no exista la certeza de su inalterabilidad, serían clasificados según las características extraídas de la nueva imagen y las características extraídas de las muestras de entrenamiento. Mediante la comparación de la clase asignada en la clasificación con la contenida en la base de datos se detecta el cambio ocurrido.

3.5. Incorporación de la información de una base de datos en la clasificación de imágenes

Numerosos estudios han demostrado que el empleo de datos auxiliares puede mejorar las clasificaciones de usos del suelo, aumentando los niveles de precisión alcanzados. Algunos investigadores han usado datos históricos, como información de cultivos de años precedentes (Janssen y Middelkoop, 1992), datos topográficos (Janssen *et al.*, 1990), etc. Los datos extraídos de modelos digitales de elevación son los más frecuentemente utilizados en combinación con imágenes, pero también se han incorporado datos de temperatura, pluviometría, tipos de suelo etc. La importancia de la utilización de datos auxiliares en la determinación de los usos del suelo varía en relación al tamaño del área considerada. Así por ejemplo, los datos topográficos mejoran la precisión en la clasificación de imágenes cuando se trabaja a escala local o regional, mientras que los datos climáticos son más útiles en escalas regionales o continentales (Skidmore, 1989). Se trata de incorporar en el proceso de generación automática de cartografía temática, la información de la que dispondría un fotointérprete para realizar esta tarea de forma manual.

Para facilitar la incorporación de este conocimiento adicional al proceso, es muy común la utilización del enfoque de clasificación por objetos.

Los numerosos métodos desarrollados para mejorar la clasificación de imágenes utilizando la información disponible en las bases de datos pueden agruparse en las siguientes categorías:

1. Estratificación pre-clasificación

Consiste en delimitar regiones en la imagen que corresponden a áreas que han de ser analizadas de forma distinta. Una delimitación inicial de la zona de estudio en áreas urbanas, agrícolas, masas de agua, etc. puede aplicarse sobre la imagen en forma de máscara a fin de aportar la información general del contexto en la que está incluido el objeto en cuestión. Reduciendo de esta forma la complejidad general de la imagen y permitiendo clasificar de forma distinta objetos con características espectrales similares. Esta información puede ser útil para distinguir por ejemplo, un parque en una zona urbana, de un bosque en una zona agrícola. Strahler *et al.* (1978) estratifican un área forestal según rangos altitudinales y posteriormente, partiendo de una imagen Landsat MSS, clasifican los píxeles de cada estrato en las clases correspondientes.

Existen numerosos ejemplos de trabajos de clasificación por parcelas, en los que la imagen de partida se segmenta según los límites de las parcelas contenidos en la cartografía y las agrupaciones de píxeles son analizadas de forma independiente. Esta metodología se ha desarrollado en la sección 3.2.5.

Pakzad (2002) realiza una segmentación de las áreas de la imagen empleando como límites elementos espaciales contenidos en una base de datos. como son los caminos, carreteras, vaguadas, acequias, etc. Los objetos así generados son divididos o unidos entre sí en función de determinadas condiciones.

Walter (2004) define las agrupaciones de píxeles según los límites contenidos en la base de datos ATKIS. Estas agrupaciones de píxeles son caracterizadas por medio de la media y varianza de los píxeles en cada una de las bandas, además de por el porcentaje de píxeles clasificados en cada una de las clases de la leyenda de una clasificación previa a nivel de píxel. Los resultados obtenidos de la clasificación de los objetos permiten su comparación inmediata con la información contenida en la base de datos.

Volante *et al.* (2007) segmentan imágenes Landsat 5 mediante los límites digitalizados manualmente sobre la banda pancromática del sensor Landsat 7. Una vez definidos los límites de las parcelas, realizan una clasificación de los polígonos, así generados, a partir de las variables espectrales extraídas de los mismos y verifican que los resultados de la clasificación por parcelas es más precisa que otra clasificación realizada a nivel de píxel con los mismos datos de partida.

2. Introducción de la información en la clasificación

Los datos auxiliares pueden incorporarse a la clasificación con varios enfoques:

- Incorporar los datos de la base de datos directamente a los extraídos de las imágenes.

La opción más sencilla para incorporar la información auxiliar al proceso de clasificación de la imagen consiste en la utilización de la información auxiliar como bandas adicionales en la clasificación. Este enfoque está condicionado tanto por el tipo de datos, continuos o categóricos (discretos), como por el tipo de clasificador utilizado; ya que los datos categóricos no son adecuados para su aplicación con métodos de clasificación estadísticos o basados en distancias. Hoffer *et al.* (1975) incluyeron datos de elevación junto a tres bandas espectrales, obteniendo unos incrementos de fiabilidad del 23% y del 32% para las clases empleadas en una clasificación forestal mediante máxima probabilidad.

Si el clasificador no requiere que los datos tengan ciertas características estadísticas, como por ejemplo, tener una distribución normal, es sencillo incorporar los datos auxiliares a la clasificación. En el caso contrario, dependiendo de la tipología de los datos, no será posible utilizarlos como bandas adicionales (Pedroni, 2001).

Por otra parte, la adición de datos auxiliares tiene el inconveniente de tener que fijar unos pesos que permitan ponderar los datos añadidos respecto a la información espectral (Lawrence *et al.*, 2001). Estos pesos son normalmente desconocidos y deben deducirse mediante ensayo y error.

- Utilizar la clase presente en la base de datos para seleccionar los objetos de entrenamiento

Heipke (1999) emplea la información disponible en la base de datos ATKIS para seleccionar automáticamente los objetos para entrenar al clasificador. Para eso es necesario que la mayor parte de los datos de la base de datos sean correctos y que los elementos de una misma clase en la base de datos tengan una representación homogénea en la imagen. A fin de evitar la confusión existente en los píxeles frontera cuyo nivel digital puede estar influido por varios objetos vecinos, estos píxeles no son utilizados como muestras de entrenamiento.

Olsen *et al.* (2002) utilizan la base de datos TOP10DK (Kort & Matrikelstyrelsen, 2001) de Dinamarca a escala 1/10.000 para estudiar su actualización y emplean la información vectorial para seleccionar de forma automática las muestras de aprendizaje. Para detectar edificios, seleccionan los píxeles correspondientes a los edificios contenidos en la B.D. y los agrupan mediante el método de clasificación no supervisada ISODATA con

el fin de obtener tipologías de edificios con respuesta espectral homogénea. Las subclases de edificios así definidas son más homogéneas que la clase global y son las utilizadas en el proceso posterior de clasificación de todos los píxeles de la imagen.

Blaes *et al.* (2005) proponen una metodología para comprobar las solicitudes de subvenciones a determinados cultivos en la Unión Europea. Parten del supuesto que las parcelas con usos distintos a los declarados por los solicitantes son una cantidad reducida frente al conjunto de las parcelas con cultivos declarados correctamente. Por esto, las firmas espectrales las obtienen para cada cultivo utilizando como muestras de aprendizaje el conjunto de declaraciones presentadas para el cultivo correspondiente. Utilizando estas firmas, cada parcela se clasifica mediante el método de máxima probabilidad.

De forma más precisa, Lerános *et al.* (2007) en la comprobación de las superficies cultivadas en Navarra, utilizan como información de partida para el cálculo de firmas espectrales, los recintos del SIGPAC donde se han realizado controles de campo de las declaraciones de subvenciones a la Unión Europea. Estas firmas espectrales se han obtenido por cultivo, comarca agraria y estrato utilizando la información de todos los píxeles de un determinado cultivo.

Walter (2004) en la actualización de la base de datos ATKIS, también utiliza como muestras de aprendizaje los elementos a clasificar con la clase contenida en la base de datos, reduciéndose, en gran medida, el laborioso trabajo de toma de muestras. Este modo de actuar dará buenos resultados siempre que la calidad de los datos contenidos en la base de datos sea alta y no estén muy desactualizados. Konecny (1996) establece que el porcentaje medio anual de cambios en los mapas topográficos en Europa es de 6.4% a la escala 1/50000 y de 7.4% a la escala 1/25.000. Por lo que esta metodología es lo suficientemente robusta para actualizar las bases de datos en ciclos anuales. Perdiendo su validez conforme aumente el tiempo transcurrido entre la creación de la base de datos y su actualización.

- Modificar las probabilidades a priori de las clases de los elementos a clasificar.

La información histórica sobre los cultivos existentes a lo largo del tiempo en una parcela puede ser un indicio del cultivo existente en el instante de estudio y, por tanto, es posible estimar las probabilidades a priori para cada clase en el caso de una clasificación mediante el método de máxima probabilidad. Janssen y Middelkoop (1992) en una clasificación de cultivos, determinan la probabilidad a priori de una clase en función de la clase, es decir, el cultivo, que tuviera el año anterior a la toma de la imagen, utilizando para ello una matriz de transición entre cultivos obtenida por medio de una base de datos con la secuencia temporal de los cultivos de la región.

Blaes *et al.* (2005) calculan las probabilidades a priori para cada cultivo a partir de las superficies dedicadas a cada cultivo presentadas en la declaración presentada por el propietario.

Se ha demostrado que modificando las probabilidades a priori en la clasificación de máxima verosimilitud se puede mejorar la precisión de la clasificación de categorías de coberturas espectralmente similares, sin afectar en la clasificación de las clases espectrales cuyo patrón espectral de por sí no se confunde con otros (Pedroni, 2001; Maselli *et al.*, 1995).

Pedroni, (2001) y Maselli *et al.* (1995) demuestran cómo se puede calcular la definición de probabilidades a priori de las clases de cobertura del suelo en función del contexto geográfico; empleando como información auxiliar, variables extraídas de un MDE o de una cartografía de tipos de suelo. En ambos trabajos, las probabilidades a priori de las distintas clases se obtienen de los histogramas de frecuencias de las muestras de aprendizaje en las variables geográficas. En ambos estudios, los resultados de las clasificaciones en los que se han calculado las probabilidades a priori muestran una precisión entre un 15% y un 20% mayor, frente a las clasificaciones en las que todas las clases tienen la misma probabilidad a priori. La información auxiliar es especialmente adecuada en casos de confusión espectral, mientras en el resto de casos es la información espectral la dominante en la clasificación.

- Condicionar la clase posible en la clasificación en función de la clase que tiene en la base de datos

El conocimiento del medio estudiado permite poner limitaciones a la clase potencial a asignar a una parcela en función de la clase que tiene en la base de datos. Así, por ejemplo, en la mayoría de las zonas agrícolas, es muy poco probable que una parcela de regadío se convierta en una parcela con cultivos de secano, por lo que los cultivos de este tipo podrían eliminarse de las posibles clases a asignar a las parcelas de regadío en la base de datos.

Heipke (2000) establece un diagrama de transiciones posibles, de modo que la clase a asignar a un objeto depende de la clase que tenía en la B.D. En la figura 3-11 se representan los posibles estados a los que pueden evolucionar los distintos objetos.

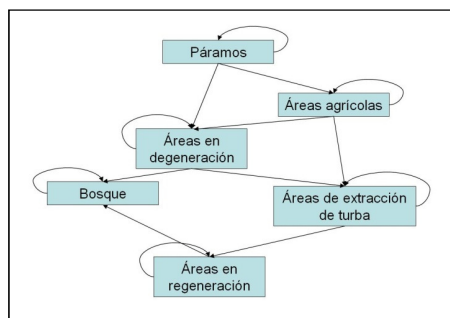


Figura 3-11. Diagrama de estados de transición (adaptada de Heipke, 2000)

3. Evaluación de la clasificación

Los datos almacenados en una base de datos fiable pueden emplearse como muestras de evaluación de la clasificación. La disponibilidad de un conjunto de datos fiables, independiente del conjunto de muestras utilizado para el entrenamiento del clasificador permite reducir el tiempo correspondiente a la selección de muestras, así como comprobar los resultados obtenidos de una forma objetiva, al hacerlo respecto a una base de datos creada con criterios distintos a los utilizados en la fase de entrenamiento.

Las estadísticas agrícolas disponibles por territorios, ya sean términos municipales, comarcas o provincias, pueden tener su utilidad para detectar errores groseros en la clasificación. Para cada territorio se calcularía la diferencia entre la superficie de un determinado cultivo según las estadísticas agrarias y la obtenida mediante la clasificación. En el caso de que esta diferencia sea mayor a un umbral prefijado, se asume que se ha producido un error en la selección de muestras de entrenamiento y la clasificación debería ser corregida (De Wit y Clevers, 2004).

4. Corrección de la clasificación

Los resultados de la clasificación pueden ser mejorados por medio de reglas de decisión derivadas de los datos almacenados en la base de datos. Esta revisión de la clasificación no tiene porqué realizarse para todos los objetos clasificados, si no que puede limitarse a separar los objetos clasificados erróneamente entre dos clases similares.

Cohen *et al.* (2000) establecen reglas de decisión para mejorar los resultados de una clasificación espectral no supervisada; añadiendo a la información espectral el resultado de un análisis de componentes principales, un mapa de suelos y un mapa de precipitaciones. Así, por ejemplo, mejoran la separación entre las clases *cultivos herbáceos* y *trigo*, las cuales tienen características espectrales similares, imponiendo la condición,

extraída del análisis de las muestras de aprendizaje, que los cultivos herbáceos se dan en zonas húmedas, mientras que el trigo se cultiva en zonas áridas o semi-áridas. Utilizando para ello la información extraída del mapa de precipitaciones.

Estas reglas de decisión permiten incluir el conocimiento que se dispone del territorio y pueden ser generadas por un experto o bien, de forma automática con algún método de inteligencia artificial como los descritos en la sección 3.3.

Blaes *et al.* (2005) proponen una clasificación iterativa en la cual, aquellos objetos cuya clase asignada en la primera iteración no coincide con la almacenada en la base de datos, son analizados de forma particular para detectar si son cambios que deben ser confirmados mediante fotointerpretación o visitas de campo, o bien, si son errores de la clasificación de la primera iteración.

Raclot *et al.* (2005) realizaron una clasificación de cultivos agrícolas, en la cual, una de las clases contenía a las parcelas de cereal, prados y barbecho ya que tenían una respuesta espectral muy similar. Para separar estas tres clases, se hizo un análisis de correspondencia múltiple en el que las variables discriminantes fueron: pendiente del terreno, tipo de suelo y si había existido rotación de cultivos en los últimos años. De los resultados de este análisis se extrajeron reglas que permitieron reclasificar los objetos clasificados en la clase común, en cada una de las tres clases integrantes a partir de las relaciones que existían con las variables discriminantes. Por ejemplo, las parcelas asignadas a la clase común con antecedente de prados, situadas en pendientes altas y en suelos calcáreos se asignaron a la clase prados.

5. Obtención de resultados

Una vez obtenida la clasificación definitiva, las discrepancias entre los resultados de la clasificación y los datos contenidos en la base de datos permiten detectar los cambios detectados y generar tanto mapas de cambios, como matrices de cambios que indiquen la tipología de los cambios detectados. Como se ha comentado en la sección 2.3.5, ésta es la metodología propuesta por Perdigo y Annoni (1997) para la detección de cambios entre el Corine Land Cover del año 2000 y el de 1990.

Capítulo IV

DATOS Y ZONA DE ESTUDIO

4.1.- Zona de estudio

Los datos empleados para realizar este estudio se centran en los polígonos catastrales 1 a 8 y 17 a 19 del término municipal de Benicarló, en la comarca del *Baix Maestrat*, en el norte de la provincia de Castellón (figura 4-1).



Figura 4-1. Mapa de situación

El área de trabajo engloba una superficie de 25 km² y está limitada por el Norte por el Barranc d'Aigua Oliva, que es el límite de los términos municipales de Benicarló y Vinarós; el límite por el Este es el mar Mediterráneo, por el Sur el Riu Sec y por el Oeste el límite del término municipal de Benicarló (figura 4-2). Las coordenadas geodésicas de los límites de la zona están recogidas en la tabla 4.1.

| | Latitud | Longitud |
|----------------------------|-------------|------------|
| Esquina superior izquierda | 40°29'35" N | 0°22'30" E |
| Esquina inferior derecha | 40°25'10" N | 0°27'20" E |

Tabla 4-1. Coordenadas extremas de la zona de estudio



Figura 4-2. Zona de estudio

Se trata de una llanura litoral formada por sedimentos cuaternarios, con una altitud media de 48 m y donde la única elevación destacable sobre la llanura es el monte Puig de Benicarló con una altitud de 166 m. En el modelo digital de elevaciones (figura 4-3) se observa la alineación NO-SE de la red de drenaje.




Figura 4-3. Modelo digital de elevaciones de la zona de estudio

Las infraestructuras más significativas son la autopista AP-7, la carretera nacional N-340 y la vía del ferrocarril Valencia – Barcelona, que cruzan la zona de Norte a Sur con trazados paralelos a la línea de costa. Los usos agrícolas son los predominantes en la zona con un 54% de la superficie, frente al 46% que corresponde a zonas urbanas, improductivas y vías de comunicación. El cultivo principal y en expansión es el naranjo, que supone un 28.6% de la superficie. El segundo cultivo más importante con un porcentaje del 19.54% son los frutales de secano como algarrobos y olivos. A continuación, los cultivos hortícolas ocupan el resto de superficie agrícola representando un 11% del total.

En los polígonos catastrales 7 y 8, situados entre la carretera N-340 y la línea de costa, las parcelas agrícolas, que son relativamente homogéneas, se alternan con parcelas de reducidas dimensiones y distribuciones muy heterogéneas, utilizadas como segundas residencias donde coexisten en un mismo recinto edificaciones, jardines, pequeños huertos familiares y balsas de riego o piscinas.

4.2.- Datos de partida

A continuación se describen las características principales de los datos y software utilizados:

a) Imágenes: Se parte de ortofotografías aéreas digitales independientes que cubren la totalidad del término municipal de Benicarló. La composición en falso color infrarrojo, con las bandas infrarrojo, rojo y verde, que se utiliza en todos los ensayos se generó mediante fusión de las bandas pancromáticas y multiespectrales originales. Las imágenes originales fueron adquiridas en agosto de 2005 por el Instituto Cartográfico Valenciano, utilizando un sistema de cámaras fotogramétricas DMC (*Digital Mapping Camera*) de Intergraph's Z/I Imaging, cuyas características técnicas se muestran en la tabla 4-2.

| | |
|-------------------------|--|
| Tipo de sensor | CCD (Charged-Coupled-Device) matricial |
| Número de cámaras | 4 pancromáticas y 4 multiespectrales |
| Campo de visión | 69.3° perpendicular a la trayectoria por 42° a lo largo de la trayectoria |
| Sensibilidad espectral | Azul: 400-580 μm Verde: 500-650 μm Rojo: 590-675 μm Infrarrojo : 675-850 μm Banda pancromática |
| Distancia focal | Cámaras pancromáticas: 120 mm Cámaras multiespectrales: 25 mm |
| Resolución radiométrica | 12 bits/píxel |
| Resolución espacial | Detectores de 12 x 12 μm Imagen final: 0.5m/píxel |

Tabla 4-2. Características técnicas básicas del sistema de cámaras aéreas digitales DMC.

b) Cartografía vectorial: Cartografía catastral en formato vectorial *shape* conteniendo la delimitación en polígonos, parcelas y subparcelas catastrales. La figura 4-4 muestra el parcelario superpuesto sobre un detalle de la ortofoto en falso color infrarrojo.



Figura 4-4. Parcelario superpuesto sobre imagen falso color infrarrojo

c) Información alfanumérica: La información alfanumérica disponible de las parcelas situadas en la zona de estudio es la correspondiente al padrón del impuesto de bienes e inmuebles, a excepción de los datos personales de los propietarios de estos bienes. Entre la información relativa a cada parcela contenida en el padrón del impuesto están su referencia catastral, su localización y su división en subparcelas de las que se describe su clase de cultivo, su intensidad productiva y su superficie.

d) Software: La programación específica de los métodos de procesado se ha realizado en el lenguaje de programación IDL versión 6.2, mientras que las operaciones básicas de visualización y preprocesado se han llevado a cabo con el programa de tratamiento de imágenes ENVI en su versión 4.2.

4.3.- Selección de muestras y definición de la leyenda

En el área de trabajo hay un total de 6170 subparcelas. Con el objeto de tener una base de datos fiable para los procesos de entrenamiento y evaluación de las clasificaciones a realizar, se determinó la clase existente para todas las subparcelas en el momento de la toma de la imagen mediante fotointerpretación asistida por ordenador. En esta fase se analizó como información auxiliar la contenida en la base de datos catastral y en el visor del SIGPAC. Aquellas parcelas en cuya superficie se diera más de un uso fueron asignadas a la clase que ocupaba una mayor superficie. Además, se indicó en un campo de observaciones la mezcla de clases que tenía lugar. En aquellos casos en que la asignación de la clase correspondiente fuera dudosa se rellenó mediante visita de campo una ficha descriptiva de la parcela en la que se incluía el cultivo, el estado, la fecha, las coordenadas GPS y fotografías que completaran la descripción de la parcela. En el anejo I se muestran dos ejemplos de las fichas utilizadas en la revisión de campo.

Del análisis de los usos existentes en el área de estudio, se deducen las clases que componen la leyenda del mapa de usos del suelo empleado en los ensayos. Los cultivos citrícolas tienen un tratamiento particular respecto al resto de usos del suelo; dada su importancia en la zona y debido a las diferentes tipologías existentes, se crearon varias clases en la leyenda correspondientes a cada una de las principales tipologías, con el objeto de que las clases se adaptasen a las características del cultivo. Las clases de

parcelas cítricas consideradas son: Cítricos adultos independientes, cítricos adultos alineados, cítricos irregulares, cítricos jóvenes y plantones de cítricos.

En la tabla 4-3 se muestran las 14 clases que forman la leyenda, así como el número de parcelas existentes en cada clase, su superficie media, la superficie total por clase y el porcentaje de superficie ocupada por cada clase respecto a la superficie total.

En la sección siguiente, se enumeran las clases definidas con ejemplos de cada una de ellas extraídos de la composición en falso color de las imágenes DMC sobre las que se ha superpuesto la cartografía catastral.

| CLASE | NÚMERO DE PARCELAS | SUPERFICIE MEDIA (m ²) | SUPERFICIE TOTAL (ha) | % DE LA SUPERFICIE |
|----------------------------------|--------------------|------------------------------------|-----------------------|--------------------|
| Agua | 148 | 128.04 | 1.89 | 0.07 |
| Algarrobos | 440 | 6270.40 | 275.90 | 10.87 |
| Cítricos adultos independientes. | 366 | 7013.55 | 256.70 | 10.11 |
| Cítricos adultos alineados | 67 | 9301.50 | 62.32 | 2.46 |
| Cítricos irregulares | 105 | 5778.94 | 60.68 | 2.39 |
| Cítricos jóvenes | 282 | 8213.81 | 231.63 | 9.13 |
| Edificios | 1339 | 220.77 | 29.62 | 1.17 |
| Jardín | 506 | 908.27 | 45.96 | 1.81 |
| Matorral | 147 | 10928.37 | 160.65 | 6.33 |
| Olivos | 430 | 5119.91 | 220.16 | 8.67 |
| Plantones de Cítricos | 160 | 7147.93 | 114.37 | 4.51 |
| Regadío | 240 | 6551.25 | 157.23 | 6.19 |
| Suelo desnudo | 1391 | 5435.95 | 756.14 | 29.79 |
| Vías de comunicación | 549 | 3002.54 | 164.84 | 6.50 |
| TOTAL | 6170 | 4113.60 | 2538.09 | 100 |

Tabla 4-3. Distribución de clases en la zona de estudio

4.3.1.- Descripción de las clases temáticas

AGUA: Las acumulaciones de agua presentes en la zona de estudio corresponden a balsas de riego y piscinas particulares. Dado el reducido tamaño de estos elementos, los errores de digitalización y/o georreferenciación provocan la inclusión de un porcentaje elevado de píxeles ajenos al objeto, modificando significativamente sus propiedades.




Figura 4-5. Muestras de la clase AGUA

ALGARROBOS: Los árboles de esta clase son los que tienen un mayor tamaño de copa. Suelen tener una distribución espacial irregular y en muchos casos están en estado de semi-abandono combinados con vegetación herbácea y matorral.




Figura 4-6. Muestras de la clase ALGARROBOS

CÍTRICOS ADULTOS ALINEADOS: Plantaciones de cítricos adultos alineados regularmente, de tal forma que las copas de los árboles colocados en una misma fila están en contacto entre sí, definiendo alineaciones de árboles intercaladas con líneas, bien de suelo desnudo o bien de sombras proyectadas por los árboles.




Figura 4-7. Muestras de la clase CÍTRICOS ADULTOS ALINEADOS

CÍTRICOS ADULTOS INDEPENDIENTES: Parcelas de cítricos adultos con los árboles aislados entre sí y marcos de plantación regulares. El suelo entre los árboles suele estar desnudo sin presencia considerable de cubierta vegetal herbácea.




Figura 4-8. Muestras de la clase CÍTRICOS ADULTOS INDEPENDIENTES

CÍTRICOS IRREGULARES: Plantaciones de cítricos adultos que aún estando plantados según marcos de plantación regulares geométricamente, presentan una distribución irregular por la falta de un porcentaje elevado de los árboles o por la combinación de árboles adultos con árboles jóvenes.




Figura 4-9. Muestras de la clase CÍTRICOS IRREGULARES

CÍTRICOS JÓVENES: Plantaciones de cítricos que todavía no están en fase de producción. Se caracterizan por un marco de plantación bien definido, copas de tamaño pequeño y una respuesta importante del suelo desnudo con poca presencia de vegetación




Figura 4-10. Muestras de la clase CÍTRICOS JÓVENES

EDIFICIOS: Los edificios presentes en la zona se corresponden con naves o almacenes industriales y viviendas unifamiliares. Los materiales predominantes en las cubiertas de estas construcciones se representan en tonos grises y amarillos.




Figura 4-11. Muestras de la clase EDIFICIOS

JARDINES: En la cercanía de las zonas urbanas es frecuente la aparición de parcelas con casas aisladas utilizadas como residencias de verano o de fin de semana. La cubierta de estas parcelas no es homogénea, ya que se combinan dentro de un mismo recinto construcciones, zonas ajardinadas, huertos familiares, balsas o piscinas, etc.



Figura 4-12. Muestras de la clase JARDINES

MATORRAL: Esta clase se corresponde con parcelas no cultivadas y cubiertas con vegetación natural no lo suficientemente densa para cubrir todo el suelo. Dentro de esta clase se incluyen aquellas parcelas agrícolas abandonadas y ocupadas por vegetación herbácea, arbustiva y con árboles dispersos ocasionalmente.




Figura 4-13. Muestras de la clase MATORRAL

OLIVOS: Parcelas con marcos de plantación regulares con las copas de los árboles independientes entre sí. El tamaño de los árboles, en general, es más reducido que los algarrobos, mientras que su respuesta en la banda del Infrarrojo es menos vigorosa que la de los algarrobos.




Figura 4-14. Muestras de la clase OLIVOS

PLANTONES DE CÍTRICOS: Parcelas de cítricos que han sido plantadas poco tiempo antes de la toma de la imagen. La copa de los árboles tiene un tamaño mínimo y se percibe perfectamente el marco de plantación utilizado. La respuesta general de la parcela es la del suelo desnudo existente en ella y la de las malas hierbas en el caso de que las haya.




Figura 4-15. Muestras de la clase PLANTONES DE CÍTRICOS

REGADÍO: Parcelas hortícolas con cultivos de temporada en un estado vegetativo medio o avanzado. Se caracterizan por presentar texturas muy homogéneas y por presentar, tonos rosáceos o rojizos en función del grado de desarrollo del cultivo.




Figura 4-16. Muestras de la clase REGADÍO

SUELO DESNUDO: En esta clase se incluyen aquellas parcelas que no tienen una cobertura vegetal. Se asignan a esta clase tanto solares sin edificaciones como parcelas agrícolas sin cultivos en el momento de la toma de la imagen o superficies asfaltadas. Estas parcelas están asociadas con tonos claros.




Figura 4-17. Muestras de la clase SUELO DESNUDO

VÍAS DE COMUNICACIÓN: La principal característica descriptiva de los polígonos que representan caminos y carreteras es su forma alargada. Por otra parte, su respuesta espectral es muy variable al estar influida, en gran medida, por la respuesta de los polígonos colindantes.




Figura 4-18. Muestras de la clase VÍAS DE COMUNICACIÓN

Capítulo V

METODOLOGÍA

5.1.- Introducción

La fotointerpretación realizada por un fotointérprete para la actualización de una base de datos de usos del suelo consiste en el reconocimiento de los elementos representados en las imágenes. Este reconocimiento precisa de un conocimiento por parte del intérprete de ciertas características propias de los objetos, como son la forma, la textura, el tono, el tamaño, su disposición espacial, las relaciones entre los objetos como por ejemplo las sombras proyectadas por ciertos elementos, etc. Este conocimiento debe estar acompañado de cierta información sobre el territorio analizado, ya que existen elementos similares en sus características perceptivas pero con ubicaciones en el espacio muy diferentes. Es decir, hay que conocer tanto los objetos a discriminar como las características del territorio analizado.

Para emular en lo posible el trabajo de un fotointérprete en el reconocimiento automático de objetos a partir de imágenes, es necesario dotar al sistema de las herramientas de análisis y de la información de la que dispone el intérprete. El conocimiento de las distintas clases se suministra 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 objetivo de dotar al sistema de la capacidad de 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, para ello deben cuantificarse de forma numérica estas propiedades de forma que pueda utilizarlas para la asignación de los objetos a una clase temática.

En este capítulo se describen las características extraídas de las parcelas agrícolas y de los objetos que las integran con el objetivo de lograr una descripción lo más completa posible de cada uno de los objetos contenidos en la base de datos a actualizar.

En la figura 5.1 se muestra el flujo de procesos que componen la metodología que se propone para realizar la actualización de una base de datos de ocupación del suelo.

El primer paso a realizar en un sistema de análisis de imágenes basado en objetos consiste en la definición del objeto de estudio, presumiblemente, mediante la segmentación de la imagen. Como se comentó anteriormente, los objetos se generan usando como límites los correspondientes a cada subparcela en la cartografía catastral. Aunque los límites utilizados corresponden a la subparcela catastral, nos referiremos a los objetos así creados como parcelas, ya que es un término más general, más habitual en la bibliografía y más correcto desde el punto de vista léxico.

Para reducir el efecto de los posibles desajustes geométricos entre ambas fuentes de datos (imágenes y parcelario vectorial) se realiza una erosión de dos píxeles a cada parcela, de forma que los valores de las zonas periféricas de cada una de ellas no se tengan en cuenta para la extracción de variables, reduciendo el riesgo de emplear datos correspondientes a píxeles de parcelas contiguas.

Para la aplicación de esta metodología, es necesario proporcionar al sistema el conocimiento del que dispone un intérprete en la interpretación de los distintos usos tanto para la fase de entrenamiento del clasificador como en la de evaluación de los resultados. Con el objeto de disponer de una base de datos de verdad terreno se determinó el uso de la totalidad de las parcelas mediante fotointerpretación y visitas de campo. Como resultados de esta fase se obtienen los conjuntos de muestras de entrenamiento y de evaluación que se van a utilizar en los ensayos de los distintos procesos de la metodología. En el anejo I se muestran dos de las fichas que se hicieron en las visitas de campo para determinar el uso de aquellas parcelas cuyo uso no era posible discernir mediante el análisis de las imágenes.

Una vez obtenida la representación en la imagen de cada parcela, se procede a extraer de ella toda la información que se considera relevante para conseguir una descripción lo más completa posible. Estas características se han agrupado en características espectrales, características texturales, características descriptivas de los patrones de distribución de los elementos de la parcela a las que denominamos estructurales (Recio *et al.*, 2006), características descriptivas de los árboles existentes en

la parcela, propiedades topográficas, relativas a una clasificación por píxel, de forma e información auxiliar.

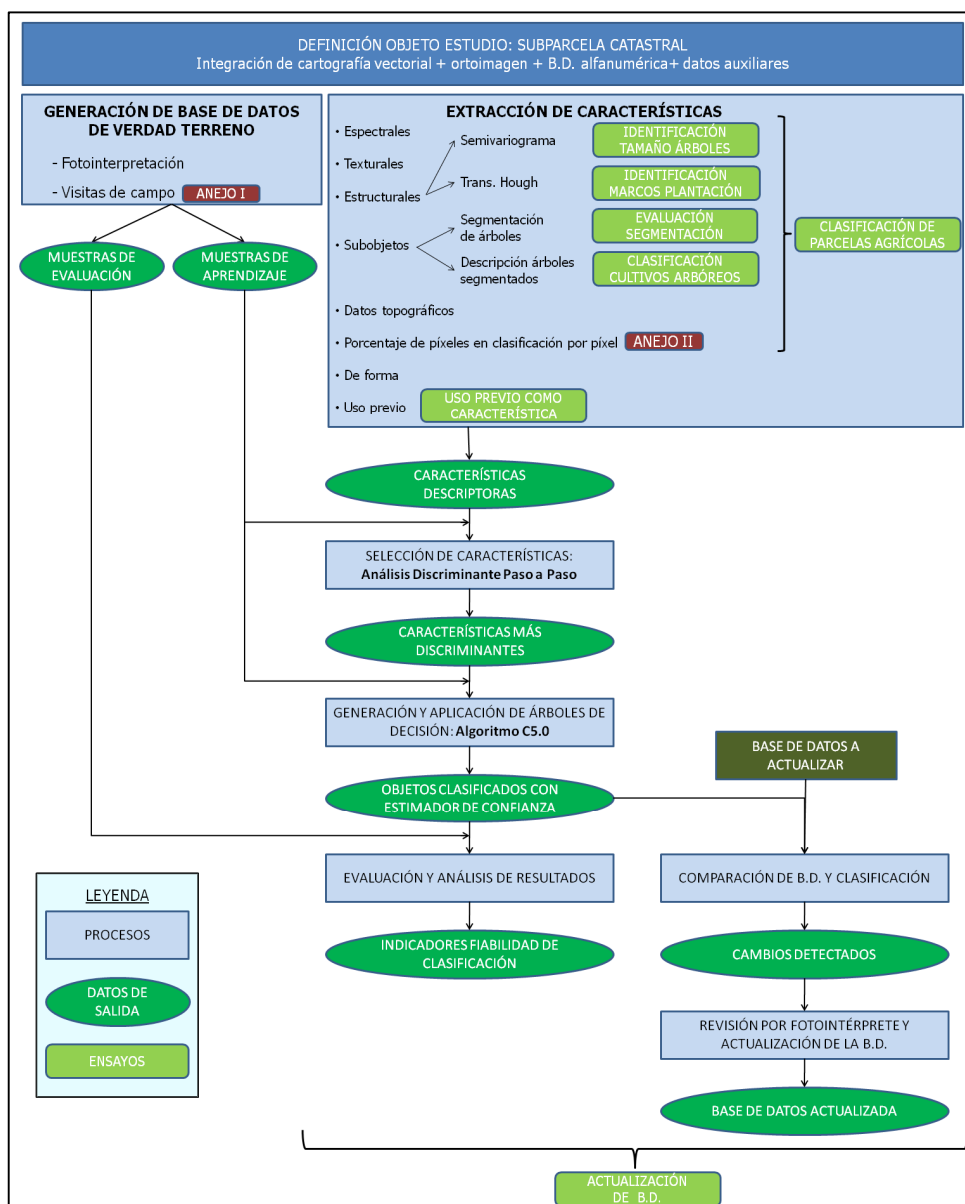


Figura 5-1. Flujo de procesos, datos y ensayos

Las características estructurales se obtienen mediante el análisis del semivariograma omnidireccional de la banda infrarroja y mediante la aplicación de la transformada de Hough sobre una imagen binaria correspondiente a la localización de los

árboles contenidos en cada parcela. En el primer ensayo, sección 6.2, se evalúa la identificación del tamaño medio de los árboles de una parcela mediante el primer máximo del semivariograma. En el ensayo de la sección 6.3 se evalúa la adecuación de dos de las características extraídas de la aplicación de la transformada de Hough para determinar las dimensiones de los marcos de plantación de cultivos arbóreos.

Mediante la aplicación de un método de segmentación automática descrito en la sección 5.2.4 se extraen los árboles contenidos en las parcelas. Estos son descritos con un conjunto de características que se añaden al vector de características de las parcelas que los contienen. Los resultados de la segmentación se comparan en el ensayo de la sección 6.4 con las superficies de los árboles delineados manualmente. Las características extraídas de los árboles segmentados se emplean en el ensayo de la sección 6.5 para determinar la clase de cultivo arbóreo al que pertenecen un conjunto de parcelas.

La realización de una clasificación a nivel de píxel permite incluir en la descripción de los objetos la proporción de píxeles clasificados en cada una de las clases de la leyenda, aportando de esta forma información sobre las distintas coberturas existentes en el interior de cada objeto. En el anejo II se muestran los resultados de la clasificación por píxel realizada.

Además de la información extraída del procesado de la imagen se completa la descripción de las parcelas con información topográfica, de la forma de las parcelas y con la información relativa al uso previo contenida en la base de datos a actualizar. La inclusión del uso previo como variable descriptora es analizada en el ensayo de la sección 6.6.

En el ensayo de la sección 6.7 se comprueba la validez del conjunto de características descritas para la clasificación de parcelas agrícolas.

Como resultado de la fase de extracción de características se obtiene para cada parcela un vector de características con toda la información que se considera relevante para determinar su uso.

A continuación, es conveniente realizar un proceso de selección de las características más discriminantes para eliminar redundancias entre las características y reducir el volumen de información no significativa. Los datos de entrada para esta fase son las muestras de aprendizaje junto con sus características descriptoras. Como resultado, se obtienen las características con mayor poder separador de las clases de la leyenda según las muestras proporcionadas, que serán las empleadas en la clasificación del resto de parcelas.

El entrenamiento del clasificador, árboles de decisión en nuestro caso, se realiza con las muestras de aprendizaje y las características seleccionadas. Tras la aplicación del clasificador se obtiene para cada objeto la clase que le corresponde según el clasificador y un estimador de la confianza con la que se ha hecho la asignación de la clase.

A partir de las parcelas clasificadas se procede por un lado a la comparación con las muestras de evaluación para determinar los parámetros que indiquen la fiabilidad global de la clasificación y las fiabilidades particulares de cada una de las clases. Por otra parte, la clase asignada a cada objeto se compara con la contenida en la base de datos a actualizar para detectar las discrepancias entre ambas fuentes de datos. Estas discrepancias corresponden a cambios de uso ocurridos entre la realización de la base de datos y la fecha de actualización, o bien, a errores en las fuentes de datos comparadas. El uso de estas parcelas debe ser confirmado o modificado por un fotointérprete para obtener la base de datos actualizada con el mayor rigor.

En el ensayo de la sección 6.8 se realiza la actualización de la base de datos catastral para toda la zona de trabajo utilizando la metodología propuesta, evaluando la precisión alcanzada y describiendo las dificultades surgidas en su aplicación.

5.2.- Extracción de características

5.2.1.- Características espectrales

Estas características proporcionan información sobre la respuesta espectral de las parcelas, la cual viene dada en función de los tipos de cobertura, estados fisiológicos de las plantas, materiales de construcción, etc. Para cada polígono se calculó la **media aritmética** y la **desviación típica** del valor de intensidad en las 3 bandas espectrales utilizadas: verde, rojo e infrarrojo cercano, y del índice NDVI.

La media aritmética de los niveles digitales de los píxeles de una parcela en una banda tiene un mayor significado como variable descriptora de la parcela cuanto más homogénea sea la respuesta espectral de la superficie, ya que en casos de parcelas heterogéneas espectralmente, el valor medio no corresponde sino a un promedio de los valores de reflectancia de elementos diversos, como suelo, vegetación, etc.

En los gráficos siguientes se muestra el valor medio y la desviación típica en cada una de las bandas según las clases definidas para el conjunto de parcelas de estudio. En la

figura 5-2, se comprueba que la clase *Agua* tiene unas propiedades espectrales características, teniendo el valor mínimo en las tres bandas y el índice considerado. Las clases *Vías de Comunicación* y *Edificios* tienen un comportamiento espectral muy similar entre sí y significativamente distinto al resto, ya que tienen los valores máximos en las bandas del IR, R y V; mientras que en el NDVI les corresponden los valores mínimos. Del mismo modo, la clase *Matorral* también es fácilmente separable del resto al tener valores mínimos en las tres bandas espectrales y máximos en el índice NDVI. La clase *Suelo Desnudo*, pese a no tener un comportamiento extremo como en los casos anteriores, sí tiene valores particulares respecto al conjunto de parcelas cuyo análisis permitiría su correcta clasificación.

Las clases en las cuales predomina la vegetación no espontánea: *Algarrobos*, *Cítricos*, *Jardines*, *Olivos* y *Regadío* presentan valores similares en las cuatro variables analizadas; resultando compleja su clasificación sin el empleo de más características descriptivas.




Figura 5-2. Media de los niveles digitales por clase

En la figura 5-3 se aprecia que la clase con una mayor heterogeneidad en sus valores radiométricos es la clase *Jardín*. Esta clase se define como un recinto en el que coexisten jardines con pequeñas plantaciones familiares, caminos, pequeños edificios y hasta incluso balsas de agua; con lo que resulta evidente que esta clase es la que tenga un valor máximo de la desviación típica en todas las bandas analizadas. Por otra parte, las clases con un valor menor de desviación típica en todas las bandas son *Regadío* y *Suelo desnudo*, que son las que muestran una respuesta más homogénea a lo largo de toda la parcela. El resto de clases presentan valores similares en estas características y no son, a

priori, separables mediante estas características. Siendo la máxima utilidad de estas características la discriminación de las parcelas espectralmente homogéneas de las heterogéneas.




Figura 5-3. Desviación típica de los ND por clase

5.2.2.- Características texturales

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.

Existe un amplio conjunto de técnicas de análisis de texturas que son utilizadas para extracción de características: métodos estadísticos, (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 wavelet (Mallat, 1989), etc.

El método estadístico de variables texturales derivadas de la MCNG es el que mejor se comporta y mejores resultados proporciona (Fernández Sarría, 2007) y ha sido

ampliamente evaluado en la clasificación de unidades de vegetación (Ruiz *et al.*, 2002 y 2004). Además, es el más utilizado de forma estándar en los programas de tratamiento digital de imágenes como ENVI, Definiens Imaging, ERDAS, etc.

A continuación se describen las variables texturales calculadas para cada parcela: intensidad de bordes, curtosis y coeficiente de asimetría del histograma y las variables extraídas de la MCNG.

- **Intensidad de bordes:** 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 utilizó 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:

$$g(d) = \sum_{(x,y) \in N} \{ |f(x,y) - f(x+d,y)| + |f(x,y) - f(x-d,y)| + |f(x,y) - f(x,y+d)| + |f(x,y) - f(x,y-d)| \} \quad (5-1)$$

En nuestro caso, se calculó la intensidad de bordes para una distancia de 1 píxel en todos los píxeles del objeto y el valor medio de esta característica para todos ellos es el asignado al objeto

- **Estadísticos de primer orden:** El histograma de una imagen con M filas y N columnas es una función que determina para cada nivel digital i su frecuencia de repetición $h(i)$ dentro de la imagen.

$$h(i) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \delta(f(x,y), i) \quad (5-2)$$

siendo la función delta de Kronecker:

$$\delta(i, j) = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (5-3)$$

El histograma de frecuencias de los niveles de gris acumula toda la información estadística de primer orden sobre una imagen o cualquier fragmento de ella. De cada nivel de gris se puede determinar cuál es la probabilidad de que aparezca en la imagen (o de ocurrencia):

$$p(i) = \frac{h(i)}{NM}, \quad i = 0, 1, 2, \dots, N_g - 1 \quad (5-4)$$

donde N_g representa el rango de niveles de gris.

A partir de ella se pueden determinar algunas variables de textura de la imagen relacionadas directamente con la forma del histograma, con su anchura, con la forma de su distribución, etc. Las variables extraídas del histograma de la imagen de cada parcela son:

- **Skewness, tercer momento o coeficiente de asimetría:** Determina si una distribución 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.

$$\mu_3 = \sum_{i=0}^{N_g-1} \left(\frac{(i-\mu)}{\sqrt{\sigma^2}} \right)^3 \cdot p(i) \quad (5-5)$$

- **Kurtosis o apuntamiento:** se define como el grado en el que una distribución estadística de frecuencias es puntiaguda y se determina por la expresión:

$$\mu_4 = \sum_{i=0}^{N_g-1} \left(\frac{(i-\mu)}{\sqrt{\sigma^2}} \right)^4 \cdot p(i) - 3 \quad (5-6)$$

- Matriz de Coocurrencias de Niveles de Gris

Los elementos de esta 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. En esta matriz cuanto mayores sean los valores de su diagonal principal más homogénea será la textura que representa, 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:

$$p(i, j) = \frac{P(i, j)}{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} P(i, j)} \quad (5-7)$$

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 8 variables estadísticas de segundo orden, propuestas por Haralick *et al.* (1973), las cuales describen las propiedades siguientes: uniformidad, contraste, media, entropía, varianza, momento producto, correlación y momento diferencia inverso.

- **Media:** Proporciona información sobre el brillo global del objeto:

$$\mu = \sum_{i=0}^{N_g-1} i \cdot p_x(i) \quad (5-8)$$

donde:
$$p_x(i) = \sum_{j=0}^{N_g-1} p(i, j)$$

- **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:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu)^2 \cdot p(i, j) \quad (5-9)$$

- **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:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - j)^2 \cdot p(i, j) \quad (5-10)$$

- **Uniformidad:** Mide la homogeneidad textural de la imagen. Los valores más altos corresponden a distribuciones espaciales de los niveles de gris casi constantes:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j)^2 \quad (5-11)$$

- **Entropía:** Mide la aleatoriedad, complejidad o desorden en la distribución de la intensidad en una imagen:

$$-\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} p(i, j) \cdot \log[p(i, j)] \quad (5-12)$$

- **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:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{p(i, j)}{1 + (i - j)^2} \quad (5-13)$$

- **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:

$$\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu) \cdot (j - \mu) \cdot p(i, j) \quad (5-14)$$

- **Correlación:** Equivale al momento producto normalizado con respecto a la varianza:

$$\frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu)(j - \mu)p(i, j)}{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - \mu)^2 \cdot p(i, j)} \quad (5-15)$$

Desde el punto de vista práctico, uno de los problemas que presenta la clasificación de imágenes mediante información o variables texturales 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 matriz de coocurrencias 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 los ensayos realizados en esta tesis, en lugar de calcular una MCNG para cada uno de los píxeles pertenecientes a un objeto y posteriormente obtener la media aritmética de las 8 variables explicadas y así obtener las 8 características correspondientes al polígono, se ha calculado una única MCNG para cada polígono 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. La banda utilizada para el cálculo de las variables de textura es la correspondiente al rojo.

5.2.3.- Características estructurales

5.2.3.1.- Estudio de la regularidad de las parcelas mediante análisis del semivariograma

5.2.3.1.1.- Introducción

El marco de plantación que se utiliza en los cultivos arbóreos es una de las características más significativas para la identificación visual de este tipo de cultivos. La disposición de los árboles siguiendo patrones geométricos, bien sea en marcos cuadrados, rectangulares, al tresbolillo, en hileras etc. supone una ayuda fundamental para la correcta fotointerpretación de los distintos cultivos.




Figura 5-4. Ejemplos de distintos marcos de plantación

Por otra parte, la descripción geométrica de estos patrones puede dar información agronómica sobre densidad de cultivos y producciones, necesidad de pesticidas, riesgos de

erosión por escorrentía por la combinación de la dirección de las alineaciones, pendientes y orientaciones de laderas, etc. (Robbez-Masson y Foltete, 2005).

La respuesta espectral de los cultivos arbóreos es una combinación de la reflectancia de los árboles, las sombras que estos proyectan y el suelo con o sin vegetación.

Ya que la característica principal definitoria de los marcos de plantación es su regularidad según un determinado patrón geométrico, se creyó conveniente utilizar herramientas geoestadísticas para caracterizar estos patrones regulares en el espacio. La geoestadística se define como la aplicación de la Teoría de Funciones Aleatorias al reconocimiento y estimación de fenómenos naturales o, simplemente, al estudio de las variables numéricas distribuidas en el espacio (Journel y Huijbregts, 1978). Algunos fenómenos distribuidos en el espacio, como es el caso de los recursos minerales o los niveles digitales en una imagen de un cultivo arbóreo, presentan un carácter mixto, un comportamiento caótico o aleatorio a escala local, pero estructural a la vez a gran escala. Se puede interpretar este fenómeno como una función aleatoria, (figura 5-5) que asocia a cada punto x del espacio una variable aleatoria $Z(x)$. Para dos posiciones en el espacio x e y , habrá dos variables aleatorias diferentes pero no independientes, y es ese grado de correlación espacial existente entre los datos el que se pretende averiguar.




Figura 5-5. Carácter mixto de una función aleatoria

5.2.3.1.2.- Variables aleatorias regionalizadas

Journel y Huijbregts (1978) definen la Variable Regionalizada como una función $f(x)$ que toma valores en todos los puntos x de coordenadas (x_i, y_i, z_i) en el espacio tridimensional. Estas funciones pueden variar de forma irregular en el espacio, siendo necesario estudiar su variabilidad por medio del semivariograma experimental.

El semivariograma experimental es la herramienta geoestadística más importante en la determinación de las características de variabilidad y correlación espacial del fenómeno estudiado representando el útil más adecuado para el análisis de la distribución espacial de la variable en estudio.

El variograma se define como la media aritmética de todos los cuadrados de las diferencias entre pares de valores experimentales separados una distancia h (Journel y Huijbregts, 1978), o lo que es lo mismo, la varianza de los incrementos de la variable regionalizada en las localizaciones separadas una distancia h .

$$\text{Var}\{Z(x+h) - Z(x)\} = 2\gamma(h) \quad (5-16)$$

La función $\gamma(h)$ se denomina semivariograma, y se obtiene con la expresión:

$$\gamma(h) = \frac{1}{2NP(h)} \sum_{i=1}^{NP(h)} [Z(x_i) - Z(x_i+h)]^2 \quad (5-17)$$

donde: $NP(h)$ es el número de pares a la distancia h

h es el incremento

$Z(x_i)$ son los valores experimentales

x_i son las localizaciones donde se miden los valores $Z(x_i)$

En el caso de una imagen, $Z(x_i)$ representa el nivel de gris para un píxel en la posición x_i .

Se distingue habitualmente entre el semivariograma medio, global u omnidireccional que proporciona una idea inicial de la variabilidad espacial de los datos, y el semivariograma direccional que facilita el estudio de la variabilidad espacial en una determinada dirección.

5.2.3.1.3.- El semivariograma experimental

Un variograma típico presenta una curva ascendente que tiende a estabilizarse. A mayor distancia entre los pares de datos, mayor es la disimilitud o variación entre ellos hasta llegar a estabilizarse.




Figura 5-6. Semivariograma experimental

Los parámetros del semivariograma caracterizan tres elementos importantes en la variabilidad de un atributo que son: la discontinuidad en el origen (existencia de efecto pepita), el valor máximo de variabilidad (meseta) y el área de influencia en la correlación (alcance).




Figura 5-7. Parámetros del semivariograma experimental

- Efecto pepita (*Nugget*): La discontinuidad en el origen del semivariograma, que por definición en este punto debía ser nulo, se conoce como efecto pepita. Y se representa por C_0 .
- Meseta (*Sill*): Es el valor de $\gamma(h)$ para el cual con el aumento de h su valor permanece constante y se representa por C_t .
- Alcance (*Range*): Es la distancia para la cual las variables $Z(x)$ y $Z(x+h)$ son independientes, es decir, la distancia para la cual los valores de la variable dejan de estar correlacionados, o lo que es lo mismo, la distancia para la cual el semivariograma alcanza la meseta. Se representa por a .

El semivariograma ha sido ampliamente utilizado en el procesado digital de imágenes ya que es una herramienta potente para analizar tanto la correlación espacial de los datos radiométricos como para estudiar su variabilidad espacial y ha demostrado su utilidad para completar la información radiométrica con información sobre la estructura espacial de la imagen.

En estudios anteriores se ha podido comprobar que existen varias características del semivariograma que tienen relación con los elementos presentes en la imagen (Durrieu *et al.*, 2005). Por ejemplo, se ha establecido una relación entre el rango alcanzado en el semivariograma y el tamaño del patrón seguido por los objetos en la imagen (Woodcock *et al.*, 1988a, 1988b). También se ha comprobado que la pendiente del semivariograma en el origen está directamente relacionada con la variabilidad de los objetos en la escena (Ruiz *et al.*, 2007).

Varios trabajos se centran en el estudio del semivariograma con el fin de extraer características útiles de las imágenes de satélite: Chica-Olmo y Abarca-Hernández (2000) calculan el primer valor de dicha función en el vecindario de un píxel para caracterizar la textura presente en ese vecindario, completando la información radiométrica de la imagen. En cambio, Maillard (2003) utiliza todos los valores del semivariograma dando más importancia a los valores iniciales y menos a los siguientes. Otros autores (Durrieu *et al.*, 2005 o Jakomulska *et al.*, 2000) utilizan para clasificar los píxeles varios índices extraídos del semivariograma calculado sobre una ventana alrededor del píxel.

Un caso especial de semivariograma es el que se obtiene al calcularlo para un fenómeno con un comportamiento periódico o cíclico, que presenta un cierto patrón de repetición con la distancia. El semivariograma obtenido se conoce como semivariograma con efecto agujero (figura 5-8) y aporta información interesante del fenómeno estudiado (Pyrzc y Deutsch, 2003). Este caso es común observarlo en imágenes de la superficie terrestre. Siendo característico de zonas con un alto grado de intervención humana.




Figura 5-8. Semivariograma con efecto agujero

Pyrz y Deutsch (2003) interpretan el efecto agujero de distintos semivariogramas direccionales correspondientes a distintas configuraciones espaciales y realizan la siguiente clasificación de patrones espaciales, aplicada a la geología (figura 5-9):

- Agrupaciones regulares y ordenadas: La distancia al primer máximo indica la dimensión media de los grupos en la dirección en la que se realiza el semivariograma. La distancia al primer mínimo es la suma de la dimensión media de los grupos y de su distancia entre ellos. La distancia entre el primer máximo y el mínimo es la distancia media entre agrupaciones.
- Estratos regulares: La distancia al primer máximo indica el grosor medio de los estratos. La distancia al primer mínimo es el doble del grosor medio de los estratos.
- Agrupaciones irregulares y desordenadas: La distancia al primer máximo, indica de forma aproximada la dimensión máxima de los grupos en esa dirección.
- Agrupaciones irregulares y ordenadas: Las variaciones en el tamaño de los grupos y en la separación entre los mismos resulta en un suavizado de los máximos y la periodicidad del semivariograma se ve atenuada.
- Estratos irregulares: La periodicidad se aprecia si existe una repetición de las capas y los picos se suavizan en función del ancho de las distintas capas. En el caso de que no existan series que se repitan perfectamente, se produce la atenuación del semivariograma.

Cuando existe periodicidad en una dirección, el variograma excede la meseta. La meseta representa la varianza global. Esta relación permite la interpretación del variograma sobre la meseta.

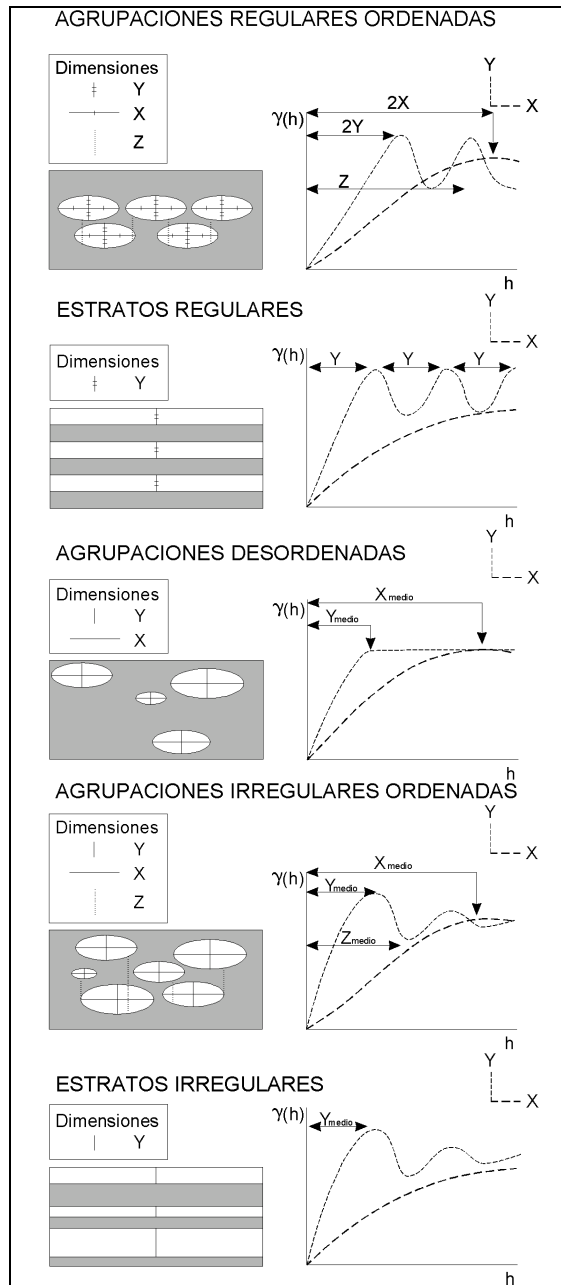


Figura 5-9. Interpretación del semivariograma con efecto agujero (adaptada de Pycz y Deutsch (2003))

5.2.3.1.4.- Pasos para la construcción del semivariograma experimental en una imagen

Sea $ND(x)$ el conjunto de niveles digitales en una imagen, donde x representa la posición de cada píxel en la imagen.

Dada una dirección α en la cual se desea calcular el semivariograma, una tolerancia angular $d\alpha$, una tolerancia lineal dh y la distancia máxima a que pueden estar alejados los segundos puntos del par con respecto a la línea que define la dirección de cálculo, conocida como ancho de banda, los pasos a seguir son:

1º Calcular la cantidad de pares de datos posibles:

$$NP = N(N - 1) / 2 \quad (5-18)$$

2º Para cada par, calcular la distancia euclídea entre las localizaciones correspondientes de los píxeles:

$$d_i = \sqrt{(C_1 - C_2)^2 + (F_1 - F_2)^2} \quad i = 1, \dots, NP \quad (5-19)$$

Almacenando para cada i :

$P1$: Número del primer píxel del par.

$P2$: Número del segundo píxel del par

d : distancia entre los dos píxeles del par

α' : ángulo que indica la dirección formada por los dos píxeles del par

3º Ordenar ascendentemente el grupo de datos anteriores por la distancia.

4º Determinar la amplitud máxima del semivariograma L_{max} .

5º Fijar una distancia h como incremento del semivariograma.

6º Calcular la expresión del semivariograma para todos los pares almacenados en el segundo paso que cumplan las condiciones siguientes:

- La distancia d debe estar comprendida entre $h-dh$ $h-dh$ y $h+dh$.

- El ángulo α' debe estar comprendido entre $\alpha - d\alpha$ y $\alpha + d\alpha$.

- La distancia entre el segundo píxel del par y la línea que pasa por el primer punto en la dirección α no supere el ancho de banda.

El valor obtenido del semivariograma para todos los pares de píxeles que cumplen las condiciones a, b y c, corresponde al valor de $\gamma(h)$ para el incremento h actual.

7º Incrementar la distancia h en su propio valor, es decir, el nuevo h será el próximo múltiplo del h inicial. Si el nuevo valor de h no supera L_{max} regresar al paso 6º. De lo contrario, continuar al próximo paso.

8º Al finalizar el paso anterior, se debe disponer de un valor de $\gamma(h)$ calculado para cada valor de h estudiado. Estos datos se representan en un gráfico, en el cual, en la abscisa se representan los valores de h y en la ordenada los de $\gamma(h)$. Obteniendo así el semivariograma experimental para una dirección, incremento y tolerancias definidas.

El tiempo de procesado del semivariograma omnidireccional de una parcela es considerable dado el volumen de operaciones a realizar. A fin de conseguir una reducción del tiempo de procesado, Balaguer *et al.* (en prensa) calculan el semivariograma en 6 direcciones separadas 30º (de 0º a 150º) y obtienen el semivariograma omnidireccional como la media de los 6 semivariogramas direccionales. En los ensayos realizados se comprobó que esta simplificación en el cálculo del semivariograma omnidireccional supone una reducción significativa en el tiempo de procesado sin afectar de forma notable al resultado obtenido.

La amplitud máxima fijada para el cálculo del semivariograma se estableció en 25 píxeles, distancia suficiente para detectar como mínimo dos alineaciones de árboles en los cultivos con los marcos de plantación de mayores dimensiones. La banda utilizada para el cálculo del semivariograma es la del infrarrojo por la mayor respuesta de la vegetación.

5.2.3.1.5.- Aplicación del semivariograma a la determinación de los marcos de plantación.

Un marco de plantación regular en una parcela agrícola tiene siempre, al menos, una dirección principal, siendo frecuente la existencia de dos direcciones principales y ortogonales entre sí en el caso de marcos rectangulares, así como tres direcciones principales formando ángulos de 120º en el caso de plantaciones al tresbolillo.

El cálculo del semivariograma omnidireccional permite identificar claramente la regularidad global existente en la parcela, independientemente de la dirección que sigan los árboles en la misma. Su efectividad es proporcional a la regularidad existente en la parcela; obteniéndose semivariogramas cíclicos para las parcelas regulares y aumentando la atenuación del mismo al aumentar la irregularidad del marco de plantación.

La distancia en la separación de los árboles es un factor condicionante en la aplicación de esta metodología ya que si la separación es mayor que el rango de distancias en las que se calcula el semivariograma, el marco de plantación no quedaría bien definido en el semivariograma. Por ello, es necesario calcular el semivariograma con una distancia superior a la que existe entre dos árboles vecinos en la plantación. La distancia máxima de cálculo puede modificarse según la tipología de las parcelas, pero su aumento conlleva incrementos sustanciales en el tiempo de cálculo.

En la figura 5-10 se comparan los semivariogramas obtenidos para parcelas con distintos tipos de plantaciones. Los semivariogramas han sido suavizados mediante un filtro gaussiano unidimensional para eliminar las posibles irregularidades. De su análisis se puede comprobar cómo a las parcelas sin un marco de plantación regular (figura 5-10a), les corresponde un semivariograma que podría modelarse como un semivariograma esférico y que se estabiliza a una cierta distancia del origen.

En el caso de las parcelas con marcos de plantaciones regulares (figuras 5-10b, 5-10c y 5-10d) sus histogramas son cíclicos y se aprecia una correspondencia muy alta entre la posición del primer máximo y el tamaño medio de los árboles, así como entre la posición del primer mínimo y la distancia entre los árboles medida desde el centro de los mismos.

En el histograma de la parcela b se aprecian dos ciclos completos del semivariograma, mientras que en los de las parcelas c y d sólo hay un ciclo debido a la relación entre la distancia máxima a la que se calcula el semivariograma (25 píxeles) y las dimensiones de los marcos de plantación (20 y 24 píxeles).

Los semivariogramas direccionales extraen perfectamente la periodicidad en los niveles digitales correspondientes a árboles, pero presentan el inconveniente de necesitar conocer las direcciones principales de las alineaciones de árboles. Este dato es desconocido en los procesos iniciales del procesado e implicaría realizar un número elevado de iteraciones para cada parcela hasta determinar con precisión las direcciones principales. Lo que resultaría en un incremento elevado del tiempo de procesado.

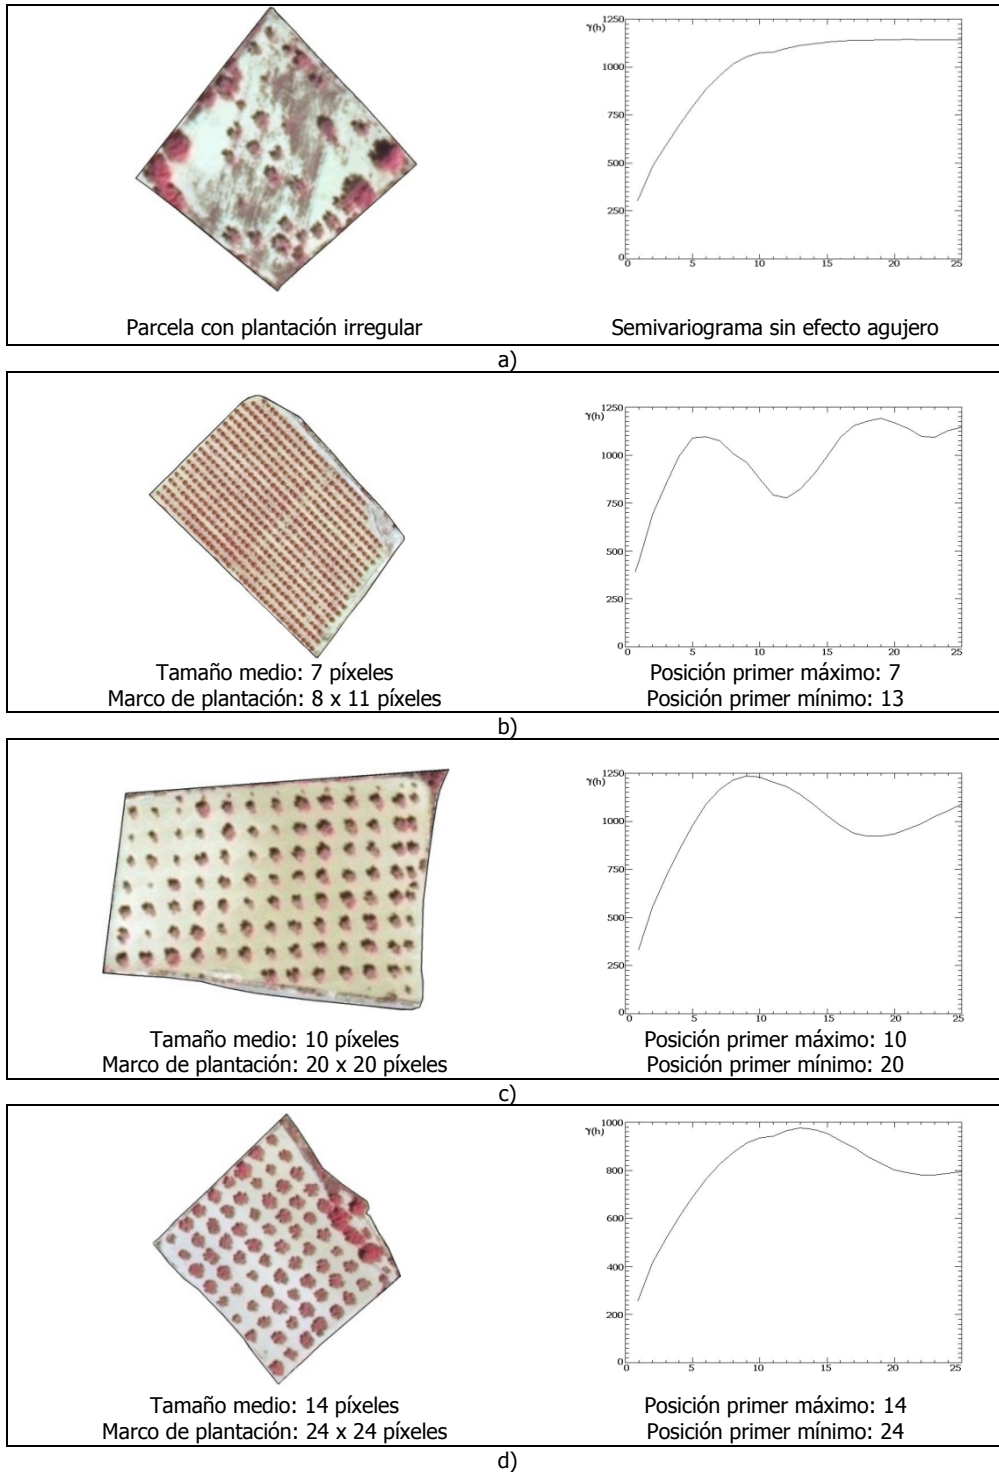


Figura 5-10. Parcelas agrícolas con sus correspondientes semivariogramas

La información extraída del semivariograma se va a utilizar en procesos posteriores en dos vertientes distintas:

1. Extracción de índices para la caracterización de la periodicidad existente en cada parcela que serán utilizados como características o variables en el proceso de clasificación de la parcela.
2. Identificación del tamaño medio de los árboles existentes para adaptar la ventana de tamaño variable utilizada en la localización de árboles mediante el método de búsqueda de máximos en la imagen de NDVI desarrollado en la sección 5.2.3.2.

5.2.3.1.5.1.- Extracción de índices

Para cada parcela se calcula un conjunto de parámetros descriptores del semivariograma que se añadirán al vector de características de cada parcela para su clasificación. Estos parámetros se han deducido del análisis realizado de los semivariogramas y se han completado con algunos de los propuestos por Durrieu *et al.* (2005). En las fórmulas siguientes h_i representa la i -ésima distancia, $\gamma(h_i)$ viene definido por la función (5-17), h_{max1} es la distancia a la que se da el primer máximo y max_1 es el número de orden de la distancia h_{max1} .

- Pendiente entre el primer máximo y el primer mínimo

Este valor es un claro indicador de la existencia de un comportamiento cíclico. Cuanto mayor sea este índice, más evidente es la periodicidad.

$$Pte_1 = \frac{\gamma(h_{max_1}) - \gamma(h_{min_1})}{h_{min_1} - h_{max_1}} \quad (5-20)$$

- Pendiente entre el segundo máximo y el primer mínimo

Similar al anterior, pero sólo se puede calcular en aquellos casos en los que existe un segundo máximo.

$$Pte_2 = \frac{\gamma(h_{max_2}) - \gamma(h_{min_1})}{h_{max_2} - h_{min_1}} \quad (5-21)$$




Figura 5-11. Puntos máximos y mínimos en el semivariograma

- Posición del primer máximo

Indica el tamaño medio de los árboles.

$$h_{max_1} \tag{5-22}$$

- Parámetro general 1

Como el variograma tiende a alcanzar la meseta cerca de la varianza, este índice describe la relación que existe entre la correlación espacial que existe a distancias cortas y a distancias largas.

$$Pg_1 = \frac{\text{Varianza}}{\gamma(h_1)} \tag{5-23}$$

- Parámetro general 4

Pendiente entre los dos primeros puntos.

$$Pg_4 = \frac{\gamma(h_2) - \gamma(h_1)}{h_2 - h_1} \tag{5-24}$$

- Parámetro general 5

Evalúa la segunda derivada en h_2 . Tanto este índice como el anterior representan la homogeneidad de las texturas en la imagen.

$$Pg_5 = \frac{\gamma(h_3) - 2\gamma(h_2) + \gamma(h_1)}{h^2} \quad (5-25)$$

- Parámetro primer máximo 4

Representa el incremento de la varianza entre h_1 y el primer máximo.

$$Ppm_4 = \gamma(h_1) - \frac{1}{max_i} \sum_{i=1}^{max_1} \gamma(h_i) \quad (5-26)$$

- Parámetro primer máximo 7

Determina la integral desde h_1 hasta h_{max} con la fórmula del trapecio compuesto.

$$Ppm_7 = \frac{h}{2} \left(\gamma(h_1) + 2 \left(\sum_{i=2}^{max_1-1} \gamma(h_i) \right) + \gamma(h_{max_1}) \right) \quad (5-27)$$

- Parámetro segundo máximo 3

Indica la atenuación del segundo máximo respecto al primero

$$Psm_3 = 1 - \left(\frac{\gamma(h_{max_2})}{\gamma(h_{max_1})} \right) \quad (5-28)$$

- Parámetro segundo máximo 7

Calcula la integral entre los dos máximos y la relaciona con la superficie del trapecio formado por las posiciones de los dos máximos y el eje de abscisas. De esta forma cuantifica el efecto agujero.

$$Psm_7 = \left(\frac{\frac{h}{2} \left(\gamma(h_{max_1}) + 2 \left(\sum_{i=max_1+1}^{max_2-1} \gamma(h_i) \right) + \gamma(h_{max_2}) \right)}{\frac{h}{2} (h_{max_2} - h_{max_1}) (\gamma(h_{max_1}) + \gamma(h_{max_2}))} \right) \quad (5-29)$$

5.2.3.2.-Identificación de árboles individuales

El tamaño de un marco de plantación es uno de los indicios claves utilizados por el fotointérprete para distinguir entre distintas tipologías de cultivos arbóreos. Por ello, una vez extraída la información relativa a la regularidad existente en la parcela de forma global a partir del análisis del semivariograma, se analiza más a fondo el marco de plantación para conseguir descriptores del mismo más concretos y que permitan detectar la regularidad en aquellos casos en los que el análisis del semivariograma no proporciona buenos resultados, como es el caso de las parcelas de plantones de cítricos.

El primer paso de este proceso es la localización de árboles individuales. Para ello, se ha empleado el método de Filtrado de Máximo Local utilizado por Wulder *et al.* (2000), Pouliot *et al.* (2002) o Nelson *et al.* (2005). Este método permite extraer la localización de árboles individuales en imágenes de alta resolución y está basado en la suposición de que la reflectancia es máxima en el centro del árbol y decrece hacia los límites de la copa del árbol. Los árboles se localizan desplazando una ventana sobre la imagen y seleccionando aquellos puntos que tienen un ND mayor al resto de sus vecinos en la ventana.

La posibilidad de identificar árboles con este método requiere que la imagen tenga un tamaño de píxel inferior que el tamaño medio de los árboles. Las imágenes utilizadas en este trabajo garantizan el cumplimiento de este requisito para todas las tipologías de árboles.

El tamaño de la ventana utilizada es fundamental en el grado de acierto de la búsqueda de árboles. Si la ventana seleccionada es demasiado pequeña se cometerán errores por exceso, ya que se identificarán árboles no existentes o bien se obtendrán varios máximos para una única copa. En cambio, si la ventana es demasiado grande, se incrementarán los errores por omisión y no todos los árboles existentes se identificarán.

Debido a las diferencias de tamaño existentes en los árboles a estudiar, desde 2 a más de 15 píxeles, se planteó la necesidad de no utilizar un tamaño fijo de ventana para todas las parcelas, sino que el tamaño de las ventanas se determinará a priori para cada parcela en estudio.

Los parámetros que determinan el tamaño de la ventana a utilizar son: el tamaño de los árboles en píxeles y las dimensiones del marco de plantación, también en píxeles. El tamaño de la ventana ha de ser siempre superior al tamaño de los árboles, para evitar los errores por exceso, pero ha de ser tal que no abarque el espacio de dos árboles consecutivos en un marco de plantación, para evitar los errores por omisión.

Esta información necesaria para la definición de la ventana de búsqueda es extraída del análisis del semivariograma. Tras varios análisis, se fijó un tamaño mínimo de

ventana de 9 píxeles para aquellas parcelas cuyo primer máximo del semivariograma se diera en la posición 9 o inferior y un tamaño máximo de ventana de 17 píxeles para las parcelas cuyo máximo fuera 17 o superior. Para las parcelas con máximos comprendidos entre 9 y 17 se selecciona el tamaño de ventana igual a la posición del máximo en el caso que sea un valor impar, o el valor impar superior en el caso de que la posición del máximo sea par.

Este filtrado de búsqueda del máximo local, se realiza sobre la banda del NDVI, eliminando los píxeles de las esquinas de la ventana de búsqueda para que su forma sea aproximadamente circular e imponiendo un umbral mínimo de NDVI a fin de evitar la selección de máximos locales en áreas sin vegetación.

En el caso de parcelas de plántones de cítricos, caracterizadas por suelos desnudos y árboles de reducidas dimensiones, la identificación de los árboles con el método expuesto sobre la banda del NDVI no da buenos resultados, ya que los plántones absorben en menor medida la radiación electromagnética correspondiente a la banda del rojo que los árboles adultos, con lo que el contraste entre los valores de la banda del infrarrojo y los del rojo es menor y por lo tanto, los valores de NDVI en los árboles jóvenes son muy similares a los obtenidos en el suelo desnudo. Por esto, se seleccionan las localizaciones de los árboles con el mismo método pero buscando los píxeles con un nivel digital mínimo en la banda del rojo, obteniéndose resultados satisfactorios.

En esta tipología de parcelas se utilizó un tamaño fijo de ventana para la búsqueda del mínimo de 7 píxeles sin utilizar los píxeles esquina de la ventana.

Para determinar las parcelas en las que utilizar cada una de las dos metodologías expuestas, búsqueda del máximo en la banda de NDVI o búsqueda del mínimo en la banda del rojo, se determina de forma empírica un umbral del valor medio de NDVI para toda la parcela, de tal forma que las parcelas con un NDVI global superior a este umbral se procesan por el primer método mientras que el resto se procesan por el segundo método. En las figuras 5-12 y 5-13 se muestra el resultado de aplicar ambos métodos en la detección de árboles.

La iluminación de la escena tiene una gran importancia en la identificación de la posición de los máximos locales, desplazándolos de la posición real en el centro del árbol. Este desplazamiento se da por igual en todos los puntos localizados, con lo que no supone un problema grave, ya que varía ligeramente la posición absoluta de los árboles localizados, pero no la posición relativa entre ellos.

Como resultado, se obtiene una imagen binaria donde los píxeles con nivel digital igual a 1 corresponden a las localizaciones de los árboles.




Figura 5-12. Localización de plántones mediante la búsqueda de mínimos locales




Figura 5-13. Localización de árboles adultos mediante la búsqueda de máximos locales

5.2.3.3.- Identificación de marcos de plantación mediante la transformada de Hough

5.2.3.3.1.- Introducción

El marco de plantación de los cultivos, entendido como la separación entre las alineaciones de plantas y la separación entre las plantas de una misma alineación, es una característica fundamental para la correcta fotointerpretación de las distintas tipologías de cultivos arbóreos y vitivinícolas. En este apartado se propone un método para la extracción de forma automática de los marcos de plantación utilizados, de forma que sus propiedades formen parte de las características descriptivas de la parcela y puedan ser empleadas en el proceso de clasificación de las parcelas.

El dato de partida en este método es la imagen binaria de localización de árboles para cada parcela, donde cada árbol viene representado por un píxel con el valor 1, obtenida mediante el método de localización de máximos o mínimos expuesto en el apartado anterior.

5.2.3.3.2.- La transformada de Hough

La transformada de Hough es una técnica utilizada en el tratamiento de imágenes para localizar curvas dentro de una imagen que puedan ser parametrizadas como líneas rectas, polinomios o círculos.

El principio básico de la transformada de Hough es que existe un infinito número de rectas que pasan por un punto, cada una de ellas con diferente orientación. El propósito de la transformación es determinar cuáles de esas teóricas líneas pasan por más puntos en la imagen, es decir, cuáles son las líneas que mejor se ajustan a los datos de la imagen.

En el estudio de los marcos de plantación de cultivos arbóreos de los ensayos realizados en esta tesis se ha empleado para determinar las direcciones principales que siguen los árboles frutales, así como la separación entre los mismos. Para ello se ha partido de una imagen binaria donde la posición de cada árbol está representada por un punto. Para cada par de puntos se ha determinado la ecuación de la recta que definen.

La **ecuación de la recta definida por dos puntos** de los que se conocen sus coordenadas cartesianas, coordenadas columna y fila, en nuestro caso, es:

$$\frac{x - x_1}{x_2 - x_1} = \frac{y - y_1}{y_2 - y_1} \quad (5-30)$$

Operando obtendríamos:

$$x(y_2 - y_1) + y(x_1 - x_2) + x_2y_1 - x_1y_2 = 0 \quad (5-31)$$

La **ecuación general de la recta** es:

$$Ax + By + C = 0 \quad (5-32)$$

donde A, B y C son números reales y A y B no son simultáneamente nulos.

De las dos últimas ecuaciones se deduce que:

$$A = y_2 - y_1 \quad B = x_1 - x_2 \quad C = x_2y_1 - x_1y_2. \quad (5-33)$$

La **ecuación normal de la recta** es:

$$x \cos \theta + y \sin \theta = \rho \quad (5-34)$$

donde ρ es la longitud del segmento normal a la recta que pasa por el origen de coordenadas y θ es el ángulo formado por este segmento y el eje de abscisas (figura 5-14).

El ángulo θ tiene un valor comprendido entre 0 y 180° , mientras que el signo del valor ρ coincide con el signo de la coordenada y del punto intercepto de la recta con el eje de ordenadas.

Se han de considerar dos posibilidades en la obtención de la ecuación normal de una recta a partir de su forma general: $B = 0$ ó $B \neq 0$.

Caso 1: $B \neq 0$

Sin pérdida de generalidad se puede suponer que $B > 0$, ya que si el coeficiente de y fuera negativo, bastaría con multiplicar toda la ecuación (5-32) por -1 .

La razón para suponer que $B > 0$, se debe al hecho de que el coeficiente de y en la forma normal es positivo, ya que el seno de un ángulo entre 0° y 180° es positivo.




Figura 5-14. Parámetros de la ecuación normal de la recta

El primer paso es multiplicar la ecuación (5-32) por una constante apropiada k de tal forma que la ecuación

$$kAx + kBy + kC = 0 \quad (5-35)$$

coincida con la ecuación (5-34).

Entonces $kA = \cos\theta$, $kB = \sin\theta$ y $kC = -\rho$

Así que $k^2A^2 + k^2B^2 = 1$, de donde:

$$k = \frac{1}{\sqrt{A^2 + B^2}} \quad (5-36)$$

Sustituyendo el valor de k obtenido en (5-35), se obtienen los términos de la forma normal en función de los términos de la forma general:

$$\cos\theta = \frac{A}{\sqrt{A^2 + B^2}}, \quad \sin\theta = \frac{B}{\sqrt{A^2 + B^2}} \quad \text{y} \quad \rho = \frac{-C}{\sqrt{A^2 + B^2}} \quad (5-37)$$

Caso 2: $B = 0$

En este caso, la ecuación (5-32) se transforma en $Ax + C = 0$, de donde $x + A/C = 0$ y esta última ecuación puede identificarse con la forma normal $x - \rho = 0$ que corresponde a una recta paralela al eje y .

Planteando la ecuación normal para cada punto en la imagen y variando el valor de θ se obtendrán los parámetros de las ecuaciones del haz de rectas que pasan por el punto analizado.




Figura 5-15. Representación de un punto en el dominio de Hough

Realizando este proceso para todos los puntos en la imagen, el punto de intersección de dos curvas en el espacio de Hough, corresponde a los parámetros ρ y θ de la recta que une los dos puntos.




Figura 5-16. Representación de una recta en el dominio imagen a) y en el dominio de Hough b)

El espacio paramétrico de Hough se representa por una estructura rectangular de celdas, llamado espacio acumulador y cuyos elementos son las celdas acumuladoras $A(\rho_i, \theta_j)$. Los valores de θ están comprendidos entre 0 y 180°, mientras que los valores de ρ

pueden variar entre $-\sqrt{C^2 + F^2}$ y $\sqrt{C^2 + F^2}$, siendo C y F el número de columnas y filas de la imagen original.

Una vez realizada la transformada de Hough, las celdas acumuladoras con una magnitud superior a un cierto umbral pueden ser consideradas como posibles rectas.

Aplicando una umbralización a la imagen del espacio acumulador, se obtienen los parámetros de las rectas formadas por un número de puntos superior al umbral establecido.

Marchant (1996) utiliza la transformada de Hough en un sistema de seguimiento automático de alineaciones de cultivos por parte de un robot y define el espacio acumulador de Hough formado por los parámetros de la ecuación simplificada de la recta (5-38), donde a es la pendiente y b es la ordenada en el origen de la recta. Un problema que surge al utilizar esta ecuación es que tanto la pendiente como la ordenada en el origen tienden a infinito cuando la línea se acerca a la vertical (González y Woods, 1996), por lo que resulta más adecuada el empleo de la ecuación normal de la recta (5-34).

$$y = ax + b \quad (5-38)$$

5.2.3.3.- Descripción del algoritmo

Los pasos a seguir para detectar rectas a partir de una nube de puntos son los siguientes:

1. Discretizar los parámetros ρ y θ y crear la matriz de contadores $A(\rho, \theta)$ inicializada en 0.
2. Para cada píxel $P(x, y)$ con $ND=1$
 - Hacer $\rho = x \cos \theta + y \sin \theta$
 - Hallar el valor de ρ más cercano al ρ calculado.
 - Incrementar la matriz de contadores $A(\rho, \theta)$
3. Encontrar los máximos que sean mayores a un umbral
4. Con los parámetros ρ y θ de los máximos se obtienen los parámetros de las rectas localizadas en forma polar.

5.2.3.3.4.- Aplicación de la transformada de Hough en el reconocimiento de marcos de plantación

En el caso de parcelas que no presenten un marco de plantación definido, la nube de puntos no sigue ningún patrón geométrico y la transformada de Hough no muestra ninguna dirección predominante sobre el resto (figura 5-17).




Figura 5-17. Nube de puntos en el espacio imagen y su representación en el dominio de Hough

En cambio, en las parcelas con un patrón de plantación bien definido, la transformada permite obtener las direcciones principales en la que están situados los árboles (figura 5-18):




Figura 5-18. Nube de puntos en el espacio imagen y su representación en el dominio de Hough

La imagen de la transformada de Hough umbralizada muestra los parámetros de las rectas definidas por un número mayor de puntos que el umbral establecido.

Para determinar la dirección predominante entre las rectas existentes, se determina el máximo de las frecuencias de coincidencias para todas las direcciones. Para ello, se suaviza el histograma de frecuencias de coincidencias de las orientaciones de las

rectas localizadas y se selecciona la dirección con una frecuencia mayor.




Figura 5-19. Histograma de frecuencias correspondiente a las 180 direcciones posibles.

Una vez obtenida la dirección principal de las alineaciones existentes, se puede determinar cuál es la segunda dirección más frecuente, analizando el mismo histograma (figura 5-19) y seleccionando la segunda dirección más frecuente entre todas las rectas detectadas. En la figura 5-19, se observa que la dirección principal es la que tiene un ángulo θ igual a 141° , mientras que la dirección secundaria corresponde al ángulo θ igual a 45° .




Figura 5-20. Detección de alineaciones en una parcela

En los estudios realizados se ha comprobado que la forma de la parcela influye significativamente en la identificación de las direcciones principales, ya que mientras en las parcelas aproximadamente cuadradas la dirección principal y la secundaria se suelen detectar correctamente, en las parcelas estrechas la segunda dirección más frecuente puede coincidir con una diagonal al marco de plantación. Por esto, en la selección de la segunda dirección se impondrán dos condiciones: la segunda dirección será una de las direcciones más frecuentes y además será aproximadamente perpendicular a la dirección principal.

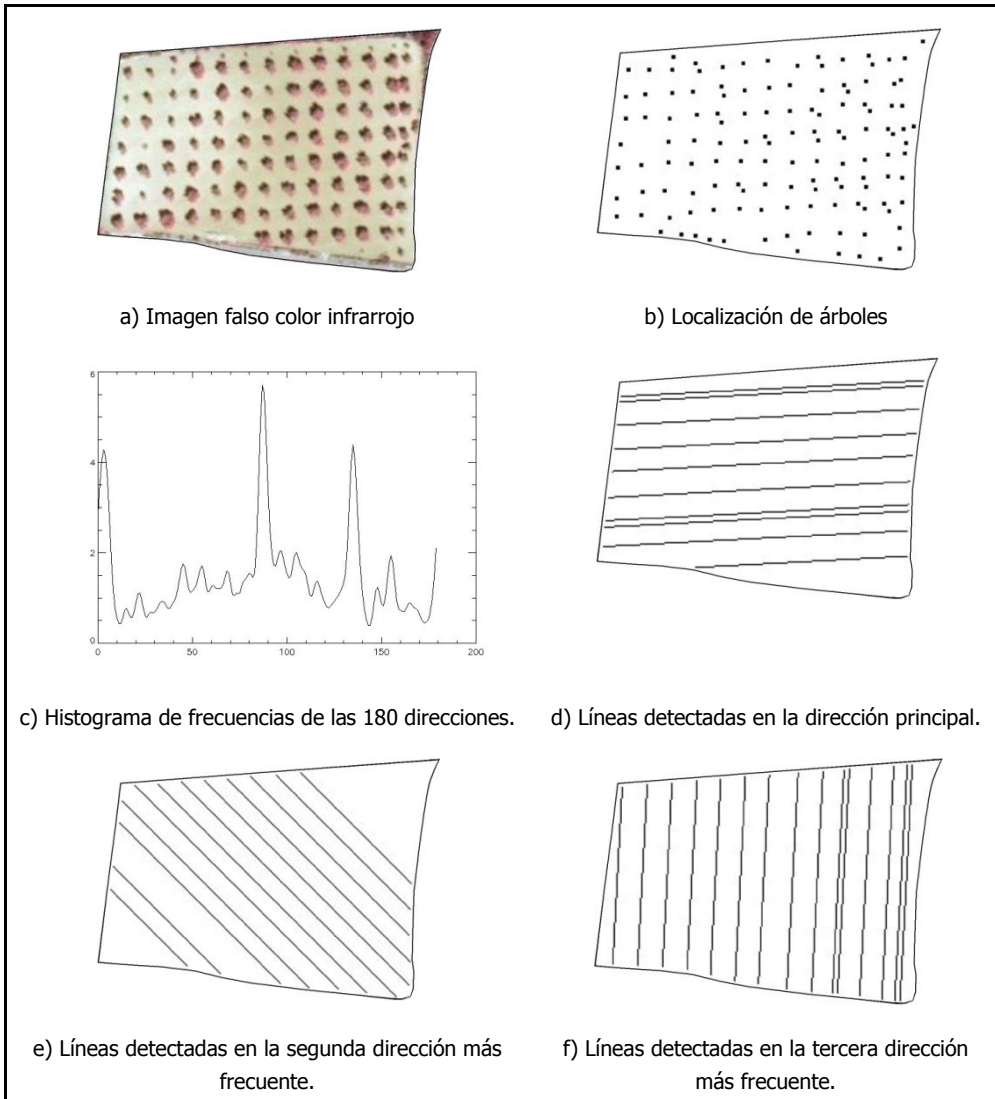


Figura 5-21. Detección de líneas en una parcela

En el ejemplo mostrado en las figuras 5-18 y 5-20 se aprecia que las dos direcciones más frecuentes son aproximadamente ortogonales (141° y 45°), por lo que la elección de las direcciones principal y secundaria es inmediata. Sin embargo, en la parcela mostrada en la figura 5-21, se aprecia que las tres direcciones más frecuentes son, 87° , 135° y 3° (figura 5-21c). La dirección seleccionada como dirección secundaria es 3° , ya que aun no siendo la segunda dirección más frecuente es aproximadamente ortogonal a la dirección principal (figuras 5-21e y 5-21f).

Para la obtención de las dimensiones del marco de plantación se parte de la suposición de que las direcciones del marco de plantación son aproximadamente ortogonales, lo cual ocurre en las plantaciones que siguen un patrón cuadrado o rectangular. Restando los valores de ρ correspondientes a las intersecciones de curvas en la dirección principal, obtendríamos la separación de los árboles en la dirección secundaria. Del mismo modo, de la sustracción de los valores consecutivos de ρ para las rectas en la dirección secundaria, obtendríamos la dimensión del marco de plantación en la dirección principal. En la figura 5-22 se muestra una parcela con las distancias existentes entre los árboles medidas a lo largo de la dirección principal (8 píxeles) y de la dirección secundaria (12 píxeles). De la figura se desprende que la separación entre las líneas detectadas en la dirección principal, corresponde con la distancia existente entre los árboles medida a lo largo de la dirección secundaria. Del mismo modo, calculando la distancia existente entre las rectas detectadas en la dirección secundaria, se obtiene la separación entre los árboles medida en el sentido de la dirección principal.

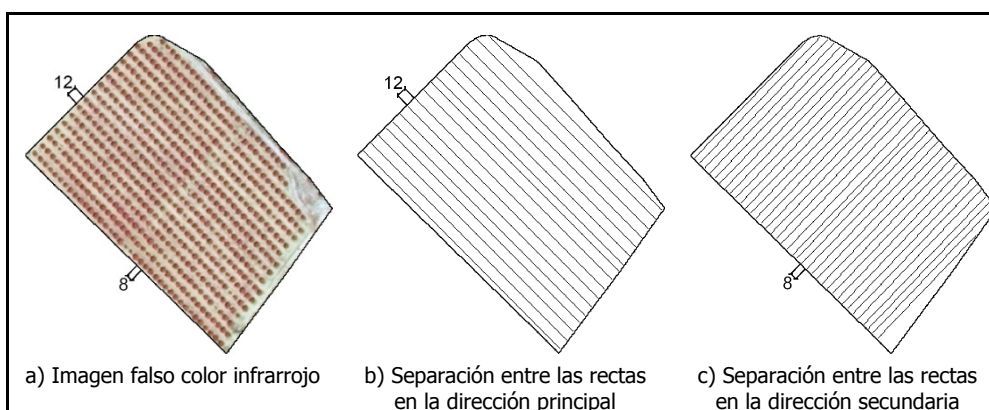


Figura 5-22. Separación entre árboles en un marco de plantación

Las distancias entre las distintas rectas localizadas en las dos direcciones estudiadas se obtienen directamente de la imagen de la transformada de Hough, ya que la distancia entre dos rectas paralelas es la diferencia de sus respectivos parámetros ρ (figura 5-23).




Figura 5-23. Obtención de distancias entre rectas paralelas

Una vez obtenidos los valores de separación entre cada par de rectas paralelas consecutivas, se selecciona la mediana de todas las distancias calculadas entre las rectas obtenidas, como valor más adecuado para caracterizar la distancia típica entre árboles en una determinada dirección.

Tras la determinación de las dos direcciones principales, se extraen una serie de características con el fin de describir el marco de plantación existente a fin de poder ser empleadas en la clasificación de la parcela. Las características calculadas para cada una de las dos direcciones principales son:

- Porcentaje de rectas con esa dirección: Indica la existencia de una dirección predominante entre los árboles.
- Media, moda y mediana de la separación entre las rectas: Estiman la separación entre las líneas de árboles y entre los árboles de una misma alineación. El valor medio suele ser menos preciso al estar más afectado por las imprecisiones de la detección mientras que la moda y la mediana caracterizan mejor las dimensiones del marco de plantación.
- Desviación típica de la separación entre las rectas: Indica el grado de regularidad del marco de plantación detectado.
- Porcentaje de árboles localizados en una dirección: Cuantifica la proporción de árboles localizados en cada dirección e indica el grado de ajuste de la dirección seleccionada a los árboles localizados.
- Porcentaje de árboles localizados en una dirección normalizado por el área de la parcela: Relaciona la proporción de árboles alineados en una dirección con la

superficie de la parcela a fin de hacer independiente este parámetro del tamaño de la parcela.

- Diferencia angular entre las dos direcciones principales: Indica sobre el grado de ortogonalidad de las dos direcciones principales.

5.2.4.- Segmentación de árboles

5.2.4.1.- Introducción

Los cultivos agrícolas se pueden clasificar en dos grandes grupos en función de su duración en el terreno. Por una parte los cultivos anuales, cuya distribución espacial abarca de forma homogénea toda la parcela de cultivo, como podrían ser los cultivos hortícolas, cereales, girasol, etc. Las parcelas correspondientes a este tipo de cultivos tienen una respuesta espectral mayoritariamente homogénea y las variaciones internas a la parcela estarían motivadas por diferencias en el estado de los cultivos causadas por factores como enfermedades, irrigación no homogénea o variaciones en la fecha de plantación. Un segundo grupo abarca a aquellos cultivos con una duración plurianual. Por el tamaño de la planta, estos cultivos necesitan un marco de plantación regular que garantice un espacio determinado entre las plantas para su correcto desarrollo a lo largo de los años. En esta categoría se incluyen los cultivos arbóreos, la vid, etc. En este caso, la reflectancia de la parcela no es homogénea, ya que se combina de una forma más evidente la respuesta del suelo con la de los árboles. La identificación de estos cultivos es más compleja al no poder considerarse la parcela como un objeto homogéneo, sino que se deben tener en cuenta los subobjetos que la componen.

Para la identificación de los cultivos arbóreos se ha diseñado una metodología que permite segmentar los árboles respecto al suelo de la parcela. Así, se establece una estructura jerárquica donde la clase a asignar al objeto de estudio, la parcela, se determina en función de la identificación de los subobjetos contenidos en la misma. Más allá del proceso de clasificación de la parcela, la segmentación de árboles tiene interés desde un punto de vista agrícola. Según los principios de la agricultura de precisión, la gestión agrícola debe cambiar la escala de observación del nivel de parcela al nivel de la planta. Por lo tanto, la identificación individual de las plantas es un aspecto que debe abordarse (Robbez-Masson y Foltete, 2005).

Las fases en las que está organizada la segmentación de árboles es la siguiente:

- 1) Preprocesado de la imagen
- 2) Clasificación no supervisada

- 3) Determinación de las clases correspondientes a árboles en la clasificación no supervisada
- 4) Caracterización de los árboles segmentados

5.2.4.2.- Preprocesado de imágenes

La segmentación automática de árboles en las imágenes empleadas está dificultada por varios factores:

- La variabilidad interna tanto de los objetos a segmentar como del fondo que rodea a los objetos.
- El hecho de que algunos de los árboles tengan un tamaño reducido frente a la resolución de la imagen; los árboles más jóvenes están representados por un número reducido de píxeles.
- La existencia de píxeles colindantes al objeto cuyo nivel digital es un valor de transición y resulta de la combinación tanto de la reflectancia del árbol como de la del suelo. Ello dificulta, incluso para un operador, la delineación del límite exacto de la copa de un árbol.

Estas características de la imagen original hacen necesaria una fase de preprocesamiento de la imagen, previa a la aplicación del algoritmo de segmentación. En este preprocesamiento se pretende homogeneizar los niveles digitales de los píxeles integrantes de un mismo objeto, ya sea suelo, árbol o sombras, al mismo tiempo que los bordes entre objetos se definan con mayor nitidez, evitando que los árboles representados por pocos píxeles se diluyan entre el suelo que los rodea.

El método de preprocesado empleado consiste en un filtrado de media ponderada, donde el peso correspondiente a cada uno de los píxeles vecinos es inversamente proporcional a la distancia espectral existente entre el píxel vecino y el píxel central de la ventana. Es decir, aquellos píxeles vecinos con niveles digitales similares al del píxel sobre el que se aplica el filtro, tendrán una influencia mayor en el valor resultante del píxel en la nueva imagen.

$$ND'_{i,j} = \frac{\sum_{p=-1}^1 \sum_{q=-1}^1 ND_{i+p,j+q} CF_{i+p,j+q}}{\sum_{p=-1}^1 \sum_{q=-1}^1 CF_{i+p,j+q}} \quad (5-39)$$

donde ND_{ij} indica el nivel digital original del píxel i,j ; ND'_{ij} es el nivel digital de salida para ese mismo píxel y CF es el coeficiente de filtraje correspondiente (Chuvienco, 2000)

Este coeficiente de filtraje se calcula como:

$$CF_{i-1,j-1} = 1 - a \cdot |ND_{i-1,j-1} - ND_{i,j}| \quad (5-40)$$

donde a es un coeficiente de ponderación de la diferencia entre el nivel digital del píxel central y los vecinos. Este coeficiente reduce la influencia de los píxeles vecinos en el nivel digital del píxel central en la imagen de salida. Esta reducción será mayor cuanto mayor sea la diferencia entre el píxel central y cada uno de los píxeles vecinos.

Para cada ventana de filtrado, se determina la diferencia en valor absoluto entre cada uno de los píxeles y el píxel central. Posteriormente, estos valores se normalizan dividiendo por el sumatorio de las diferencias de los píxeles de la ventana.

En la figura siguiente se muestra el proceso para obtener los coeficientes de filtrado para una ventana de 3x3, variando el valor del coeficiente de ponderación a .

| Imagen original | | | Diferencias absolutas | | | Diferencia absoluta $\frac{\text{Diferencia absoluta}}{\sum \text{Diferencias absolutas}}$ | | |
|--|-------|-------|-----------------------|-------|-------|---|-------|--------|
| 18 | 18 | 6 | 2 | 2 | 14 | 0.037 | 0.037 | 0.259 |
| 18 | 20 | 4 | 2 | 0 | 16 | 0.037 | 0 | 0.296 |
| 18 | 18 | 6 | 2 | 2 | 14 | 0.037 | 0.037 | 0.259 |
| Coeficientes de filtraje calculados con distintos coeficientes de ponderación: | | | | | | | | |
| a=1 | | | a=3 | | | a=6 | | |
| 0.963 | 0.963 | 0.741 | 0.889 | 0.889 | 0.222 | 0.778 | 0.778 | -0.555 |
| 0.963 | 1 | 0.704 | 0.889 | 1 | 0.111 | 0.778 | 1 | -0.777 |
| 0.963 | 0.963 | 0.741 | 0.889 | 0.889 | 0.222 | 0.778 | 0.778 | -0.555 |

Figura 5-24. Proceso de obtención de los coeficientes de filtrado

En el caso de que los coeficientes de filtraje sean negativos, se sustituyen por el valor 0.

Al aplicar el filtro, como se indica en la ecuación (5-39), el sumatorio de los productos de los niveles digitales por sus correspondientes coeficientes de filtraje se divide por el sumatorio de éstos.

En la tabla siguiente se muestran los resultados correspondientes a la aplicación de los filtros presentados en la figura anterior sobre el píxel situado en el centro del fragmento de imagen con nivel digital igual a 20.

| ND _{i,j} original | ND' _{i,j} para $a = 1$ | ND' _{i,j} para $a = 3$ | ND' _{i,j} para $a = 6$ |
|----------------------------|---------------------------------|---------------------------------|---------------------------------|
| 20 | 14.8 | 17.2 | 18.4 |

Tabla 5-1. Resultados del filtrado con distintos parámetros de ponderación

Cuando el parámetro a es igual a la unidad, el resultado es un valor cercano al que se obtendría con un filtro de media. Es decir, los coeficientes de ponderación son próximos a la unidad para todos los píxeles vecinos, con lo que se produce un promediado de los niveles digitales de los píxeles vecinos aunque la diferencia de éstos respecto al píxel central sea significativa; reduciéndose la nitidez en los bordes.

En caso de utilizar un parámetro mayor a la unidad, el efecto producido por el filtro es de homogeneización de los objetos a segmentar además de aumentar el realce de los bordes entre los objetos y el fondo. Los píxeles de transición entre el objeto y el fondo son los más afectados por la aplicación del filtro y sus niveles digitales en la imagen de salida serán similares a los de los píxeles de objeto o de fondo en función de a los que fueran más similares en la imagen original.

La aplicación de este método de filtrado de forma iterativa facilita en gran medida la aplicación de cualquier técnica de segmentación.

En la figura siguiente se muestra el resultado de aplicar iterativamente el filtrado propuesto, consiguiendo el objetivo buscado de homogeneización interna de los objetos y del fondo y de eliminación de los píxeles de transición entre los mismos.




Figura 5-25. Aplicación iterativa del método de filtrado ponderado

En la figura 5-26 se comparan, sobre un perfil espectral de la banda infrarrojo a lo largo de la línea señalada en la figura 5-25a, los niveles digitales de las imágenes de la figura anterior.

La aplicación del filtrado iterativamente consigue aumentar la pendiente entre las zonas con mayor respuesta en el infrarrojo, correspondientes a las zonas de suelo, y las zonas con menor ND, pertenecientes a los árboles. Esta mayor verticalidad en las zonas de

transición del perfil corresponde a una mayor nitidez en los bordes, consiguiéndose la eliminación de los píxeles de transición.




Figura 5-26. Perfil espectral sobre la imagen original y las imágenes filtradas

A continuación, se muestra otro ejemplo de la aplicación del filtrado proporcional a la distancia espectral, sobre una imagen de árboles jóvenes.




Figura 5-27. Aplicación iterativa del método de filtrado ponderado

Completando la comparación visual de la aplicación del filtrado, se muestra en la figura 5-28 el perfil espectral realizado sobre la banda infrarrojo, a lo largo de la recta dibujada en la figura 5-27a. Al igual que en el ejemplo anterior, se aprecia cómo la aplicación sucesiva del método de filtrado produce transiciones más bruscas entre los árboles y el suelo ya que aumenta la verticalidad de las curvas en las zonas de cambios de cobertura, al mismo tiempo, se produce una homogeneización en el interior de las coberturas representada por una mayor horizontalidad de las curvas.




Figura 5-28. Perfil espectral sobre la imagen original y las imágenes filtradas

5.2.4.3.- Clasificación no supervisada

Para obtener agrupaciones de píxeles con características espectrales homogéneas, se propone una clasificación no supervisada con el algoritmo K medias. El algoritmo K medias es un método de agrupamiento por vecindad en el que se parte de un conjunto de datos a agrupar en un número determinado de subconjuntos. Es el método más popular de los métodos de agrupamiento denominados *por partición*, en contraposición a los métodos jerárquicos (Hernández Orallo *et al.*, 2004).

La idea básica del algoritmo K medias consiste en situar los centros de los subconjuntos en el espacio de características, de forma que los datos pertenecientes a cada subconjunto, por ser mínima su distancia al centro del mismo, tengan características similares.

Una vez situados los centros de los subconjuntos correctamente, cada ejemplo nuevo es comparado con éstos y asociado a aquél que sea más próximo, en los términos de una distancia previamente elegida. Normalmente, se emplea la distancia euclídea.

Los subconjuntos se definen minimizando la suma de las distancias cuadráticas entre cada vector de características de entrada y el centro de su correspondiente clase. El proceso comienza con la selección arbitraria de una partición de forma que cada clase disponga al menos de un ejemplo. Los centros de cada clase se calculan como la media de los ejemplos pertenecientes a esa clase. A medida que el algoritmo se va ejecutando, algunos ejemplos cambian de una clase a otra, recalculándose de nuevo la posición del centro de la clase, lo que implica un desplazamiento del mismo.

El procedimiento es el siguiente:

- Para cada ejemplo se calcula las distancias a todos los centros y se asigna al centro más cercano.
- Se desplaza la posición del centro a la posición del centro de masas de su conjunto de ejemplos asignados.
- Se repite el proceso hasta que ya no varíe la posición de los centros de las clases.

Mediante este algoritmo el espacio de ejemplos de entrada se divide en k clases o regiones y el prototipo de cada clase estará en el centro de la misma. Dichos centros se seleccionan de modo que minimicen las distancias cuadráticas euclídeas entre los patrones de entrada y el centro más cercano, es decir, minimizando el valor de J :

$$J = \sum_{i=1}^k \sum_{n=1}^m M_{i,n} d(x_n - A_i)^2 \quad (5-41)$$

donde m es el conjunto de ejemplos, d es la distancia euclídea, x_n es el ejemplo de entrada n , A_i es el centro de la clase i , y $M_{i,n}$ es la función de pertenencia del ejemplo n a la región i de forma que vale 1 si el centro A_i es el más cercano al ejemplo x_n y 0 en caso contrario.

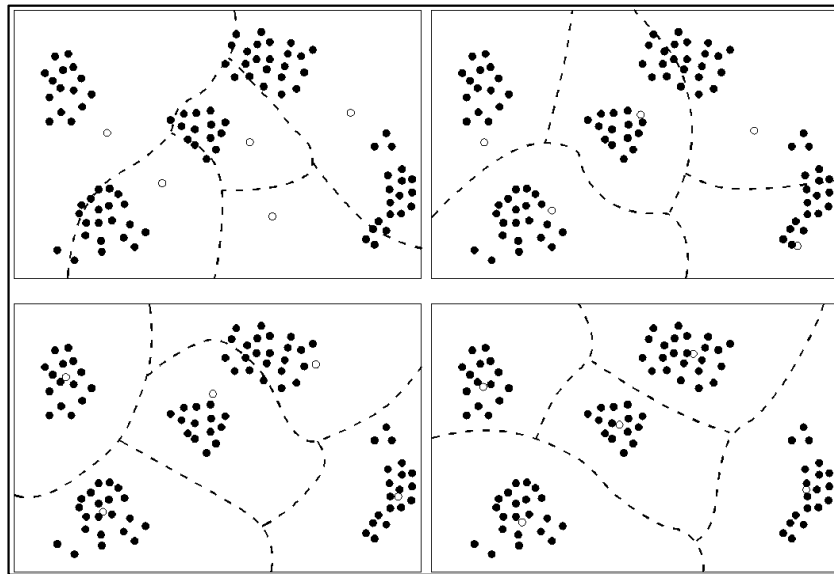


Figura 5-29. Ejemplo de evolución de los prototipos u grupos formados con el algoritmo K medias (Hernández Orallo *et al.*, 2004)

En la utilización de este algoritmo se debe fijar *a priori* el número de categorías a generar. En nuestro caso, dada la variabilidad espectral existente en el interior de las parcelas, y dado que se desconoce el número de categorías adecuado a cada parcela, se elige un número elevado (10 categorías), ya que es preferible una excesiva fragmentación a que aparezcan clases heterogéneas espectralmente.

El algoritmo K medias se aplica de forma iterativa hasta que se alcanza el número máximo de iteraciones o bien, se estabiliza la posición de los prototipos.




Figura 5-30. Ejemplos de la clasificación por el método K medias

5.2.4.4.- Asignación de significado a las clases generadas en la clasificación no supervisada

Una vez realizada la clasificación no supervisada se procede a seleccionar aquellas clases cuyas características espectrales pueden corresponder a árboles de distintas especies. Para ello, se selecciona de forma automática en la imagen un conjunto de píxeles que representen a los árboles y que van a ser empleados para obtener los parámetros estadísticos que describan el comportamiento espectral de los mismos en cada una de las bandas disponibles. La selección automática de píxeles correspondientes a árboles en cada parcela está dificultada por la variedad en las tipologías de árboles existentes en el área de estudio. Así por ejemplo, la utilización de una umbralización de la imagen de NDVI no da

buenos resultados ya que los píxeles correspondientes a sombras tienen un valor superior en este índice a los propios árboles. Por otra parte, los árboles jóvenes tienen un valor de NDVI inferior al suelo ocupado por vegetación espontánea de tipo herbáceo. La metodología propuesta está basada en la eliminación de sombras y en la selección de aquellos píxeles con un valor mayor en la imagen resultante de filtrar la imagen de NDVI con un filtro laplaciano.

- **Eliminación de sombras:** Las sombras proyectadas por los árboles de mayor tamaño se caracterizan por tener niveles digitales bajos en las tres bandas pero con la particularidad de que las diferencias entre los niveles digitales en la banda del IR y en la banda del rojo son mayores que en los píxeles correspondientes a vegetación vigorosa, por lo que sus valores en el índice NDVI suelen ser los más altos en las parcelas analizadas. Para eliminar de la selección de píxeles de árbol los correspondientes a sombras se aplicó una umbralización de la banda I en el espacio de color HSI.

El espacio de color HSI (tono, saturación e intensidad) debe su utilidad a dos hechos fundamentales. Por un lado la componente de intensidad, I, se puede separar de la información de color en la imagen y por otro lado, las componentes de tono y saturación (H y S), están íntimamente relacionadas con el modo en que los humanos perciben el color. Estas características hacen del modelo HSI una herramienta ideal para el desarrollo de algoritmos de procesamiento de imágenes basados en alguna de las sensaciones de color del sistema visual humano (Pajares y De la Cruz, 2001). Las componentes de color del modelo HSI (tono y saturación) están definidas con respecto al triángulo de color mostrado en la figura 5-31(a): el punto W es la intersección de las medianas del triángulo; el tono (H) de un punto de color P es el ángulo del vector \overline{WP} con respecto al eje rojo. Por tanto $H=0^\circ$ corresponde al color rojo, $H=60^\circ$ al amarillo y así sucesivamente. La saturación S del punto de color P es el grado de dilución del color con blanco y es proporcional a la distancia de P al centro del triángulo. La intensidad se mide con respecto a una línea perpendicular al triángulo y pasando a través de su centro. Las intensidades a lo largo de esta línea progresan hacia el negro por debajo del triángulo y por encima hacia el blanco (figura 5-31b). Los valores que puede tomar el tono están comprendidos en el rango de 0° a 360° , mientras que los valores de saturación e intensidad están comprendidos en el intervalo de 0 a 1.

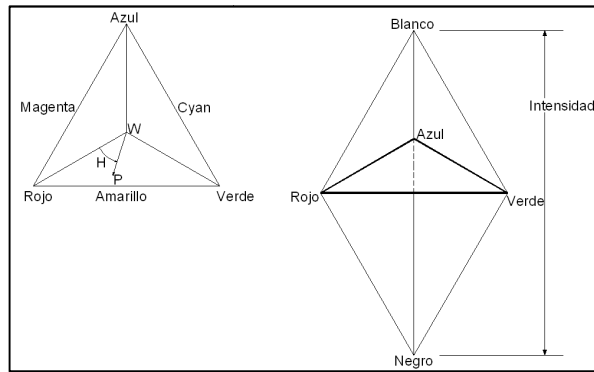


Figura 5-31. a) Triángulo de color HSI b) Color e intensidad en el modelo HSI (adaptada de Pajares y De la Cruz, 2001)

De forma empírica se estableció un umbral (0.30) para la imagen de intensidad, de forma que los píxeles con un valor inferior a este umbral son enmascarados y no son considerados en los procesos posteriores de selección de puntos correspondientes a árboles ni a suelo.




Figura 5-32. Detección de sombras

- **Selección de píxeles correspondientes a árboles y a suelo:** La extracción automática de píxeles representativos de los árboles existentes en la parcela y del suelo que los rodea, se realizó por medio de la aplicación de un filtro laplaciano sobre la banda correspondiente al índice NDVI. El laplaciano de una función bidimensional $f(x,y)$ es una derivada de segundo orden definida por:

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \quad (5-42)$$

En el dominio discreto, la aproximación más sencilla es calcular la diferencia de pendientes a lo largo de cada eje:

$$g(x,y) = (f(x,y) - f(x,y-1)) - (f(x,y+1) - f(x,y)) + (f(x,y) - f(x+1,y)) - (f(x-1,y) - f(x,y)) \quad (5-43)$$

Esta ecuación suele implementarse para su utilización en imágenes mediante la máscara de 3 x 3 siguiente:

| | | |
|----|----|----|
| 0 | -1 | 0 |
| -1 | 4 | -1 |
| 0 | -1 | 0 |

Figura 5-33. Máscara de filtro laplaciano

Como el laplaciano es una derivada, la suma de los coeficientes debe ser cero. Por lo tanto, la respuesta es cero siempre que el punto en cuestión y sus vecinos tengan el mismo valor. Su aplicación más general es en la localización de bordes utilizando sus propiedades de paso por cero.

En la figura 5-34 se muestra el efecto de aplicar un filtro laplaciano sobre una imagen binaria (a). En la imagen resultante (b) se representan en blanco los píxeles con un valor positivo que corresponden a aquellos píxeles que forman el contorno interior del objeto, en gris se representan los píxeles con valores negativos, que corresponden a los píxeles del fondo en contacto con el objeto, mientras que en negro se representan los píxeles con el valor 0 donde no se produce ningún cambio respecto a los vecinos.

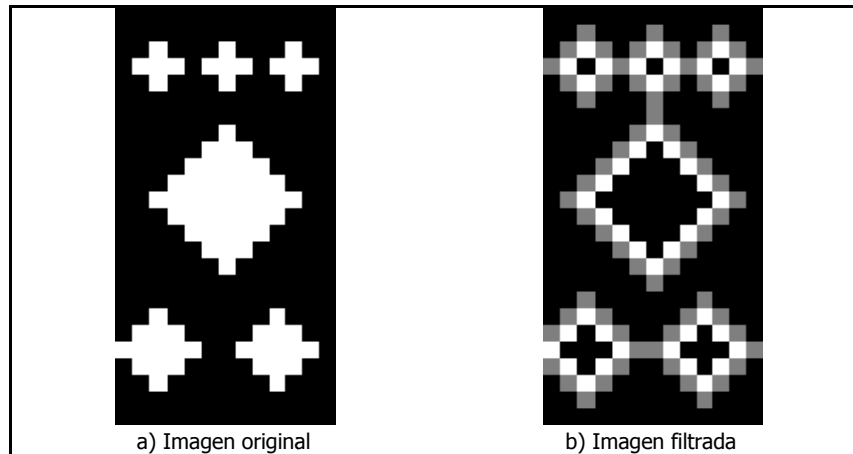


Figura 5-34. Aplicación del filtro laplaciano sobre una imagen binaria

Como paso previo a la aplicación del filtro laplaciano, se le aplica a la imagen de NDVI un filtro de paso bajo a fin de homogeneizarla y reducir el ruido que pueda tener.

Una vez aplicado el filtro laplaciano, aquellos píxeles con valores máximos son seleccionados como píxeles representativos de los árboles, mientras que los píxeles con valores mínimos son seleccionados como representantes del suelo.

De esta forma, la selección de los píxeles de *árbol* no se realiza mediante una umbralización de la imagen de NDVI como podría pensarse en un principio, sino que se localizan los puntos con mayor incremento del índice respecto al resto. Fijar un único umbral del NDVI para segmentar de forma automática los árboles resulta imposible para el conjunto de las parcelas, dada la gran variedad en las distintas tipologías de vegetación existentes, ya que el valor del índice en los árboles de una parcela puede llegar a ser inferior al valor que tiene la vegetación herbácea entre los árboles de otra parcela.

Esta primera selección de píxeles representativos de *árbol* y de *suelo* es filtrada por medio de condiciones extraídas de los parámetros estadísticos calculados para estos conjuntos de puntos. Así por ejemplo, ningún punto de *árbol* puede tener un valor del índice NDVI inferior al valor medio de este índice para los píxeles de *suelo*, por tanto, los píxeles seleccionados como píxeles de *árbol* que no cumplen esta condición son eliminados del conjunto inicial. Esta misma condición se aplica de forma inversa a los píxeles *suelo*.




Figura 5-35. Selección automática de píxeles de *árbol* y de *suelo*




Figura 5-36. Selección automática de píxeles de *árbol* y de *suelo*

- **Determinación de las clases correspondientes a árboles**

Una vez obtenidos dos conjuntos de píxeles de *árboles* y de *suelo*, que permiten describir los objetos en cada imagen, se calcula la media y la desviación típica de ambos conjuntos de datos por separado en las tres bandas de la imagen disponible.

La determinación en cada banda del umbral que delimite el intervalo de niveles digitales correspondiente a las clases de *árbol*, tiene lugar calculando la intersección de las curvas gaussianas correspondientes a los puntos *árbol* y a los puntos de *suelo*.

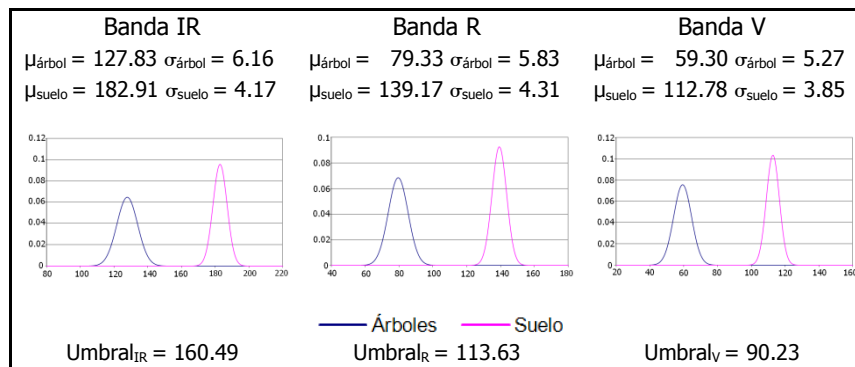


Figura 5-37. Determinación de umbrales para la parcela de la figura 5-36

La determinación de las categorías que representan árboles en la clasificación no supervisada se realiza mediante una regla de clasificación (figura 5-38), comparando el valor medio de cada categoría en las tres bandas con los umbrales establecidos en el paso anterior. Una categoría será considerada como *árboles* cuando su nivel digital medio en cada una de las tres bandas esté comprendido en el intervalo que tiene por límite inferior el valor medio de los niveles digitales de los puntos *árbol* menos 2.5 veces la desviación típica y por límite superior el umbral obtenido como intersección de las curvas gaussianas en la banda correspondiente.

| | |
|----------|---|
| Si | $\mu_{\text{Categ1-IR}} > \mu_{\text{árbol-IR}} - 2.5\sigma_{\text{árbol-IR}}$ Y $\mu_{\text{Categ1-IR}} < \text{Umbral}_{\text{IR}}$ y $\mu_{\text{Categ1-R}} > \mu_{\text{árbol-R}} - 2.5\sigma_{\text{árbol-R}}$ Y $\mu_{\text{Categ1-R}} < \text{Umbral}_{\text{R}}$ y $\mu_{\text{Categ1-V}} > \mu_{\text{árbol-V}} - 2.5\sigma_{\text{árbol-V}}$ Y $\mu_{\text{Categ1-V}} < \text{Umbral}_{\text{V}}$ |
| entonces | Categoría 1 = árbol |
| si no | Categoría 1= no árbol |

Figura 5-38. Regla de clasificación

De esta forma, se dota de significado a las clases resultantes del algoritmo K medias, obteniéndose una imagen binaria donde los píxeles pertenecientes a las categorías reclasificadas como árboles tienen el valor 1 frente al resto que tienen el nivel digital igual a 0. En la figura 5-39 se muestra el resultado de aplicar el método de segmentación de árboles propuesto en dos parcelas de la zona de estudio.

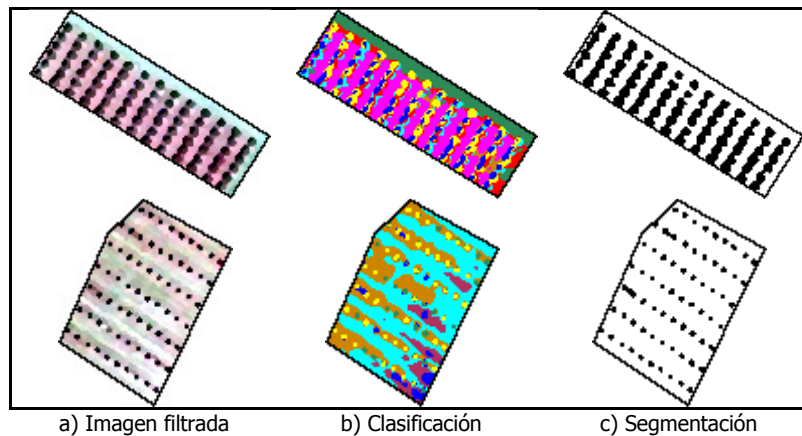


Figura 5-39. Segmentación de árboles

5.2.4.5.- Características extraídas de los sub-objetos segmentados

Las características extraídas de los sub-objetos resultantes de la segmentación permiten una completa descripción de los mismos, que facilita tanto su clasificación en distintas tipologías de árboles como la clasificación de las parcelas que los contienen. Dado que el objetivo final de este proceso es la clasificación de las parcelas, no se considera necesario examinar los distintos árboles de una parcela de forma individual, sino que cada característica de las expuestas a continuación se calcula de forma independiente para cada sub-objeto y a la parcela se le asigna el valor medio de los valores de cada característica para los sub-objetos contenidos en la parcela. Así por ejemplo, a cada parcela se le asigna como característica descriptiva el tamaño medio de los árboles existentes en ella, en lugar de considerar el tamaño de cada uno de los árboles existentes.

Las características extraídas pueden agruparse en las siguientes categorías:

- Características espectrales
- Características relativas al tamaño de los sub-objetos
- Características relativas a la posición de los sub-objetos
- Características relativas a la forma de los sub-objetos

Para encontrar los píxeles que limitan los sub-objetos se ha utilizado el algoritmo basado en el *código cadena* (Freeman, 1961) desarrollado por Fanning (2002). El *código cadena* consiste en definir el contorno poligonal de un objeto mediante un conjunto de vectores que unen cada píxel frontera con el siguiente. En una imagen con píxeles cuadrados, la longitud de estos vectores será o la longitud de un píxel o la longitud de un píxel multiplicado por $\sqrt{2}$, y cada uno de ellos contendrá un valor de 0 a 7 en función de la dirección al píxel siguiente (Russ, 1994).




Figura 5-40. Valores de dirección del código cadena

Una vez obtenido el código cadena que define el contorno de un objeto, se obtienen las coordenadas de los píxeles que forman el contorno a partir de las coordenadas del píxel inicial y las direcciones contenidas en el código cadena.

5.2.4.5.1.- Características espectrales

Para el conjunto de píxeles segmentados como árboles se calcula la **media aritmética** y la **desviación típica** de los niveles digitales en cada una de las tres bandas, así como en el índice NDVI. Estas características permiten discriminar diferentes variedades de árboles en función de su respuesta espectral.

5.2.4.5.2.- Características relativas al tamaño de los sub-objetos

La característica más sencilla para expresar el tamaño de un objeto es su **superficie**. En una imagen, la superficie de un objeto equivale al producto del número de píxeles que lo forman por la superficie de un píxel.

En el caso de disponer de las coordenadas de los píxeles que lo delimitan, como es nuestro caso, su superficie puede calcularse según:

$$Superf = \frac{\sum_{i=1}^n (x_i + x_{i-1})(y_i - y_{i-1})}{2} \quad (5-44)$$

Una vez determinada la superficie es conveniente expresarla como el **diámetro equivalente** al de un círculo con una superficie igual a la del objeto (Russ, 1994).

$$Diám.Eq.Circ. = \sqrt{\frac{4}{\pi} Superf} \quad (5-45)$$

Este índice es una forma sencilla de caracterizar objetos según su tamaño y que permite comparar objetos con formas y orientaciones diferentes.

Perímetro: La definición del perímetro de un objeto en una imagen, entendido como la longitud del contorno del mismo, no es tan simple como podría parecer a priori. La opción más sencilla es el conteo del número de lados de píxeles que no son adyacentes o comunes a otro píxel del mismo objeto y se puede obtener con la fórmula propuesta por Bogaert *et al.* (2000):

$$P = 4a - 2r \quad (5-46)$$

donde a = número de píxeles del objeto
 r = número de lados comunes a dos píxeles

El perímetro obtenido de esta forma es un valor inferior al real, ya que la distancia entre dos píxeles vecinos con un vértice en común, es mayor que la que existe entre dos píxeles vecinos con un lado común. Además este error depende de la orientación del objeto respecto a los ejes de coordenadas de la imagen. En el ejemplo de la figura 5-41, el objeto paralelo a los ejes de coordenadas tiene un perímetro de 20 unidades, frente a las 28 unidades que mide el perímetro del objeto girado 45° respecto a los ejes de coordenadas.




Figura 5-41. Estimación del perímetro mediante el conteo de los lados de un objeto (Russ, 1994)

Si se dispone de la representación del contorno por coordenadas, el sumatorio de las distancias existentes entre cada par de puntos del contorno equivale al perímetro del objeto.

$$\text{Perím} = \sum_{i=1}^n \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2} \quad (5-47)$$

En el caso de utilizar el código cadena para representar el contorno, los segmentos de la cadena tienen una longitud de 1 píxel si son paralelos a los ejes de coordenadas de la imagen, o bien, su longitud es de $\sqrt{2}$ píxeles si es un segmento diagonal. Simplemente, obteniendo el número de códigos impares, que son los que corresponden a las direcciones diagonales, y el número de códigos pares correspondientes a las direcciones paralelas a los ejes y multiplicando por su longitud, $\sqrt{2}$ o 1 respectivamente, se obtiene el perímetro de la figura.

5.2.4.5.3.- Características relativas a la posición de los sub-objetos

Las coordenadas del punto central de un objeto pueden calcularse considerando los píxeles que forman el contorno del mismo, o bien, considerando a todos los píxeles que forman la figura. En el primer caso, la opción más simple es obtener la media de las coordenadas mínimas y máximas de los píxeles que lo limitan. Estas coordenadas son sencillas de obtener ya que consiste en obtener los valores máximos y mínimos tanto de la coordenada x como de la y. Además, definen los límites del rectángulo, paralelo a los límites de la imagen, que engloba al objeto de estudio y cuyo centro se puede utilizar

como centro del objeto. Sin embargo, esta forma de obtener la localización del centro del objeto no es lo suficientemente precisa, ya que puede estar desplazado respecto a su posición correcta por la influencia de un número reducido de píxeles, ya que el punto calculado estaría desplazado hacia la parte del contorno más compleja y que contenga un mayor número de píxeles.

En el caso de figuras con formas irregulares, es preferible considerar la localización de todos los píxeles que forman la figura y la opción más utilizada es localizar el centroide de la figura. El **centroide** o **centro de masas** es el punto de equilibrio de la figura y es aquel punto tal que la superficie del objeto a la derecha del mismo es la misma que la que existe en la parte izquierda al igual que ocurre con las superficies situadas por encima y por debajo del mismo (Pratt, 1991). Viene definido por los momentos de orden 0 y de orden 1. Los momentos son propiedades numéricas que se pueden obtener de la imagen y en su cálculo intervienen todos los píxeles que forman la figura y no sólo los de su contorno (Pajares y de la Cruz, 2001).

Para una función discreta $f(x,y)$, el momento de orden $(p+q)$ se obtiene como:

$$M(p,q) = \sum_x \sum_y x^p y^q f(x,y) \quad (5-48)$$

El momento de orden 0 coincide con la superficie de la figura en las imágenes binarias.

$$M(0,0) = \sum_x \sum_y f(x,y) \quad (5-49)$$

Las coordenadas del centroide se obtienen mediante las expresiones:

$$X = \frac{M(1,0)}{M(0,0)} = \frac{\sum_x \sum_y x f(x,y)}{Superf} \quad Y = \frac{M(0,1)}{M(0,0)} = \frac{\sum_x \sum_y y f(x,y)}{Superf} \quad (5-50)$$

Los momentos centrales se obtienen con la expresión (5-51) y permiten reconocer figuras dentro de una imagen independientemente de su posición (Hu, 1962):

$$MC_{pq} = \sum_x \sum_y (x - X)^p (y - Y)^q f(x,y) \quad (5-51)$$

donde X e Y son las coordenadas del centroide.

5.2.4.5.4.- Características relativas a la forma de los sub-objetos

Dado que muchos objetos en la realidad tienen formas irregulares y resulta complicado definir índices o parámetros que los describan de forma robusta y permitan su comparación y clasificación es conveniente, para simplificar el problema, ajustar una figura geométrica al objeto de estudio y analizar esta figura en lugar del objeto original. Un ejemplo de este enfoque es la utilización del diámetro equivalente circular para comparar el tamaño de los objetos. Una figura más adecuada para tratar con objetos cuya forma no es circular es la elipse. El hecho de tener dos ejes de diferente tamaño, permite adaptarse mejor a la forma del objeto, así como a su orientación.

5.2.4.5.4.1.- Ajuste de una elipse

Hay varios métodos para ajustar una elipse a un objeto. El método más sencillo consiste en asignar como dimensiones de los ejes de la elipse, las dimensiones del rectángulo que limita el objeto. El resultado obtenido suele ser una elipse con un tamaño superior al del objeto.

Otra opción para ajustar una elipse a un objeto es la utilización de mínimos cuadrados para definir la elipse que mejor se adapta a los píxeles que forman el contorno del objeto. Este método tiene el inconveniente de que la elipse puede estar desplazada hacia la zona del contorno con más irregularidades.

El método más robusto para ajustar una elipse a un objeto se basa en el cálculo de momentos (Russ, 1994). Los tres momentos centrales de 2º orden forman las componentes del tensor de inercia o matriz de rotación:

Momentos centrales de 2º orden:

$$U(2,0) = \sum_x \sum_y (x - X)^2 f(x, y) \quad (5-52)$$

$$U(0,2) = \sum_x \sum_y (y - Y)^2 f(x, y) \quad (5-53)$$

$$U(1,1) = \sum_x \sum_y (x - X)(y - Y) f(x, y) \quad (5-54)$$

Tensor de inercia:

$$J = \begin{vmatrix} U(0,2) & -U(1,1) \\ -U(1,1) & U(2,0) \end{vmatrix} \quad (5-55)$$

A partir de los componentes del tensor de inercia se puede obtener la orientación y las dimensiones de la elipse.




Figura 5-42. Ajuste de una elipse

- La orientación (θ) o ángulo de rotación de la figura alrededor de su centro de masas es el ángulo comprendido entre el eje de abscisas y el eje alrededor del cual la figura puede rotar con mínima inercia. Este ángulo se puede obtener a partir de las dos componentes del primer vector propio $\vec{v}_1 = (v_{1x}, v_{1y})$ del tensor de inercia:

$$\theta = \arctan\left(\frac{v_{1y}}{v_{1x}}\right) \quad (5-56)$$

- Las dimensiones de los semiejes de la elipse (a y b) se obtienen a partir de los valores propios (λ_1, λ_2) de la misma matriz:

$$a = 2\sqrt{\lambda_1} \quad b = 2\sqrt{\lambda_2} \quad (5-57)$$

Las coordenadas de los puntos que forman la elipse, respecto a los ejes que definen los vectores propios, se determinan como:

$$x_1 = a \cos \varphi \quad y_1 = b \sin \varphi \quad (5-58)$$

donde φ varía entre 0 y 2π .

Partiendo de las coordenadas del centro de masas y el ángulo orientación, se determinan las coordenadas de los puntos de la elipse en el sistema de coordenadas original:

$$\begin{aligned} x_2 &= X + (x_1 \cos \theta) - (y_1 \sin \theta) \\ y_2 &= Y + (x_1 \sin \theta) + (y_1 \cos \theta) \end{aligned} \quad (5-59)$$

En la figura 5-43 se muestra el resultado de la aplicación de la metodología descrita sobre la imagen binaria resultante de la segmentación de los árboles.




Figura 5-43. Ajuste de elipses

5.2.4.5.4.2.- Índices descriptores de la forma del objeto

A partir de la superficie, el perímetro y los parámetros de la elipse ajustada al objeto, se define un conjunto de índices descriptores de su forma:

- Ratio largo/ancho: La relación entre el largo y el ancho de un objeto se puede obtener como el cociente de los valores propios o como el cociente de los semiejes de la elipse.

$$LA = \frac{\lambda_1}{\lambda_2} = \frac{a}{b} \quad (5-60)$$

- Ratio perímetro/área:

$$PA = \frac{\text{Perím}}{\text{Superf}} \quad (5-61)$$

- Asimetría: Parámetro que determina el grado de desviación de una elipse respecto a una circunferencia. Su valor está comprendido entre 0 y 1.

$$e = \sqrt{1 - \frac{b^2}{a^2}} \quad (5-62)$$

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

$$\gamma_1 = \frac{\text{Superf}}{\text{Perím}^2} \quad (5-63)$$

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:

$$\gamma_2 = \frac{2\sqrt{\pi \cdot \text{Superf}}}{\text{Perím}} \quad (5-64)$$

Este índice es habitualmente nombrado en la bibliografía como índice de forma y varía entre 0 y 1, siendo 0 el valor correspondiente a un objeto lineal y 1 el de un objeto circular.

- Dimensión fractal: Expresa la complejidad de los polígonos a partir de un cociente entre perímetro y superficie (Krummel *et al.*, 1987):

$$Df = 2 \frac{\log\left(\frac{\text{Perím}}{4}\right)}{\log(\text{Superf})} \quad (5-65)$$

5.2.5.- Características topográficas

Las propiedades topográficas del terreno pueden influir e incluso llegar a condicionar su uso. La altitud del terreno, la pendiente, la orientación, etc., son

parámetros que los agricultores tienen en cuenta a la hora de establecer los cultivos por su influencia en las condiciones climáticas de las parcelas. Su consideración facilita el aporte al sistema del conocimiento que se tenga sobre la distribución espacial de los distintos usos del suelo. Así, por ejemplo, algunos cultivos están limitados a un determinado intervalo altitudinal ya que por sus características no soportan temperaturas inferiores a cierto umbral. En zonas de pendiente elevada, el aprovechamiento agrícola está limitado y los usos que se pueden dar, sin realizar transformaciones del terreno, serían pastos, bosques, matorral, etc.

Al mismo tiempo, estas propiedades topográficas están fuertemente relacionadas con la naturaleza y condiciones de los suelos, factores también influyentes en la distribución espacial de los usos agrícolas.




Figura 5-44. Modelo digital de elevaciones de la zona de estudio

Dentro de este grupo de variables descriptoras se puede incluir la distancia a un determinado elemento: distancia a un núcleo urbano, a un cauce, a una vía de comunicación, a la línea de costa, etc. Estas características combinadas con conocimiento experto y un clasificador adecuado permiten utilizar relaciones espaciales entre determinados elementos en la clasificación. Así por ejemplo, los bosques de riberas y determinados cultivos de regadío sólo se dan en las inmediaciones de cauces fluviales. Ciertos elementos geomorfológicos costeros como las playas, marjales o albuferas sólo se dan en las proximidades de la línea de costa, etc. En estos casos, sería posible establecer un umbral que restringiera la asignación a una de estas clases a aquellas parcelas cuya distancia al elemento considerado sea inferior al umbral fijado.

De forma menos evidente, la distancia puede estar relacionada con otros cambios de usos del suelo. En el área de estudio se aprecia un mayor número de parcelas de regadío y edificaciones aisladas en las zonas más próximas a la costa, mientras que al aumentar la distancia, estas clases se ven sustituidas por algarrobos, cítricos y olivos.



Figura 5-45. Modelo de distancias a la costa

Para cada una de las parcelas en el área estudiada se calcularon los valores medios de las características siguientes: distancia a la costa, altitud y pendiente.

5.2.6.- Clasificación a nivel de píxel

En la clasificación orientada a objetos, las características descriptivas de cada objeto se suelen calcular mediante el cálculo de un estadístico, normalmente la media o la desviación típica, sobre los valores de los píxeles que forman el objeto en la característica en cuestión. Al sintetizar los valores de los píxeles en un solo valor, se produce una homogeneización de la característica reduciéndose parte del grado de detalle que proporciona la resolución de la imagen.

Con el fin de preservar la información respecto a la heterogeneidad interna de los objetos y mejorar su descripción, se propone la realización de una clasificación a nivel de píxel, de tal forma que para cada parcela se pueda conocer la proporción de superficie cubierta por cada una de las clases básicas establecidas en la clasificación por píxel. Esta forma de trabajar es una combinación de los dos métodos de clasificación por parcela descritos en el apartado 3.2.5 de esta tesis: los objetos clasificados en último término son las parcelas pero entre sus características descriptivas se incluye el resultado de una clasificación por píxel.

La consideración del píxel como unidad básica en la clasificación requiere el establecimiento de una leyenda distinta a la empleada en la clasificación por parcelas ya que los descriptores de los píxeles son los niveles digitales en las bandas de la imagen y las clases a utilizar deben ser espectralmente homogéneas. Es decir, las clases a utilizar deben ser simples: suelo, árboles frutales, sombras, etc. para a partir de ellas determinar el uso de las parcelas mediante la combinación de las clases simples.

En el anejo II se muestran los resultados de la clasificación por píxel realizada para la zona de estudio en la que se han definido las clases *Agua, Asfalto, Edificios amarillos, Edificios azules, Frutales de regadío, Frutales de secano, Matorral, Regadío, Sombras, Suelo desnudo claro* y *Suelo desnudo oscuro*. A partir de esta clasificación, se obtienen once nuevas características descriptoras para cada parcela que indican la proporción de píxeles clasificados en cada una de las clases.

5.2.7.- Características de forma de la parcela

Para describir la forma de cada parcela se realiza el mismo proceso descrito en la sección 5.2.4.5.4.2 relativo a la obtención de características de forma de los árboles resultantes de la segmentación. En este caso, el objeto de estudio es la parcela en su conjunto y a partir de la imagen binaria correspondiente a la misma, se lleva a cabo el ajuste de una elipse a la forma de la parcela y se extraen los mismos índices citados que en el tratamiento de los sub-objetos contenidos en ella.

Capítulo VI

RESULTADOS

6.1.- Introducción

En este capítulo se recogen los ensayos realizados para evaluar la validez de la metodología de extracción de características propuesta en el capítulo anterior. Las características descriptoras empleadas en cada ensayo están en función del objetivo planteado en cada uno de ellos.

El primer ensayo valora la adecuación de la posición del primer máximo en el semivariograma omnidireccional de una parcela como indicador del tamaño medio de los árboles de la misma. Para ello, se compara el valor medio del diámetro de los árboles medido manualmente en un conjunto de parcelas representativas de todas las clases de cultivos arbóreos existentes en la zona de estudio con la posición del primer máximo en el semivariograma omnidireccional correspondiente.

En el segundo ensayo se describen los marcos de plantación de los cultivos arbóreos mediante la aplicación de la transformada de Hough sobre una imagen binaria con la localización de los árboles. Para caracterizar las parcelas en este ensayo se han utilizado las 15 características extraídas de la aplicación de la transformada de Hough descritas en la sección 5.2.3.3.4. En primer lugar, se evalúa la capacidad de estas características para separar las parcelas con marco de plantación regular de las que no lo tienen. En segundo lugar, se compara, para las parcelas con marcos de plantación regulares, la separación entre los árboles en las dos direcciones principales medida manualmente con el valor de la mediana de las separaciones entre las alineaciones de la

dirección principal y secundaria detectadas automáticamente con la aplicación del método descrito en el apartado 5.2.3.3.4.

En el tercer ensayo se aplica la metodología de segmentación de árboles descrita en la sección apartado 5.2.4. La calidad de la segmentación realizada se evalúa mediante la comparación de la superficie ocupada por las copas de los árboles segmentadas automáticamente con la delineada manualmente.

El cuarto ensayo tiene por objeto evaluar la validez de las características extraídas de los sub-objetos, creados mediante la segmentación de árboles, para describir los cultivos arbóreos. Consiste en la clasificación de cultivos arbóreos utilizando para describir las parcelas únicamente las características correspondientes a los árboles contenidos en ellas y que están descritas en el apartado 5.2.4.5.

En el quinto ensayo se comprueba la eficacia de la metodología presentada para la clasificación de parcelas agrícolas. Para describir las parcelas se han utilizado todas las características descritas en el capítulo 5 con excepción del uso previo. Las clases utilizadas son aquellas de las que existen como mínimo cien parcelas con un uso homogéneo en toda su superficie.

El objetivo del sexto ensayo es evaluar la validez de incorporar el uso previo contenido en la base de datos como una variable más en el proceso de clasificación. Para resaltar los efectos de la inclusión de esta característica, en la descripción de los objetos se han utilizado únicamente las características espectrales de las parcelas. Como el grado de actualización de una base de datos es un dato desconocido a priori se ha comprobado cómo interviene esta variable en la clasificación con bases de datos con distintos grados de actualización.

En el último ensayo se desarrolla el proceso completo de actualización de una base de datos cartográfica. Las parcelas utilizadas corresponden a toda la zona de trabajo, pero se han limitado a aquellas con una superficie superior a 200 m². Para todas ellas se han calculado las 89 características descritas en el capítulo 5. En primer lugar, mediante la aplicación de un árbol de decisión basado en las características de forma de las parcelas se extraen las vías de comunicación. A continuación, mediante análisis discriminante paso a paso, se seleccionan las 37 características con un mayor poder discriminante. Con estas características y las muestras de entrenamiento se crean los árboles de decisión que asignan a cada parcela una clase y un valor de la confianza con la que se hace la asignación a una clase. Posteriormente, se obtienen los indicadores de fiabilidad de la clasificación mediante las muestras de evaluación. Finalmente, la comparación de los resultados de la clasificación con la información contenida en la base de datos a actualizar detecta aquellas parcelas cuya clase debe ser confirmada por un fotointérprete.

6.2.- Identificación del tamaño medio de los árboles mediante el análisis del semivariograma

Para comprobar la efectividad de utilizar el primer máximo del semivariograma en la determinación del diámetro de los árboles presentes en una parcela se ha medido, de forma manual, el radio medio de los árboles existentes en 216 parcelas representativas de los distintos cultivos presentes en la zona de estudio. El diámetro medio de cada parcela se ha comparado con la posición del primer máximo en el semivariograma omnidireccional correspondiente.

Los cultivos arbóreos analizados en este ensayo son: *algarrobos, olivos y cítricos*. Estos últimos se han separado en distintas categorías en función del tamaño de los árboles y de su marco de plantación, obteniéndose así las siguientes clases por división de la categoría *cítricos*:

- *Plantones de cítricos*: Cítricos con un tamaño de copa igual o inferior a 3 píxeles (1.5 m).
- *Cítricos jóvenes*: Cítricos con un tamaño superior a 3 e inferior a 5 píxeles (1.5 m a 2.5 m).
- *Cítricos adultos*: Cítricos con un tamaño superior a 5 píxeles.
- *Cítricos alineados*: Cítricos que forman alineaciones en las que se solapan las copas de los árboles vecinos.
- *Cítricos irregulares*: Cítricos en estado de abandono con numerosas faltas y tamaño de copas variable.

En la tabla 6-1 se muestran la media y desviación típica de los diámetros, medidos en píxeles, para las parcelas pertenecientes a cada una de las categorías, así como la media y la desviación típica de las diferencias entre el diámetro medio y la posición del primer máximo del semivariograma, agrupados según categorías de cultivos. Del análisis de los resultados contenidos en esta tabla se extraen las siguientes conclusiones:

- Los mejores resultados en la determinación del tamaño de los árboles por medio del semivariograma se obtienen para los olivos y los cítricos jóvenes, adultos, alineados e irregulares, con diferencias entre 0.87 y 1.59 píxeles. A estas clases

son las que les corresponden semivariogramas cíclicos con un efecto agujero más claro.

- En el caso de los algarrobos, la estimación de su diámetro es deficiente ya que al no estar plantados según un marco de plantación claro, el semivariograma obtenido no muestra un comportamiento cíclico. Por otra parte, la variabilidad en las dimensiones de este tipo de árboles dentro de una misma parcela es muy importante, hecho éste que dificulta la correcta determinación del tamaño medio con el máximo del semivariograma.

| Clase | Número de parcelas | Diámetros medidos | | Diferencias | |
|-----------------------|--------------------|-------------------|----------|-------------|----------|
| | | μ | σ | μ | σ |
| Algarrobos | 43 | 14.7 | 3.2 | 5.79 | 4.37 |
| Olivos | 34 | 10.1 | 2.1 | 1.32 | 1.70 |
| Plantones de cítricos | 26 | 2.9 | 0.3 | 5.20 | 3.06 |
| Cítricos jóvenes | 43 | 4.3 | 0.6 | 1.59 | 1.23 |
| Cítricos adultos | 20 | 6.8 | 1.3 | 1.52 | 3.23 |
| Cítricos alineados | 16 | 6.5 | 1.1 | 0.87 | 0.86 |
| Cítricos irregulares | 35 | 7.4 | 1.3 | 1.16 | 1.21 |

Tabla 6-1. Comparación de diámetros medidos y obtenidos con el semivariograma

- Los plantones de cítricos no se caracterizan correctamente mediante el máximo del semivariograma. La superficie reducida de estos árboles respecto a la superficie total de la parcela hace que su influencia en el semivariograma sea muy baja, obteniéndose semivariogramas crecientes y sin ningún tipo de comportamiento cíclico.

Resumiendo las conclusiones expuestas, se puede afirmar que la posición del primer máximo es un indicador muy preciso para determinar el tamaño de los árboles situados en parcelas a las que corresponde un semivariograma cíclico. Las dos condiciones necesarias para que una parcela tenga un semivariograma omnidireccional cíclico son que ésta tenga un marco de plantación bien definido y que los árboles tengan un tamaño de copa lo suficientemente grande para ser detectados por medio del semivariograma. La precisión del método disminuye en la medida en la que no se cumplen alguna de estas dos condiciones.

Aunque la información extraída sólo tiene un grado de exactitud alto para algunas de las clases, es de utilidad como una aproximación al tamaño de los árboles para su localización mediante el método de filtrado de máximos o mínimos locales.

6.3.- Determinación de características descriptivas del marco de plantación mediante la transformada de Hough.

Para la verificación de la metodología basada en la transformada de Hough en la identificación de los marcos de plantación de los cultivos arbóreos, se seleccionaron 200 parcelas en las que se cultivan cítricos, olivos y algarrobos con distintos marcos de plantación y distintos tamaños de árboles de cada una de las especies. También se seleccionaron otras 200 parcelas donde no existe marco de plantación por pertenecer a clases como agua, matorral, suelo desnudo, regadío, etc.

La mitad de las parcelas seleccionadas se emplearon para el entrenamiento del clasificador mientras que el resto se emplearon en su evaluación.

El primer paso consistió en comprobar la adecuación de las variables extraídas de la transformada de Hough para determinar la existencia, o no, de cultivos arbóreos plantados según un marco de plantación regular. Para ello, se generaron diez árboles de clasificación con el algoritmo C5.0 y el multclasificador *boosting*. En la figura 6.1 se muestra el primero de los diez árboles creados para la separación de las parcelas con marco de plantación regular de las que no lo tienen.




Figura 6-1. Árbol de decisión para la separación de las parcelas con marcos de plantación regulares

Las variables utilizadas en el árbol de decisión de la figura 6.1 son: proporción de puntos en la dirección principal (PORCPTODIR1) y secundaria (PORCPTODIR2), ángulo formado por las dos direcciones principales (DIFANGUL) y proporción de rectas en la dirección principal (PORCDIR1).

La totalidad de las parcelas utilizadas para la generación de los árboles de clasificación se clasificaron correctamente en las dos clases que indican la presencia o ausencia de marco de plantación. Al aplicar el clasificador descrito sobre el conjunto de

parcelas de evaluación se obtuvo una precisión global de la clasificación del 93.5%. En la tabla 6-2 se muestra la matriz de confusión obtenida:

| V. Terreno | Clasificación | | TOTAL | F. Productor |
|-------------------|---------------|----------|-------|--------------------|
| | MARCO | NO MARCO | | |
| MARCO | 95 | 5 | 100 | 95 |
| NO MARCO | 8 | 92 | 100 | 92 |
| TOTAL | 103 | 97 | 200 | |
| F. Usuario | 92.2 | 94.8 | | F.G. = 93.5 |

Tabla 6-2. Matriz de confusión

Los cinco errores de clasificación por defecto son aquellas parcelas en las que, según la clasificación, no existe marco de plantación, cuando en realidad sí existe. Se trata de parcelas con plantaciones de cítricos irregulares que dificultan la extracción correcta del marco de plantación.

Los ocho errores de clasificación por exceso, es decir, detección de marco de plantación en parcelas donde no lo hay, se corresponden a parcelas donde los árboles no se han detectado correctamente y las alineaciones detectadas mediante la transformada de Hough cumplen las condiciones establecidas por los árboles de decisión.

La segunda fase del ensayo consistió en la evaluación de la precisión con la que las dimensiones de los marcos de plantación son determinadas mediante la obtención de la mediana de las separaciones de las rectas paralelas detectadas en las direcciones principal y secundaria.

De forma manual se midieron en las 200 parcelas con marcos de plantación regulares las dimensiones de los marcos de plantación en las dos direcciones principales. Las dimensiones del marco de plantación hacen referencia a la separación entre los árboles según la dirección principal y secundaria. Los datos medidos se comparan con los resultados obtenidos de forma automática con la metodología expuesta

En el gráfico de la figura 6.2 se muestra en el eje de abscisas la diferencia entre la dimensión medida manualmente y la calculada automáticamente. En el eje de ordenadas se muestra la proporción de parcelas a las que corresponde una diferencia inferior o igual al que indica el eje de abscisas. Así por ejemplo, la separación entre los árboles en la dirección principal se obtiene con una diferencia inferior o igual a 0.5 píxeles para el 69% de las parcelas. Del mismo modo, en el 89% de las parcelas la diferencia en la estimación de la separación entre los árboles en la dirección principal es inferior o igual a 2 píxeles, que equivale aproximadamente a una distancia de 1 metro.

Los resultados en la separación entre los árboles en la segunda dirección se obtiene con una diferencia inferior o igual a 0.5 píxeles para el 58% de las parcelas, mientras que para el 85% de las parcelas la diferencia es inferior o igual a 2 píxeles.




Figura 6-2. Proporción de parcelas con una diferencia inferior a la indicada en la determinación de cada dimensión de los marcos de plantación

Los resultados obtenidos permiten obtener de forma lo suficientemente precisa una característica tan importante para la descripción de los cultivos arbóreos como son los marcos de plantación empleados.


Es necesario destacar que la distancia entre alineaciones obtenida mediante la resta de los valores de ρ con el método propuesto es siempre un valor entero, ya que los valores de ρ utilizados para el cálculo de la transformada de Hough también lo son. Por tanto, la utilización de valores de ρ no enteros en el cálculo de la transformada de Hough, proporcionarían un incremento en la precisión de las distancias entre alineaciones obtenidas, a costa de un incremento en el tiempo de procesado.

Con la aplicación de la metodología expuesta, se puede obtener, para un alto porcentaje de parcelas, características tan necesarias para un fotointérprete como son las relativas al marco de plantación que siguen los cultivos arbóreos. Estas características van a complementar al resto de características descriptivas de la parcela aportando información no redundante con la que ya se tenía y cuya incorporación al proceso de clasificación es previsible que suponga un aumento en la fiabilidad de la misma.


Los errores detectados en la aplicación del método se pueden agrupar en las siguientes categorías:

- Marcos de plantación irregulares. Su estructura no regular dificulta la extracción de las alineaciones principales (figura 6-3a).


- La existencia de dos marcos de plantación distintos en la misma parcela produce que las alineaciones formadas por los árboles detectados no correspondan a las alineaciones de ninguno de los dos marcos existentes, sino que sea una combinación de ambos (figura 6-3b).
- Parcelas estrechas formadas por sólo dos o tres alineaciones de árboles, de forma que el número de árboles en la alineación secundaria es inferior al umbral mínimo establecido para crear rectas (figura 6-3c).
- Parcelas de cítricos alineados donde las copas de los árboles de una misma alineación se funden entre sí, resultando prácticamente imposible para un fotointérprete determinar la posición de los árboles que forman la alineación. En este caso, sólo la separación entre las rectas de la dirección principal se obtiene correctamente (figura 6-3d).




a) Parcela cítrica con marco de plantación irregular



b) Parcela con dos tipos de plantación



c) Parcela con tres filas de árboles



d) Parcela con cítricos alineados

Figura 6-3. Parcelas con marcos de plantación incorrectamente detectados

6.4.- Extracción de árboles mediante segmentación de imágenes

La metodología propuesta en el apartado 5.2.4. sobre segmentación de árboles se ha comprobado con un conjunto de 45 parcelas en las que se ha digitalizado manualmente el perímetro de los árboles existentes en las parcelas. Las parcelas seleccionadas incluyen las distintas tipologías de cultivos arbóreos tanto de secano como de regadío presentes en el área de estudio, con distintos tamaños de árboles (desde plántones hasta árboles adultos), distintas condiciones del suelo (desde parcelas con el suelo desnudo a parcelas con vegetación herbácea), así como con distintos marcos de plantación: rectangulares, cuadrados, en alineaciones, etc.



Figura 6-4. Delineación manual de copas

Debido a la resolución espacial de las imágenes empleadas y al hecho de que las imágenes se han obtenido como fusión de bandas pancromáticas y multiespectrales, el contorno de las copas de los árboles no es un borde nítido. Por ello, la delineación de las copas resulta imprecisa, ya que existen *píxeles de transición* cuya respuesta resulta de la

combinación de la reflectancia del árbol y del suelo. En las figuras 6-5 y 6-6 se muestran los contornos de dos árboles sobre la imagen original sobre la que se delinearon (a), sobre la imagen filtrada con el filtro de media ponderada explicado en el apartado 5.2.4.2 (b) y sobre la segmentación resultante (c).




Figura 6-5. Delineación manual de copas

En ambas figuras se aprecia que el filtrado de media ponderada reduce los píxeles de transición, obteniéndose un contorno considerablemente más nítido. Por otra parte los límites de las copas obtenidos con la segmentación coinciden en gran medida con los que seleccionaría un fotointérprete sobre la imagen filtrada.




Figura 6-6. Delineación manual de copas

Al delimitar las copas sobre la imagen original, se produce un error debido a la falta de definición exacta del límite de la copa. Este error puede ser tanto por exceso como por defecto.

La evaluación de los resultados de la segmentación se ha realizado de forma cuantitativa comparando los valores de la superficie en metros cuadrados ocupada por los árboles obtenida de forma automática mediante la segmentación propuesta con la obtenida de la delineación manual. Se ha calculado el ratio entre la superficie segmentada y la delineada, de forma que valores de este ratio mayores a 1 indican que la segmentación produce una estimación de la superficie por exceso, mientras valores inferiores a 1 indican una estimación de la superficie por defecto (tabla 6-3).

| Id. | Área Segmentada | Área Delineada | Ratio | Clase |
|-------|-----------------|----------------|--------------------|-----------------------|
| 573 | 1006.75 | 1003.77 | 1.00 | Algarrobos |
| 783 | 483.33 | 582.33 | 0.83 | Algarrobos |
| 981 | 910.25 | 810.38 | 1.12 | Algarrobos |
| 1093 | 1052.25 | 836.00 | 1.26 | Algarrobos |
| 4868 | 951.00 | 779.45 | 1.22 | Algarrobos |
| 11999 | 721.00 | 861.46 | 0.84 | Algarrobos |
| 12001 | 543.00 | 530.77 | 1.02 | Algarrobos |
| 12002 | 609.00 | 812.62 | 0.75 | Algarrobos |
| 12004 | 911.00 | 895.53 | 1.02 | Algarrobos |
| 870 | 364.00 | 342.75 | 1.06 | Cítricos adultos |
| 935 | 1112.50 | 1062.23 | 1.05 | Cítricos adultos |
| 5438 | 157.75 | 154.64 | 1.02 | Cítricos adultos |
| 5684 | 1394.00 | 1257.47 | 1.11 | Cítricos adultos |
| 8640 | 749.00 | 863.69 | 0.87 | Cítricos adultos |
| 10603 | 1457.75 | 1360.06 | 1.07 | Cítricos adultos |
| 10956 | 693.75 | 926.53 | 0.75 | Cítricos adultos |
| 11052 | 800.00 | 846.56 | 0.95 | Cítricos adultos |
| 11988 | 687.25 | 632.14 | 1.09 | Cítricos adultos |
| 11995 | 535.00 | 450.13 | 1.19 | Cítricos adultos |
| 11996 | 689.50 | 699.60 | 0.99 | Cítricos adultos |
| 11990 | 475.25 | 381.71 | 1.25 | Cítricos alineados |
| 231 | 1307.25 | 1476.82 | 0.89 | Cítricos alineados |
| 765 | 446.00 | 510.25 | 0.87 | Cítricos alineados |
| 5773 | 1559.00 | 1349.46 | 1.16 | Cítricos alineados |
| 10922 | 1682.75 | 1387.14 | 1.21 | Cítricos alineados |
| 11992 | 450.25 | 396.66 | 1.14 | Cítricos alineados |
| 11994 | 1465.50 | 1505.42 | 0.97 | Cítricos alineados |
| 12003 | 391.00 | 560.58 | 0.70 | Cítricos alineados |
| 534 | 1160.75 | 1266.59 | 0.92 | Olivos |
| 4918 | 1985.00 | 1824.66 | 1.09 | Olivos |
| 10322 | 3148.25 | 3107.92 | 1.01 | Olivos |
| 10495 | 914.00 | 889.46 | 1.03 | Olivos |
| 10614 | 729.25 | 443.59 | 1.64 | Olivos |
| 11053 | 1856.00 | 2053.57 | 0.90 | Olivos |
| 11993 | 621.25 | 486.38 | 1.28 | Olivos |
| 11991 | 120.75 | 45.28 | 2.67 | Plantones de cítricos |
| 755 | 264.50 | 213.44 | 1.24 | Plantones de cítricos |
| 4964 | 219.25 | 224.43 | 0.98 | Plantones de cítricos |
| 5572 | 414.75 | 353.64 | 1.17 | Plantones de cítricos |
| 10374 | 2206.75 | 1765.82 | 1.25 | Plantones de cítricos |
| 11989 | 105.75 | 81.01 | 1.31 | Plantones de cítricos |
| 11997 | 197.50 | 230.64 | 0.86 | Plantones de cítricos |
| 11998 | 163.50 | 65.48 | 2.50 | Plantones de cítricos |
| 12000 | 158.75 | 127.54 | 1.24 | Plantones de cítricos |
| 11027 | 1644.50 | 999.51 | 1.65 | Plantones de cítricos |
| | | | Media= | 1.14 |
| | | | Desviación típica= | 0.37 |

Tabla 6-3. Evaluación de la segmentación automática de árboles

Los mayores ratios obtenidos (2.66 y 2.49) corresponden a las parcelas con las menores superficies de copa de todo el ensayo (tabla 6-3) y son parcelas ocupadas por plantones de cítricos. Esta tipología es la que presenta un mayor error en la determinación de la superficie cubierta (tabla 6-4) ya que se ve más afectada por el error en la determinación de los bordes de las copas que aquellas parcelas con copas de mayor tamaño donde la proporción de píxeles de borde es menor frente al total de los píxeles que representan árboles.

En la figura 6-7 se muestra la correspondencia entre las superficies arbóreas segmentadas automáticamente con las delineadas manualmente.




Figura 6-7. Áreas segmentadas frente a áreas delineadas

Los resultados obtenidos en el resto de cultivos se consideran lo suficientemente precisos para el fin que se pretende, que es la extracción de los árboles a fin de identificar el tipo de cultivo existente en la parcela. En la tabla 6-4 se muestra que, para el resto de cultivos, el valor medio del ratio está comprendido entre 1.007 y 1.124.

| Clase | Número de parcelas | Ratio | |
|---------------------------------|--------------------|-------|----------|
| | | μ | σ |
| Algarrobos | 9 | 1.007 | 0.176 |
| Cítricos adultos independientes | 11 | 1.012 | 0.122 |
| Cítricos adultos alineados | 8 | 1.022 | 0.194 |
| Olivos | 7 | 1.124 | 0.261 |
| Plantones de cítricos | 10 | 1.480 | 0.614 |

Tabla 6-4. Evaluación por clase de la segmentación automática de árboles

El método de segmentación automático propuesto basado en el preprocesado mediante un filtrado de media ponderada, la clasificación no supervisada y la selección de muestras de árboles y de suelo sin la intervención de un operador, permite extraer los árboles existentes con un alto grado de ajuste. La imagen binaria obtenida es empleada para la descripción completa de los árboles extraídos mediante las características desarrolladas en el apartado 5.2.4.5.

Por otra parte, esta información extraída de la imagen puede ser útil no sólo para la descripción de la parcela y su posterior clasificación, sino también para aquellas aplicaciones agronómicas o forestales en las que sea necesario conocer la superficie cubierta por los árboles, como por ejemplo, estudios de irrigación, estimación de producciones frutales o madereras, etc.

6.5.- Clasificación de parcelas con cultivos arbóreos

En este ensayo se evaluó la capacidad de las características extraídas de los árboles resultantes de la segmentación para describirlos eficientemente con el objeto de clasificarlos según la clase de cultivo arbóreo a la que correspondan.

Se realizaron cuatro clasificaciones mediante el algoritmo C5.0, variando tanto el método de aplicación del mismo como las variables descriptoras de los sub-objetos. La aplicación del algoritmo C5.0 se realizó con un solo árbol y con 10 árboles empleando la opción *boosting*.

El nombre y la definición de las características empleadas en la descripción de los árboles de las parcelas se muestran en la tabla 6-5. En dos de las clasificaciones se utilizaron todas las características enumeradas incluyendo la media del nivel digital de los árboles en las tres bandas disponibles y en el índice NDVI, así como los valores medios y las desviaciones típicas de las características siguientes: perímetro, área, diámetro equivalente, ratio largo/ancho, ratio perímetro/área, asimetría, compacidad y dimensión fractal llegando a un total de 20 características. En las dos clasificaciones restantes se empleó solamente el valor medio de las características citadas (12 características).

| CARACTERÍSTICAS ESPECTRALES DE LOS SUB-OBJETOS SEGMENTADOS | |
|--|---|
| IRARB | Media de la banda infrarroja |
| RARB | Media de la banda roja |
| GARB | Media de la banda verde |
| NDVIARB | Media del índice NDVI |
| CARACTERÍSTICAS DE FORMA DE LOS SUB-OBJETOS SEGMENTADOS | |
| PERIMARB | Media del perímetro |
| PERIM_STDARB | Desviación típica del perímetro |
| AREAARB | Media de la superficie |
| AREA_STDARB | Desviación típica de la superficie |
| DIAMEQARB | Media del diámetro equivalente |
| DIAM_STDARB | Desviación típica del diámetro equivalente |
| LARGOANCHOARB | Media del cociente entre largo y ancho |
| LARGOANCHO_STDARB | Desviación típica del cociente entre largo y ancho |
| PERIAREAARB | Media del cociente entre perímetro y superficie |
| PERIAREA_STDARB | Desviación típica del cociente entre perímetro y superficie |
| ASIMETRIAARB | Media del índice de asimetría |
| ASIMETRIA_STDARB | Desviación típica del índice de asimetría |
| COMPACIDADARB | Media del índice de compacidad |
| COMPACIDAD_STDARB | Desviación típica del índice de compacidad |
| FRACTALARB | Media de la dimensión fractal |
| FRACTAL_STDARB | Desviación típica de la dimensión fractal |

Tabla 6-5. Nombre y descripción de las características descriptivas de los objetos

En la tabla 6-6 se resumen las clasificaciones realizadas:

| Árboles de decisión | | |
|---------------------|------------------------|---------------------------|
| Características | 1 árbol con 20 caract. | 10 árboles con 20 caract. |
| | 1 árbol con 12 caract. | 10 árboles con 12 caract. |

Tabla 6-6. Parámetros de las clasificaciones realizadas

Las tipologías de cultivos arbóreos presentes en la zona de estudio son cítricos, algarrobos y olivos. A fin de completar las tipologías de cultivos existentes en la zona de estudio, se seleccionaron parcelas de almendros localizadas en el municipio de Segorbe.

Se seleccionaron manualmente 360 parcelas de las cuales 60 pertenecen a cada una de las categorías a estudiar. El 50% de las muestras se utilizaron para entrenamiento del clasificador y el 50% restante para la evaluación del rendimiento del mismo.

Tanto el valor medio, como la desviación típica de una característica para una parcela se calculan como el valor medio y la desviación típica de esa característica para los objetos segmentados contenidos en esa parcela. A fin de evitar valores anómalos de las características a causa de un posible error en la segmentación, los objetos con áreas extremas en el conjunto de objetos de una parcela no son considerados en el cálculo de la característica determinada.

En la figura 6-8 se muestran los valores medios de las tres características descriptoras del tamaño de los árboles segmentados: perímetro, área y diámetro equivalente para las parcelas correspondientes a cada una de las tipologías de cultivo. Con el fin de facilitar la comparación de las tres variables, las cuales tienen rangos de valores muy distintos, se han normalizado por el valor máximo, quedando un intervalo de valores de salida comprendido entre 0 y 1.




Figura 6-8. Media aritmética de las características de tamaño

Las tres variables de tamaño identifican correctamente a la clase de cítricos alineados como la de mayor tamaño ya que los objetos segmentados en esta clase corresponden a agrupaciones formadas por varios árboles. A continuación, las clases de árboles ordenados en sentido descendente según su tamaño de copa son: algarrobos, olivos, almendros, cítricos independientes y plantones de cítricos que coinciden con el orden de tamaño asignado por las tres variables calculadas.

La figura 6-9 representa los valores medios de las características de forma. En ella se aprecia cómo el cociente largo por ancho permite discernir claramente los cítricos alineados del resto; ya que los objetos de esta clase tienen una forma marcadamente alargada al corresponder su dimensión más corta al diámetro de un árbol, mientras que su dimensión más larga corresponde a la suma de los diámetros de varios árboles.

El ratio perímetro por área facilita la identificación de los plantones de cítricos, ya que los valores máximos de este índice corresponden a objetos circulares y de tamaño reducido.

La asimetría vuelve a identificar a los cítricos alineados como los objetos más alargados, frente a los cítricos independientes, olivos y plantones con una forma aproximadamente circular.




Figura 6-9. Media aritmética de las características de forma

La compacidad determina que los árboles con formas aproximadamente circulares son los cítricos independientes, almendros, olivos y plantones. Mientras que los algarrobos y los cítricos alineados son aquellos cuyo contorno más difieren de la forma circular.

La dimensión fractal es la variable que tiene un rango de valores más reducido y determina la complejidad de los distintos objetos.

La figura 6-10 muestra los valores medios para los objetos generados en las tres bandas espectrales disponibles y en el índice NDVI. El análisis de esta gráfica permite determinar que los cultivos con un mayor vigor vegetativo son los cítricos alineados y los algarrobos, seguidos por los olivos y almendros y por último las clases de árboles más jóvenes como son los cítricos independientes y los plantones.

La clase plantones tiene una respuesta elevada en las tres bandas espectrales. En esta clase se da la circunstancia de que sus características de tamaño y forma son singulares respecto al resto de cultivos, por lo que su identificación resulta más sencilla que en otros cultivos.

La alta respuesta espectral de los almendros en la banda del verde resulta fundamental para su correcta discriminación de otros cultivos con formas y tamaños similares.

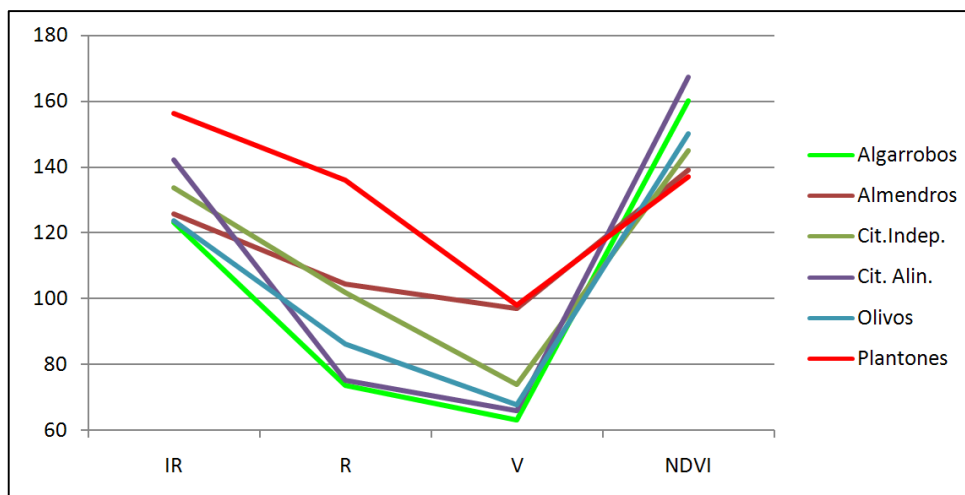


Figura 6-10. Media aritmética de las características espectrales

6.5.1.- Ensayo 1: Un árbol de decisión con 20 características

Partiendo del conjunto de muestras de aprendizaje formado por 30 parcelas de cada clase descritas por 20 características y por medio del algoritmo C5.0 se obtiene el árbol de decisión mostrado en la figura 6-11. En esta figura, se muestran las distintas condiciones que debe cumplir un objeto para ser asignado a una clase determinada. Estas condiciones están basadas en umbrales de las variables descriptoras. A continuación de cada combinación de condiciones que asigna un objeto a una clase, se muestra entre paréntesis la efectividad de esa asignación, cuantificando el número de parcelas que cumplen esas condiciones y el número de errores que esa predicción ha cometido en la asignación de la clase. Así por ejemplo, la asignación de parcelas a la clase cítricos independientes se realiza mediante la regla:

PERIAREAARB \leq 1.999186 Y GARB \leq 87.95989 Y ÁREA_STDARB \leq 16.18241

Del total de parcelas contenidas en el conjunto de entrenamiento, 31 parcelas cumplen la regla expuesta, de las cuales sólo una de esas parcelas no pertenece a la clase cítricos independientes.

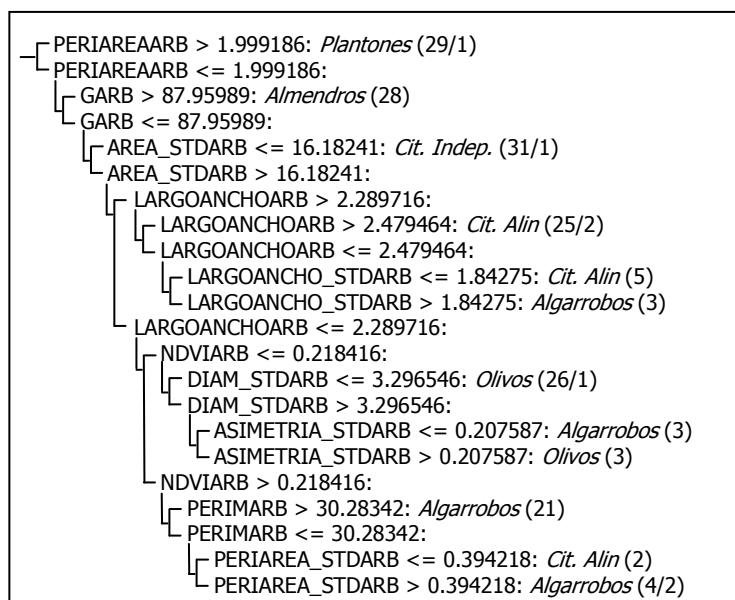


Figura 6-11. Árbol de decisión creado a partir de 20 características

Del conjunto de muestras de entrenamiento formado por 180 parcelas, 173 (96.1%) son correctamente clasificadas, mientras que 7 (3.9%) lo son de forma incorrecta. Los errores de clasificación más abundantes son entre la clase plantones y cítricos alineados (2 errores) y entre la clase olivos y algarrobos (2 errores).

Dado el volumen de características utilizadas en la descripción de las parcelas, es interesante conocer cuáles son las que contribuyen en mayor medida en la clasificación, de forma que las características menos significativas pueden ser eliminadas en trabajos similares. La tabla 6-7 muestra para las características empleadas el porcentaje de parcelas que han sido clasificadas basándose en cada característica. Del análisis del porcentaje de relevancia de las variables en la clasificación, se desprende que las características que mejor permiten discriminar las parcelas son basadas en la forma de los objetos y en sus propiedades espectrales. Salvo la característica AREA_STDARB, el resto de variables obtenidas como la desviación típica de una característica tienen poca importancia en la clasificación.

| Característica | % de parcelas |
|-------------------|---------------|
| PERIAREAARB | 100 |
| GARB | 84 |
| AREA_STDARB | 68 |
| LARGOANCHOARB | 51 |
| NDVIARB | 33 |
| DIAM_STDARB | 18 |
| PERIMARB | 15 |
| LARGOANCHO_STDARB | 4 |
| PERIAREA_STDARB | 3 |
| ASIMETRÍA_STDARB | 3 |

Tabla 6-7. Relevancia de las características en la clasificación

6.5.2.- Ensayo 2: Un árbol de decisión con 12 características

En este ensayo se emplearon sólo 12 características, eliminando del conjunto de características descriptivas las desviaciones típicas de las características de forma y tamaño.

En este caso, el grado de acierto es el mismo que el obtenido en el ensayo anterior, 173 aciertos por 7 errores, pero con un volumen de datos inferior al reducir de 20 a 12 las características descriptivas. En cambio, ha aumentado el número de ramas del árbol de decisión, entendidas éstas como cada una de las combinaciones de condiciones necesarias para definir una clase, que en este caso es de 14 ramas por las 12 obtenidas en el caso anterior.

Los errores de clasificación más comunes corresponden a algarrobos clasificados como olivos (3 errores) y a confusión entre almendros y cítricos independientes (2 errores).

En la figura 6-12 se muestra el árbol de decisión creado.




Figura 6-12. Árbol de decisión creado a partir de 12 características

En la tabla 6-8, donde se refleja la relevancia de las características en la clasificación, se pone de manifiesto la coincidencia en las variables significativas para la clasificación, siendo notable la incorporación de la variable AREAARB en la clasificación del total de las parcelas de muestra.

| Característica | % de parcelas |
|----------------|---------------|
| AREAARB | 100 |
| NDVIARB | 69 |
| GARB | 67 |
| LARGOANCHOARB | 53 |
| PERIAREAARB | 52 |
| IRARB | 17 |
| PERIMARB | 16 |

Tabla 6-8. Relevancia de las características en la clasificación

6.5.3.- Ensayo 3: Diez árboles de decisión con 20 características

En este ensayo se utilizaron 20 características y se construyeron 10 árboles de decisión, asignando a cada muestra la clase más frecuente de las asignadas por los 10 árboles.

Las 180 muestras de entrenamiento se clasificaron correctamente sin cometer ningún error.

Las variables empleadas para la clasificación de todas las parcelas son relativas al tamaño de los árboles (AREAARB y AREA_STDARB), su forma (PERIAREAARB) y su respuesta espectral (NDVIARB y GARB). Las variables obtenidas como la desviación típica de una característica tienen un peso global en la clasificación inferior a las medias de las características. En la tabla 6-9 se recogen los porcentajes de parcelas clasificadas con las variables empleadas en la construcción de los 10 árboles

| Característica | % de parcelas |
|-------------------|---------------|
| AREAARB | 100 |
| AREA_STDARB | 100 |
| PERIAREAARB | 100 |
| NDVIARB | 100 |
| GARB | 100 |
| IRARB | 77 |
| PERIMARB | 59 |
| LARGOANCHOARB | 58 |
| ASIMETRIA_STDARB | 58 |
| COMPACIDADARB | 57 |
| DIAM_STDARB | 49 |
| ASIMETRIAARB | 42 |
| FRACTALARB | 41 |
| PERIAREA_STDARB | 38 |
| PERIM_STDARB | 33 |
| FRACTAL_STDARB | 33 |
| RARB | 28 |
| LARGOANCHO_STDARB | 28 |

Tabla 6-9. Relevancia de las características en la clasificación

6.5.4.- Ensayo 4: Diez árboles de decisión con 12 características

El último ensayo corresponde a la clasificación de las 180 parcelas de entrenamiento con 12 características y 10 árboles de decisión. El resultado obtenido fue de 179 parcelas clasificadas correctamente y la comisión de un error. La tabla 6-10 muestra la importancia de las variables empleadas en esta clasificación.

| Característica | % de parcelas |
|----------------|---------------|
| PERIMARB | 100 |
| AREAARB | 100 |
| PERIAREAARB | 100 |
| COMPACIDADARB | 100 |
| FRACTALARB | 100 |
| NDVIARB | 100 |
| GARB | 100 |
| IRARB | 93 |
| LARGOANCHOARB | 75 |
| ASIMETRIAARB | 53 |
| DIAMEQARB | 49 |
| RARB | 34 |

Tabla 6-10. Relevancia de las características en la clasificación

Los resultados obtenidos en los cuatro ensayos muestran la adecuación de la metodología propuesta para clasificar los objetos segmentados en distintas tipologías de cultivos. Trabajando con un solo árbol de clasificación se obtiene un grado de acierto del 96.1% sobre las muestras de entrenamiento, mientras que aplicando el método multclasificador *boosting*, en el cual cada uno de los árboles tiende a corregir los errores cometidos por el árbol anterior en la clasificación de las muestras de entrenamiento, el grado de acierto es del 100% empleando 20 variables y del 99.4% con 12 variables.

Del análisis de las variables empleadas en estos ensayos, se desprende que en los tres grupos de características descriptivas de los objetos: espectrales, de forma y de tamaño, hay características fundamentales para la correcta clasificación, mientras que hay otras cuya aportación es nula o muy reducida y que por tanto podrían eliminarse en trabajos posteriores. Entre las características espectrales, el índice NDVI y la banda VERDE son empleadas en los cuatro ensayos en la clasificación de la mayor parte de las parcelas, mientras que la banda del ROJO sólo se utiliza en los ensayos con *boosting* y con un porcentaje reducido. De las características de forma, los ratios LARGO/ANCHO y PERÍMETRO/ÁREA son los que aportan más información y son empleados en los cuatro ensayos, mientras que la aportación de la ASIMETRÍA, COMPACIDAD y DIMENSIÓN FRACTAL son más reducidas y sólo son empleadas en las clasificaciones por *boosting*. Por último, entre las características de tamaño, el ÁREA y el PERÍMETRO son las características más relevantes, mientras que el DIÁMETRO EQUIVALENTE puede eliminarse por su poca aportación en las clasificaciones realizadas.

6.5.5.- Evaluación de las clasificaciones

La evaluación de las clasificaciones se realizó por medio de un conjunto de muestras de evaluación distinto al utilizado para la creación de los árboles de decisión, formado por 30 parcelas de cada una de las clases consideradas. De forma, que los resultados obtenidos muestran, de forma más fiable, la capacidad de los árboles de decisión para clasificar las tipologías de cultivos arbóreos que los resultados mostrados hasta el momento correspondientes a las muestras de aprendizaje.

Las tres clases correspondientes a cultivos cítricos se han fundido en una sola, ya que el objetivo principal del estudio no es la identificación de distintas tipologías dentro de un mismo cultivo sino la separación entre distintos cultivos.

Las tablas 6-11, 6-12, 6-13 y 6-14 muestran las matrices de confusión obtenidas para los cuatro ensayos realizados. En todos los casos se ha calculado la fiabilidad global como el cociente de las parcelas correctamente clasificadas (suma de la diagonal principal) entre el número total de muestras. También se calculan para cada clase la fiabilidad del productor, entendida como el cociente de parcelas de una clase correctamente clasificadas entre el número de parcelas de esa clase y la fiabilidad de usuario obtenida como el

cociente entre las parcelas de una clase bien clasificadas y el total de las parcelas clasificadas en esa clase. La fiabilidad de productor indica los errores por defecto, mientras que la fiabilidad de usuario muestra los errores por exceso.

Los resultados del primer ensayo (tabla 6-11) muestran una fiabilidad de productor elevada para las clases algarrobos, almendros y cítricos. Por otra parte, la clase olivos tiene un valor de fiabilidad de productor más bajo ya que existe un número elevado de parcelas de olivos asignadas a la clase algarrobos. Por lo que respecta a la fiabilidad de usuario, los cítricos y los olivos tienen valores elevados, correspondiendo a los algarrobos y los almendros los valores más bajos. En el caso de los algarrobos está motivado principalmente por la clasificación de parcelas de olivos en la clase algarrobos, mientras que en el caso de los almendros se debe a la confusión con la clase cítricos. La fiabilidad global obtenida es del 83%.

| | | Clasificación | | | | | |
|-------------------|------------|---------------|----------|--------|-------|------------------|--|
| V. Terreno | Algarrobos | Almendros | Cítricos | Olivos | TOTAL | F. Productor | |
| Algarrobos | 25 | | 5 | | 30 | 0.83 | |
| Almendros | 1 | 28 | 1 | | 30 | 0.93 | |
| Cítricos | 3 | 9 | 77 | 1 | 90 | 0.86 | |
| Olivos | 9 | | 1 | 20 | 30 | 0.67 | |
| TOTAL | 38 | 37 | 84 | 21 | 180 | | |
| F. Usuario | 0.66 | 0.76 | 0.92 | 0.95 | | F.G.=0.83 | |

Tabla 6-11. Matriz de confusión del ensayo 1: Un árbol de clasificación y 20 variables

La matriz de confusión del segundo ensayo (tabla 6-12) muestra un incremento significativo de la fiabilidad de productor para la clase olivos respecto al ensayo 1 (de 0.67 a 0.87), al mismo tiempo que empeora la correspondiente a los algarrobos (de 0.83 a 0.70), confirmándose la confusión entre ambas clases detectada en el ensayo anterior. Al mismo tiempo, las fiabilidades de usuario de ambas clases tienen comportamientos inversos; la fiabilidad de usuario de los algarrobos aumenta, mientras que la de los olivos disminuye. Las clases restantes muestran resultados similares a los obtenidos en el primer ensayo. Así como la fiabilidad global que coincide con la obtenida anteriormente.

| | | Clasificación | | | | | |
|-------------------|------------|---------------|----------|--------|-------|------------------|--|
| V. Terreno | Algarrobos | Almendros | Cítricos | Olivos | TOTAL | F. Productor | |
| Algarrobos | 21 | | 3 | 6 | 30 | 0.70 | |
| Almendros | | 28 | 2 | | 30 | 0.93 | |
| Cítricos | 5 | 10 | 74 | 1 | 90 | 0.82 | |
| Olivos | 4 | | | 26 | 30 | 0.87 | |
| TOTAL | 30 | 38 | 79 | 33 | 180 | | |
| F. Usuario | 0.70 | 0.74 | 0.94 | 0.79 | | F.G.=0.83 | |

Tabla 6-12. Matriz de confusión del ensayo 2: Un árbol de clasificación y 12 variables

En el tercer ensayo (tabla 6-13), utilizando 20 características y 10 árboles de decisión se produce un incremento en las fiabilidades de productor y en las de usuario, y por lo tanto en la fiabilidad global de la clasificación que pasa de un 83% a un 88%. Se reduce la confusión entre las clases algarrobos y olivos, al mismo tiempo que también se reduce entre las clases cítricos y almendros. Este ensayo, con el mayor número de variables implicadas y con la aplicación del método *boosting*, es el que mejores resultados obtiene, obteniendo todas las clases fiabilidades superiores al 75%.

| Clasificación | | | | | | |
|-------------------|------------|-----------|----------|--------|-------|------------------|
| V. Terreno | Algarrobos | Almendros | Cítricos | Olivos | TOTAL | F. Productor |
| Algarrobos | 25 | | 3 | 2 | 30 | 0.83 |
| Almendros | | 30 | | | 30 | 1.00 |
| Cítricos | 2 | 4 | 80 | 4 | 90 | 0.89 |
| Olivos | 6 | | 1 | 23 | 30 | 0.77 |
| TOTAL | 33 | 34 | 84 | 29 | 180 | |
| F. Usuario | 0.76 | 0.88 | 0.95 | 0.79 | | F.G.=0.88 |

Tabla 6-13. Matriz de confusión del ensayo 3: 10 árboles de clasificación y 20 variables

Los resultados del cuarto ensayo (tabla 6-14) con 12 variables y 10 árboles de decisión indican una mejora en la clasificación respecto al ensayo 2, donde se emplean las mismas variables descriptoras, de las clases algarrobos, almendros y cítricos frente a una disminución de las fiabilidades de la clase olivos.

La fiabilidad global se incrementa ligeramente respecto al segundo ensayo a costa del empleo de un mayor número de árboles de decisión, pero que tiene el inconveniente de la pérdida de inteligibilidad que se produce al utilizar 10 árboles con el método *boosting* en lugar de un solo árbol.

| Clasificación | | | | | | |
|-------------------|------------|-----------|----------|--------|-------|------------------|
| V. Terreno | Algarrobos | Almendros | Cítricos | Olivos | TOTAL | F.Productor |
| Algarrobos | 23 | | 4 | 3 | 30 | 0.77 |
| Almendros | | 29 | 1 | | 30 | 0.97 |
| Cítricos | 3 | 4 | 75 | 8 | 90 | 0.83 |
| Olivos | 6 | | | 24 | 30 | 0.80 |
| TOTAL | 32 | 33 | 80 | 35 | 180 | |
| F. Usuario | 0.72 | 0.88 | 0.94 | 0.69 | | F.G.=0.84 |

Tabla 6-14. Matriz de confusión del ensayo 4: 10 árboles de clasificación y 12 variables

En la actualización de ciertas bases de datos puede ser interesante la simple discriminación entre cultivos arbóreos de secano y de regadío. Por este motivo, se han agrupado en una clase, las tres clases de cultivos de secano, algarrobos, olivos y almendros y se han obtenido los valores de fiabilidades globales, de productor y de usuario

en los cuatro ensayos considerando solamente dos clases: frutales de secano y frutales de regadío. En la figura 6-13 se aprecia que en todos los casos las fiabilidades son superiores al 80%; obteniéndose fiabilidades globales entre el 88% y 92%.

Al tercer ensayo corresponden los mejores resultados en todos los índices, al igual que ocurre al considerar cuatro clases. Por otra parte, el ensayo con resultados más bajos corresponde al segundo, que es en el que menos variables se utilizan y sólo un árbol de clasificación.




Figura 6-13. Fiabilidades de clasificación para las clases secano y regadío.

Las fiabilidades obtenidas en los ensayos realizados están comprendidas en su mayoría entre 0.75 y 1. Estos valores se consideran adecuados dada la complejidad existente en la discriminación de las distintas especies arbóreas ya que, aun dentro de la misma especie, existen diferencias de edad, estado o mantenimiento que dificultan su identificación. Estos resultados confirman que las características propuestas describen eficazmente y desde distintos puntos de vista las propiedades de los sub-objetos integrantes de las parcelas. Al mismo tiempo, los árboles de decisión empleados se adaptan fielmente al conjunto de muestras de entrenamiento, proveyendo información valiosa e inteligible sobre el procedimiento de clasificación empleado.

6.6.- Clasificación de parcelas agrícolas

Este ensayo tiene por objeto evaluar el grado de fiabilidad que se obtiene en la clasificación de parcelas mediante su descripción con el conjunto de características descritas en esta tesis y su posterior clasificación con el algoritmo C5.0.

Para conseguir la descripción adecuada de todas las clases utilizadas y que el número de las muestras de aprendizaje de las distintas clases estuviera equilibrado, se consideraron únicamente las clases presentes en el área de estudio de las que existían como mínimo cien parcelas con un uso homogéneo en toda su superficie. Las clases consideradas en este ensayo son: algarrobos, caminos, cítricos, edificios, jardines, matorrales, olivos, plantones de cítricos, regadío y suelo desnudo. El centenar de parcelas correspondiente a cada clase se dividió en dos subconjuntos iguales, el de muestras de entrenamiento y el de muestras de evaluación. En la selección de muestras de la clase cítricos se seleccionaron parcelas correspondientes a las sub-clases integrantes de este cultivo, es decir, cítricos adultos alineados, irregulares, adultos independientes y cítricos independientes para que hubiese el mismo número de parcelas que en el resto de cultivos.

Para las 1000 parcelas utilizadas en el ensayo, se calcularon las características enumeradas en la tabla 6-16. La aplicación del multi-clasificador *boosting* con el algoritmo C5.0 sobre la mitad de estas parcelas permitió crear los diez árboles de clasificación utilizados para la clasificación de las parcelas restantes; el primero de los cuales se representa en la figura 6.14. Para evitar que las condiciones creadas fueran excesivamente ajustadas a las muestras de aprendizaje se impuso que el número mínimo de parcelas clasificadas por una condición fuera de cinco.

| Árbol | Errores (%) | Árbol | Errores (%) |
|-------|-------------|-----------------|-------------|
| 1 | 7.0 | 6 | 12.8 |
| 2 | 10.6 | 7 | 10.4 |
| 3 | 11.8 | 8 | 16.2 |
| 4 | 16.0 | 9 | 12.4 |
| 5 | 11.8 | 10 | 12.6 |
| | | <i>Boosting</i> | 0.0 |

Tabla 6-15. Grado de error de los árboles de decisión sobre las muestras de entrenamiento

En la tabla 6-15 se muestra que el porcentaje de error cometido por cada uno de los diez árboles de clasificación sobre el conjunto de muestras de aprendizaje varía entre el 7% y el 16.2%. La aplicación conjunta de los diez árboles clasifica las 500 muestras de aprendizaje correctamente sin cometer ni un solo error. Confirmándose la potencia de este multi-clasificador para crear árboles de clasificación capaces de adaptarse a las muestras de entrenamiento.

| CARACTERÍSTICAS ESPECTRALES DE LAS PARCELAS | |
|---|--|
| IRPAR | Media de la banda infrarroja |
| IR_STDPAR | Desviación típica de la banda infrarroja |
| RPAR | Media de la banda roja |
| R_STDPAR | Desviación típica de la banda roja |
| GPAR | Media de la banda verde |
| G_STDPAR | Desviación típica de la banda verde |
| NDVIPAR | Media del índice NDVI |
| NDVI_STDPAR | Desviación típica del índice NDVI |
| CARACTERÍSTICAS TEXTURALES DE LAS PARCELAS | |
| IB | Media de la intensidad de bordes |
| IB_STD | Desviación típica de la intensidad de bordes |
| UNIFORMIDAD | Uniformidad |
| ENTROPIA | Entropía |
| CONTRASTE | Contraste |
| MDI | Momento Diferencia Inverso |
| COVARIANZA | Covarianza |
| VARIANZA | Varianza |
| CORRELACION | Correlación |
| SKEWNESS | Coefficiente de asimetría |
| CURTOSIS | Curtosis |
| CARACTERÍSTICAS EXTRAÍDAS DE LA TRANSFORMADA DE HOUGH | |
| PORCDIR1 | Porcentaje de rectas en la 1ª dirección |
| PORCDIR2 | Porcentaje de rectas en la 2ª dirección |
| RODIR1 | Media de la separación entre las rectas de la 1ª dir. |
| RODIR1_STD | Desv. típica de la separación entre las rectas de la 1ª dir. |
| PORCPTODIR1 | Porcentaje de puntos en la 1ª dirección |
| PORCPTODIR1NORM | Porcentaje de puntos en la 1ª dirección normalizado por el área |
| RODIR1MEDIAN | Mediana de la separación entre las rectas de la 1ª dir. |
| RODIR1MODA | Moda de la separación entre las rectas de la 1ª dir. |
| RODIR2 | Media de la separación entre las rectas de la 2ª dir. |
| RODIR2_STD | Desv. típica de la separación entre las rectas de la 2ª dir. |
| PORCPTODIR2 | Porcentaje de puntos en la 2ª dirección |
| PORCPTODIR2NORM | Porcentaje de puntos en la 2ª dirección normalizado por el área |
| RODIR2MEDIAN | Mediana de la separación entre las rectas de la 2ª dir. |
| RODIR2MODA | Moda de la separación entre las rectas de la 2ª dir. |
| DIFANGUL | Diferencia angular entre las dos direcciones principales |
| CARACTERÍSTICAS EXTRAÍDAS DEL SEMIVARIOGRAMA | |
| POS1MAX | Posición del primer máximo |
| GP1 | Parámetro general 1 |
| GP4 | Parámetro general 4 |
| GP5 | Parámetro general 5 |
| FMP2 | Parámetro del primer máximo 2 |
| FMP4 | Parámetro del primer máximo 4 |
| FMP7 | Parámetro del primer máximo 7 |
| SMP1 | Parámetro del segundo máximo 1 |
| SMP3 | Parámetro del segundo máximo 3 |
| SMP7 | Parámetro del segundo máximo 7 |
| VPEND1 | Pendiente entre el primer máximo y el primer mínimo |
| VPEND2 | Pendiente entre el segundo máximo y el primer mínimo |
| GP4N | Parámetro general 4 normalizado por la varianza total del semivariograma |

| CARACTERÍSTICAS EXTRAÍDAS DE LA CLASIFICACIÓN POR PÍXEL | |
|---|---|
| AGUA | Porcentaje de píxeles de la clase <i>agua</i> |
| ASFALTO | Porcentaje de píxeles de la clase <i>asfalto</i> |
| EDIFAMAR | Porcentaje de píxeles de la clase <i>edificios amarillos</i> |
| EDIFAZUL | Porcentaje de píxeles de la clase <i>edificios azules</i> |
| FRUREG | Porcentaje de píxeles de la clase <i>frutales de regadío</i> |
| FRUSEC | Porcentaje de píxeles de la clase <i>frutales de secano</i> |
| MATORRAL | Porcentaje de píxeles de la clase <i>matorral</i> |
| REGADIO | Porcentaje de píxeles de la clase <i>regadío</i> |
| SOMBRAS | Porcentaje de píxeles de la clase <i>sombras</i> |
| SDCLARO | Porcentaje de píxeles de la clase <i>suelo desnudo claro</i> |
| SDOSCURO | Porcentaje de píxeles de la clase <i>suelo desnudo oscuro</i> |
| CARACTERÍSTICAS TOPOGRÁFICAS | |
| DIST | Distancia media a la costa |
| COTA | Altitud media |
| PTE | Pendiente media |
| CARACTERÍSTICAS DE FORMA DE LA PARCELA | |
| PERIMPAR | Perímetro |
| AREAPAR | Superficie |
| DIAMEQPAR | Diámetro equivalente |
| ASIMETRIAPAR | Índice de asimetría |
| COMPACPAR | Índice de compacidad |
| FRACTALPAR | Dimensión fractal |
| LARGOANCHOPAR | Cociente entre largo y ancho |
| PERIAREAPAR | Cociente entre perímetro y superficie |
| CARACTERÍSTICAS ESPECTRALES DE LOS ÁRBOLES SEGMENTADOS | |
| IRARB | Media de la banda infrarroja |
| RARB | Media de la banda roja |
| GARB | Media de la banda verde |
| NDVIARB | Media del índice NDVI |
| CARACTERÍSTICAS DE FORMA DE LOS ÁRBOLES SEGMENTADOS | |
| PERIMARB | Media del perímetro |
| PERIM_STDARB | Desviación típica del perímetro |
| AREAARB | Media de la superficie |
| AREA_STDARB | Desviación típica de la superficie |
| DIAMEQARB | Media del diámetro equivalente |
| DIAM_STDARB | Desviación típica del diámetro equivalente |
| LARGOANCHOARB | Media del cociente entre largo y ancho |
| LARGOANCHO_STDARB | Desviación típica del cociente entre largo y ancho |
| PERIAREAARB | Media del cociente entre perímetro y superficie |
| PERIAREA_STDARB | Desviación típica del cociente entre perímetro y superficie |
| ASIMETRIAARB | Media del índice de asimetría |
| ASIMETRIA_STDARB | Desviación típica del índice de asimetría |
| COMPACIDADARB | Media del índice de compacidad |
| COMPACIDAD_STDARB | Desviación típica del índice de compacidad |
| FRACTALARB | Media de la dimensión fractal |
| FRACTAL_STDARB | Desviación típica de la dimensión fractal |

Tabla 6-16. Nombre y descripción de las características calculadas

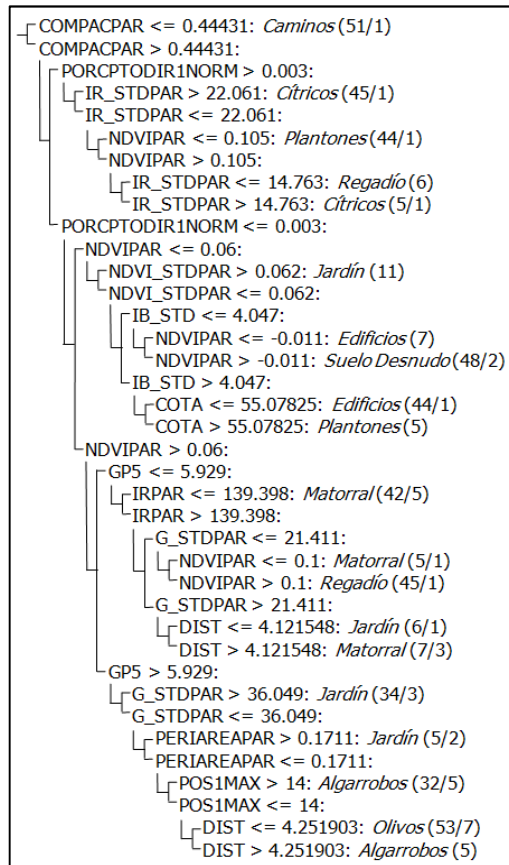


Figura 6-14. Árbol de decisión

El análisis del árbol mostrado en la figura 6-14 facilita la comprensión de la clasificación realizada. Por medio de la primera condición basada en la forma de la parcela se consigue separar los caminos del resto de parcelas. A continuación, un umbral sobre una característica extraída de la transformada de Hough permite separar las parcelas con una regularidad interna pertenecientes a las clases cítricos y plantones de cítricos del resto. La división entre ambas clases de cítricos se lleva a cabo según características espectrales. A continuación, el conjunto de parcelas donde la regularidad es menos importante se divide, según el índice NDVI de la parcela, entre parcelas con poca vegetación (correspondientes a las clases jardín, edificios, suelo desnudo y plantones) y con bastante vegetación (clases matorral, regadío, jardín, algarrobos y olivos). Ambos subconjuntos se continúan dividiendo según características espectrales, topográficas y extraídas del semivariograma.

Con las muestras de evaluación se determinó que la fiabilidad global con la que se realizó la clasificación es del 86%. En las tablas 6-17 y 6-18 se muestran la matriz de confusión y las fiabilidades de usuario y productor obtenidas.

| CLASIFICACIÓN | VERDAD TERRENO | | | | | | | | | | |
|---------------|----------------|---------|----------|-----------|--------|----------|--------|-----------|---------|---------------|-------|
| | Algarrobos | Caminos | Cítricos | Edificios | Jardín | Matorral | Olivos | Plantones | Regadío | Suelo desnudo | Total |
| Algarrobos | 38 | | | | | | 7 | 5 | | | 50 |
| Caminos | | 50 | | | 2 | 3 | | | 1 | 1 | 57 |
| Cítricos | | | 49 | | | 1 | 1 | | 1 | | 52 |
| Edificios | | | | 41 | 2 | | 1 | | | 1 | 45 |
| Jardín | | | | 1 | 46 | 3 | 3 | | | | 53 |
| Matorral | 6 | | | 1 | | 34 | 1 | | 3 | | 45 |
| Olivos | 4 | | | | | | 38 | | | | 42 |
| Plantones | | | 1 | 6 | | | 1 | 48 | | 6 | 62 |
| Regadío | 2 | | | | | 2 | | | 45 | | 49 |
| Suelo desnudo | | | | 1 | | | | 2 | | 42 | 45 |
| Total | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 500 |

Tabla 6-17 Matriz de confusión de la clasificación de parcelas

El análisis de la matriz de confusión revela que la clasificación de las parcelas agrícolas se realiza con una fiabilidad elevada. No obstante, los errores de clasificación más abundantes se producen entre ciertas clases con características similares, como por ejemplo, las parcelas de olivos y algarrobos, ciertas parcelas de algarrobos relativamente descuidadas con las superficies de matorral y los plantones de cítricos con los edificios y las parcelas de suelo desnudo, etc.

| | Fiab. Usuario | Fiab. Productor |
|---------------|---------------|-----------------|
| Algarrobos | 0.76 | 0.76 |
| Caminos | 0.88 | 1.00 |
| Cítricos | 0.94 | 0.98 |
| Edificios | 0.91 | 0.82 |
| Jardín | 0.87 | 0.92 |
| Matorral | 0.76 | 0.68 |
| Olivos | 0.90 | 0.76 |
| Plantones | 0.77 | 0.96 |
| Regadío | 0.92 | 0.90 |
| Suelo desnudo | 0.93 | 0.84 |

Tabla 6-18. Fiabilidades de usuario y de productor de la clasificación de parcelas

La clasificación mediante árboles de decisión realiza de forma implícita una selección de las características con un mayor poder discriminante. En la tabla 6-19 se muestra, para las características empleadas en la clasificación, el porcentaje medio de parcelas clasificadas con cada una de ellas. La variable más utilizada es COMPACPAR que se ha utilizado principalmente para separar los caminos del resto de parcelas. A continuación, la característica PORCPTODIR1NORM indicadora de la existencia de árboles alineados en una determinada dirección. Las características siguientes son NDVIPAR y NDVI_STDPAR que describen la cantidad y la variabilidad de la vegetación en la parcela. Con porcentajes de utilización inferiores al 30% se combinan variables extraídas del semivariograma, con variables extraídas de la segmentación de árboles, características topográficas y de textura. El único grupo de características que no ha contribuido en la clasificación de ninguna parcela es el correspondiente a la clasificación por píxel.

| % | CARACTERÍSTICA | % | CARACTERÍSTICA | % | CARACTERÍSTICA |
|------|------------------|------|-----------------|-----|-------------------|
| 69.1 | COMPACPAR | 10.0 | RPAR | 2.6 | DIAMEQARB |
| 64.6 | PORCPTODIR1NORM | 8.7 | PORCPTODIR2NORM | 2.5 | COMPACIDAD_STDARB |
| 62.8 | NDVIPAR | 8.3 | PERIAREAPAR | 2.5 | GP1 |
| 31.4 | NDVI_STDPAR | 8.1 | FMP2 | 2.4 | AREAPAR |
| 29.2 | GP4 | 7.5 | PORCPTODIR1 | 2.3 | CURTOSIS |
| 28.1 | NDVIARB | 6.2 | SMP3 | 2.2 | FRACTALARB |
| 23.5 | COTA | 5.6 | FMP7 | 2.1 | PORCDIR1 |
| 23.1 | GP5 | 5.5 | PERIAREAARB | 1.9 | DIFANGUL |
| 21.2 | IB_STD | 4.7 | VPTE2 | 1.7 | ASIMETRIAARB |
| 16.7 | DIST | 4.3 | POS1MAX | 1.7 | COMPACIDADARB |
| 16.6 | IRPAR | 3.3 | CORRELACION | 1.7 | PERIMPAR |
| 14.9 | ENTROPIA | 3.2 | IR_STDPAR | 1.6 | IRARB |
| 14.8 | FMP4 | 3.0 | IB | 1.2 | RODIR1MODA |
| 13.2 | UNIFORMIDAD | 3.0 | PERIM_STDARB | 0.9 | GPAR |
| 11.7 | G_STDPAR | 2.9 | FRACTALPAR | 0.6 | DIAM_STDARB |
| 11.1 | ASIMETRIA_STDARB | 2.7 | SKEWNESS | 0.6 | ASIMETRIAPAR |

Tabla 6-19. Contribución de las características en la clasificación de parcelas

6.7.- Incorporación del uso previo contenido en una base de datos en la clasificación de parcelas

El objetivo de este ensayo es evaluar la conveniencia de incorporar en el proceso de clasificación el uso previo contenido en la base de datos como una variable descriptora más de los objetos. Ya que el grado de actualización de una base de datos es un dato desconocido a priori se pretende comprobar cómo influye la desactualización de esta información en la precisión de la clasificación y en la relevancia de esta variable en la clasificación.

Dado que este ensayo está centrado en el análisis de la incorporación de la información alfanumérica como variable adicional, se utilizaron como variables descriptoras de los objetos sólo las variables espectrales basadas en la media y la desviación típica de los niveles digitales de los píxeles que forman cada objeto en cada una de las bandas disponibles y en el índice NDVI. El empleo de un mayor número variables puede dificultar la interpretación de los resultados. La clasificación se realizó con el algoritmo C5.0 y el método multclasificador *boosting*.

Con el objeto de conocer a priori el grado de actualización y corrección de la base de datos, se asignó a la variable *uso previo* del conjunto de parcelas utilizadas en el ensayo la clase real obtenida mediante fotointerpretación y visitas de campo.

Para la realización del ensayo se seleccionaron 150 parcelas de cada una de las clases existentes. De ellas, un tercio se utilizaron para entrenamiento del clasificador y el resto para la evaluación del rendimiento del mismo.

En un primer ensayo se realizó la clasificación únicamente con las características espectrales de cada una de las parcelas. En cambio, en las clasificaciones sucesivas se incorporó la información sobre el uso previo contenido en la base de datos. La información de la base de datos se alteró de forma controlada de modo que el grado de actualización/corrección de la base de datos varía desde el 40% hasta el 90% en incrementos del 10%.

En la figura 6-15 se muestran los distintos valores de fiabilidad global de las clasificaciones. La clasificación realizada sin considerar el uso previo contenido en la base de datos presenta una fiabilidad global del 77.3%. La incorporación del uso previo con distintos grados de actualización produce un incremento continuado de las fiabilidades

globales hasta llegar a una fiabilidad global del 93% cuando la información del uso previo está actualizada al 90%.




Figura 6-15. Fiabilidades globales obtenidas en los ensayos

Es importante destacar el hecho de que, la incorporación del uso previo, en ningún caso ha afectado negativamente a la clasificación aun en el caso de que la información de esta variable sea mayoritariamente errónea como ocurren en las clasificaciones con un grado de actualización de la base de datos del 40 ó el 50%.




Figura 6-16. Fiabilidades de productor y de usuario obtenidas en las clasificaciones

Analizando los resultados de fiabilidades de productor y de usuario de cada una de las clases de estudio (figura 6-16) se aprecia claramente cómo en todos los casos las fiabilidades van aumentando a medida que se actualiza la información relativa al uso previo que se añade en la clasificación. Las fiabilidades aumentan especialmente en aquellas clases cuyas fiabilidades obtenidas únicamente con la información espectral eran más bajas. Del análisis de los gráficos de fiabilidades se deduce que la incorporación de la base de datos, con un determinado grado de actualización, asegura que todas las clases se clasifican con una fiabilidad mínima aproximadamente igual a la de la base de datos

incorporada. El hecho de añadir la información sobre el uso previo de las parcelas en ningún caso supone una reducción de fiabilidad sino que aporta información significativa sólo en aquellos casos en los que su poder discriminante sea mayor que el del resto de variables.

En la figura 6-17 se comparan los errores cometidos en la clasificación en la que no se considera la información previa, con los errores cometidos en cada una de las clasificaciones que sí incorporan la información relativa al uso previo. De un total de 900 parcelas de evaluación, 204 se clasificaron erróneamente en la clasificación que no considera el uso previo contenido en la base de datos. En el caso de la clasificación que incluye la base de datos actualizada en un 40%, se cometen 175 errores en común con la clasificación anterior, mientras que 29 errores son corregidos y se cometen 23 nuevos errores, no comunes con la clasificación anterior. Al aumentar el grado de actualización de la información disminuyen los errores comunes, aumentando por tanto las correcciones, mientras que el número de errores no comunes se mantiene aproximadamente estable en torno a 25 parcelas. El número total de errores cometidos en cada una de las clasificaciones se puede obtener del gráfico mediante la suma de las barras en tonos rojizos.




Figura 6-17. Comparación de errores entre clasificaciones

La principal ventaja del clasificador C5.0, además de su capacidad de gestionar datos discretos, radica en su capacidad para seleccionar las variables según su potencial para separar los objetos de entrenamiento en grupos homogéneos. De hecho, cuanto menos útil es una variable para separar los objetos, menos será empleada esa variable, llegando incluso a ser desechada en la construcción de los árboles de clasificación. En cada una de las seis clasificaciones en las que se consideró el uso previo como variable descriptora se evaluó la influencia de la variable en la clasificación. Para ello se calculó, en cada árbol, el número de muestras de entrenamiento clasificadas según una condición en

la que se evaluara la variable *uso previo*. Dado que en cada clasificación se utilizaron diez árboles de decisión por la aplicación del método *boosting*, se calculó para cada clasificación el número medio de parcelas de entrenamiento clasificadas considerando su uso previo en los diez árboles.

La figura 6-18 muestra el grado de participación medio de la característica *uso previo* en los distintos ensayos. Para una actualización de la base de datos del 40%, la participación es ínfima, ya que sólo un 1.6% de las parcelas se ha clasificado según una regla en la que se evalúa esta característica. A medida que el grado de actualización de la información va aumentando, el porcentaje de parcelas clasificadas según esta variable aumenta hasta un máximo del 53.3%.




Figura 6-18. Porcentaje medio de parcelas de entrenamiento clasificadas considerando el uso previo

En la tabla 6-20 se refleja el número de parcelas clasificadas teniendo en cuenta la característica *uso previo*.

| | 40% | 50% | 60% | 70% | 80% | 90% |
|----------|------------|--------------|---------------|---------------|-------------|-------------|
| Árbol 1 | 73 | 73 | 171 | 281 | 450 | 450 |
| Árbol 2 | 0 | 143 | 141 | 305 | 0 | 0 |
| Árbol 3 | 0 | 0 | 0 | 132 | 0 | 450 |
| Árbol 4 | 0 | 0 | 261 | 0 | 450 | 0 |
| Árbol 5 | 0 | 266 | 0 | 450 | 0 | 299 |
| Árbol 6 | 0 | 0 | 127 | 34 | 0 | 0 |
| Árbol 7 | 0 | 0 | 171 | 0 | 450 | 450 |
| Árbol 8 | 0 | 0 | 132 | 450 | 0 | 0 |
| Árbol 9 | 0 | 156 | 65 | 153 | 0 | 450 |
| Árbol 10 | 0 | 159 | 188 | 118 | 450 | 302 |
| Promedio | 7.3 (1.6%) | 79.7 (17.7%) | 125.6 (27.9%) | 192.3 (42.7%) | 180 (40.0%) | 240 (53.4%) |

Tabla 6-20. Porcentaje de parcelas clasificadas en cada árbol considerando el uso previo

Para un total de 450 parcelas utilizadas en la creación de los árboles, en la primera clasificación con la base de datos actualizada en un 40%, sólo se consideró esta variable en 73 parcelas y en un solo árbol. En el último caso, con la información del uso previo correcta en un 90% de los casos, la variable se emplea en seis de los diez árboles creados, cuatro de los cuales emplean esta variable en la primera regla del árbol. En la aplicación del método *boosting* el primer árbol generado siempre es el que mejor se adapta al conjunto de muestras de entrenamiento. En el caso de la información del uso actualizada al 90%, se ve cómo la primera variable utilizada en el primer árbol es el uso previo ya que es la variable que mayor poder discriminante tiene. Este primer árbol, centrado principalmente en la información de la base de datos, erró en la clasificación de 33 parcelas, siendo que 45 parcelas (10%) tenían la clase erróneamente asignada en la base de datos. En la construcción del segundo árbol, el peso asignado a las muestras erróneamente clasificadas en el primer árbol es muy superior al asignado a las clasificadas correctamente, lo que implica que el segundo árbol está dirigido a la clasificación de las parcelas cuya clase es errónea en la base de datos, por lo que las reglas de clasificación tienen en cuenta las variables espectrales en lugar de la información de la BBDD. Tras la aplicación del segundo árbol, que comete 103 errores, los pesos de las muestras se calculan de nuevo para la construcción del tercer árbol, obteniéndose pesos más parecidos entre las muestras erróneamente y correctamente clasificadas en el segundo árbol. Dado que todas las muestras tienen pesos similares, de nuevo es la variable relativa al uso previo la que tiene un mayor poder discriminante y es en la que se basa el tercer árbol de decisión. Este proceso se va repitiendo a lo largo de los diez árboles de decisión empleados, alternándose la utilización de la variable correspondiente al uso previo, que da lugar a árboles muy precisos, con su omisión que da lugar a árboles poco precisos. En la figura 6-19 se muestran las condiciones establecidas en los cuatro primeros árboles de decisión creados para el ensayo con la BBDD actualizada al 90%.

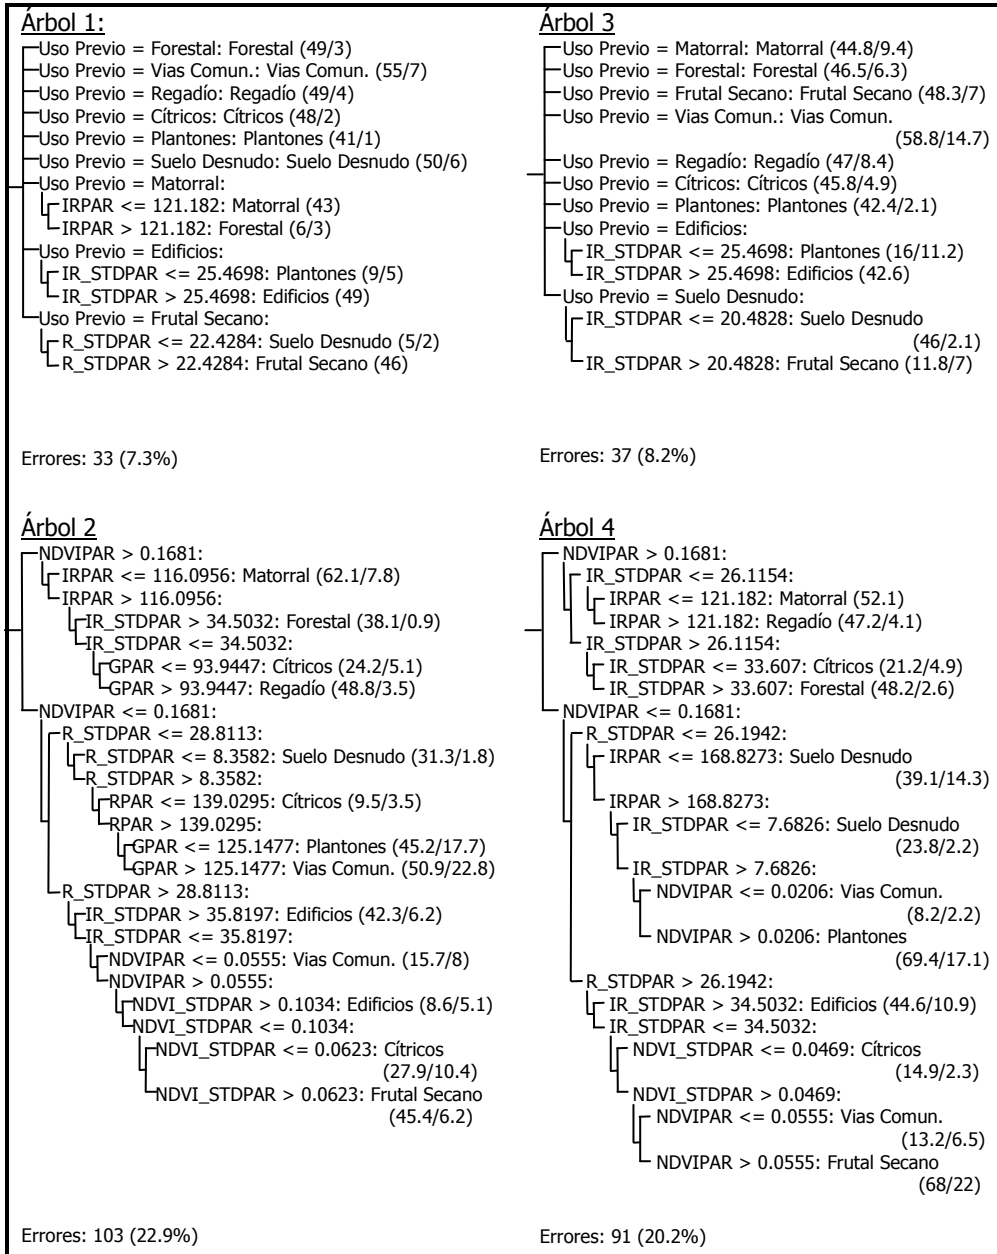


Figura 6-19. Árboles de clasificación creados en el ensayo con la BBDD actualizada al 90%

En el proceso de actualización de una base de datos sobre usos del suelo, la clase asignada en la clasificación debe compararse con la información contenida en la base de datos, de forma que las discrepancias entre ambas pongan de manifiesto tanto los errores de la clasificación como los errores por desactualización de la base de datos. En este ensayo al disponer de la información de verdad terreno para todas las parcelas se puede realizar un análisis más exhaustivo de los resultados.

En la tabla 6-21 se muestran las posibles combinaciones entre los tres conjuntos de datos a comparar.

| | Verdad terreno | Base de datos | Clasificación |
|----------|----------------|---------------|---------------|
| Aciertos | A | A | A |
| Cambios | A | B | A |
| Error 1 | A | A | B |
| Error 2 | A | C | B |
| Error 3 | A | B | B |

Tabla 6-21. Tipos de combinaciones posibles de datos

Sea el uso de una parcela el valor A en el instante de la toma de la imagen. Las posibles combinaciones de los datos dan lugar a las categorías siguientes:

- *Aciertos*: Coincide la clasificación con la base de datos y la verdad terreno.
- *Cambios*: La clasificación asigna correctamente el uso que es incorrecto en la base de datos.
- *Error tipo 1*: La clasificación asigna incorrectamente el uso, que es correcto en la base de datos.
- *Error tipo 2*: La clasificación asigna incorrectamente el uso, que también es incorrecto en la base de datos y ambos no coinciden.
- *Error tipo 3*: La clasificación asigna incorrectamente el uso, que también es incorrecto en la base de datos y ambos coinciden.

A fin de no introducir errores en la base de datos es recomendable que las modificaciones a la misma estén confirmadas por un intérprete. La revisión de las parcelas cuya clase no coincide en la clasificación y en la base de datos incluye a las parcelas de las categorías *cambios*, *error tipo 1* y *error tipo 2*. Quedando sin revisar los *aciertos*, cuya revisión no es necesaria, y los *errores tipo 3*, por no disponer de un método de detección al coincidir el uso de la base de datos con el de la clasificación y ser ambos erróneos.

En la tabla 6-22 se muestra para cada uno de los ensayos, variando el grado de actualización de la base de datos y con la inclusión o no de la información contenida en la base de datos como variable descriptora, el número de parcelas de evaluación en cada categoría.

En el caso de no incluir el *uso previo*, el número de errores de clasificación es siempre el mismo (204), ya que se considera siempre la misma clasificación, mientras que

lo que varía es el grado de actualización de la base de datos. Por tanto, las parcelas erróneamente clasificadas se redistribuyen entre las tres categorías de errores.

| | CON LA VARIABLE DESCRIPTORA <i>USO PREVIO</i> | | | | | SIN LA VARIABLE DESCRIPTORA <i>USO PREVIO</i> | | | | |
|-----|---|---------|--------------|--------------|--------------|---|---------|--------------|--------------|--------------|
| | Aciertos | Cambios | Error tipo 1 | Error tipo 2 | Error tipo 3 | Aciertos | Cambios | Error tipo 1 | Error tipo 2 | Error tipo 3 |
| 40% | 273 | 429 | 71 | 111 | 16 | 269 | 427 | 75 | 110 | 19 |
| 50% | 357 | 360 | 77 | 71 | 35 | 340 | 356 | 94 | 87 | 23 |
| 60% | 487 | 275 | 43 | 60 | 35 | 417 | 279 | 113 | 82 | 9 |
| 70% | 571 | 194 | 49 | 51 | 35 | 483 | 213 | 137 | 61 | 6 |
| 80% | 690 | 124 | 25 | 14 | 47 | 553 | 143 | 162 | 34 | 8 |
| 90% | 797 | 40 | 11 | 4 | 48 | 629 | 67 | 179 | 23 | 2 |

Tabla 6-22. Parcelas de evaluación por categoría

Los resultados de la tabla muestran que independientemente del grado de actualización de la base de datos, la inclusión del *uso previo* produce un incremento en el número de parcelas correctamente clasificadas (suma de las categorías *aciertos* y *cambios*). Este incremento de fiabilidad es tanto mayor cuanto mayor es el grado de actualización de la base de datos.

Los *errores de tipo 1* aumentan cuanto más actualizada esté la base de datos si no se considera el *uso previo*. En cambio, al considerar la información previa, disminuyen significativamente al aumentar el grado de actualización de la base de datos ya que también aumenta la influencia de esta variable en la clasificación.

Los *errores de tipo 2* disminuyen al aumentar el grado de actualización de la base de datos. Cuando se emplea la variable *uso previo* esa disminución es debida al aumento de la fiabilidad de las clasificaciones, mientras que cuando no se emplea esta variable, esta disminución se debe a que los errores dejan de ser de tipo 2 y pasan a ser de tipo 1.

Los *errores de tipo 3* aumentan progresivamente al aumentar la actualización de la base de datos cuando se considera el *uso previo*. El aumento del grado de participación de la variable *uso previo* en la clasificación que se produce cuanto más actualizada está la base de datos, implica que parte de los errores contenidos en la base de datos se trasladan a la clasificación y son indetectables mediante la comparación con la base de datos. En cambio, cuando no se considera el *uso previo*, este tipo de error disminuye al aumentar la actualización de la base de datos ya que siendo siempre el mismo número de errores de clasificación el número de errores de las bases de datos es menor y por tanto, menor es la posibilidad de que coincidan ambos.

El número de parcelas a revisar (suma de las categorías *cambios* y *errores tipo 1* y *2*) disminuye drásticamente cuando se considera el *uso previo* al aumentar tanto la fiabilidad de las clasificaciones como el grado de actualización de la base de datos. Según la tabla 6-17 las parcelas a revisar pasarían de ser 611 cuando la base de datos tiene una

actualización del 40% a 55 parcelas cuando la actualización es del 90 %. Este efecto positivo se ve contrarrestado porque el número de parcelas del *error tipo 3* que no son detectables, aumentan de 16 a 48. En cambio, cuando no se considera el *uso previo* la reducción del número de parcelas a revisar no es tan importante, ya que se pasa de 612 a 269 parcelas

Las conclusiones extraídas de este ensayo son las siguientes:

- El uso previo de una parcela puede considerarse en la asignación de una clase a la parcela ya que, de alguna forma, está relacionado con la probabilidad del uso actual de la parcela.
- La incorporación de información alfanumérica en un proceso de clasificación requiere clasificadores capaces de tratar esta información. El algoritmo C5.0 es capaz de gestionar eficazmente variables alfanuméricas, y al mismo tiempo, seleccionar adecuadamente las variables que proporcionan una mayor separabilidad en cada caso.
- En todos los supuestos planteados, la incorporación del uso anterior produce un incremento de la fiabilidad de la clasificación proporcional al grado de actualización de la información. De forma general, la incorporación de información alfanumérica desactualizada no produce descensos de fiabilidad de la clasificación.
- La relevancia de la variable *uso previo* en la clasificación es proporcional al grado de actualización de la base de datos. Cuando esta información aporta menos a la separabilidad de las clases que otras variables no participa en la clasificación.
- La fiabilidad con la que se clasifican los objetos es un valor cercano al grado de actualización de la base de datos sobre todo principalmente en aquellas parcelas cuya clasificación resulta más compleja con el resto de variables empleadas.
- Esta metodología permite intuir patrones o relaciones sobre la evolución de los usos en un territorio entre dos fases de actualización de una base de datos de usos del suelo. Pueden detectarse las tendencias que siguen determinados cambios de usos del suelo a través del análisis de las reglas creadas en los árboles de decisión.
- En un proceso de actualización de una base de datos cartográfica, la incorporación en la clasificación del uso previo reduce el número de parcelas a revisar a costa de que parte de los errores de la base de datos se trasladen a la clasificación. El mayor grado de automatización implica una reducción en la precisión de la clasificación de los objetos de la base de datos.

6.8.- Actualización de una base de datos cartográfica

En este ensayo se aplican de forma conjunta las distintas metodologías propuestas con el fin de actualizar una base de datos de usos del suelo en el área de estudio. La base de datos utilizada corresponde a la cartografía catastral. Se pretende comprobar la adecuación del empleo conjunto de las metodologías desarrolladas así como establecer una secuencia de pasos orientada a lograr la actualización de la base de datos. El conjunto de clases a determinar vienen descritas en el apartado 4.3.1. Los pasos establecidos son:

1.- Preprocesado de la información: En esta fase se corrigen y se comprueban las imágenes, la base cartográfica y la base alfanumérica a utilizar.

El procesado de las imágenes tiene por objeto generar una ortoimagen con las mejores propiedades métricas y radiométricas que cubra de forma continua todo el territorio a analizar. Para ello, es necesaria la aplicación del método de fusión de imágenes adecuado, la corrección de las imágenes tanto radiométricamente como geométricamente y la generación de mosaicos.

La cartografía base debe ser comprobada a varios niveles. Es imprescindible que el sistema geodésico de referencia coincida con el empleado en la ortoimagen, el grado de coincidencia entre la cartografía y el mosaico debe ser cercano a la resolución espacial de la imagen, la coherencia topológica de la cartografía debe estar garantizada, etc. Es en esta fase cuando se deben extraer del proceso aquellas parcelas que por sus reducidas dimensiones o por ser polígonos "astilla" no deben ser procesadas.

La base de datos alfanumérica debe ser depurada con el objeto de reducir errores en el procesado posterior. Todas las parcelas deben tener un identificador único y un uso asignado conforme a la leyenda.

2.- Cálculo de características descriptivas: En este proceso se realiza la extracción de la ortoimagen de la superficie correspondiente a los límites cartográficos de la parcela. Mediante los procesos descritos en el capítulo V, se asigna a cada parcela un vector de características de forma que la parcela quede descrita de la forma lo más amplia posible.

3.- Extracción de vías de comunicación: Las carreteras y caminos se extraen del conjunto de objetos de la base de datos a partir de las características descriptivas de la forma de las parcelas.

4.- Selección de las características más eficientes: Debido al elevado número de características obtenidas para las parcelas es conveniente realizar una selección de las variables con el objeto de emplear en la clasificación sólo aquellas características que aporten información significativa para el proceso.

5.- Clasificación de las parcelas: La selección de un conjunto de parcelas para el entrenamiento del clasificador junto con las características extraídas de las parcelas, permiten realizar la asignación del conjunto de parcelas a alguna de las clases definidas en la leyenda. En este trabajo se propone la clasificación mediante árboles de decisión.

6.- Evaluación de la clasificación y análisis de los errores cometidos: La selección de un conjunto de parcelas de forma manual permite evaluar el resultado de la clasificación. El análisis de los resultados obtenidos es fundamental para cuantificar la calidad de los procesos automatizados.

7.- Comparación de la clase asignada con la contenida en la base de datos: Mediante la comparación del uso asignado en la clasificación con la información proveniente de la base de datos se detectan tanto los cambios ocurridos en el uso del suelo como los errores contenidos en la base de datos y los cometidos en la clasificación.

8.- Revisión mediante fotointerpretación y visitas de campo: Las discrepancias detectadas en el paso anterior deben ser validadas por un fotointérprete quien asignará el uso definitivo a las parcelas. En caso de incertidumbre en el uso a asignar se realizará visita de campo para definir el uso real de la parcela.

6.8.1.- Cálculo de las características descriptivas para cada parcela

La integración de la cartografía vectorial con la ortoimagen permite extraer de la imagen, la región que corresponde a la representación de cada una de las parcelas. En la tabla 6.16 se muestra el nombre y la descripción del conjunto de características calculadas sobre la región de la imagen representativa de cada parcela según la metodología desarrollada en el capítulo V.

El cálculo de las características descriptivas se limitó a aquellas parcelas cuya superficie fuese superior a 200 m², ya que se considera que los polígonos pequeños no garantizan que las variables extraídas tengan un significado coherente, especialmente en las características extraídas del semivariograma y de la transformada de Hough.

6.8.2.- Extracción de vías de comunicación

Debido a las características particulares de las vías de comunicación respecto al resto de elementos, se procedió a un procesamiento previo de los objetos existentes en la base de datos para extraer del conjunto de objetos aquellos pertenecientes a la clase *Vías de comunicación*. Los valores de los caminos o carreteras en variables como las extraídas de la segmentación de árboles, los relativos a marcos de plantación con la transformada de Hough o los calculados del semivariograma no son descriptivos de la clase real a la que pertenecen estos objetos, por lo que no se emplearon en la extracción de los mismos. Las variables utilizadas se limitaron a las características espectrales, texturales y de forma.

Se consideraron únicamente dos clases: *Vías de comunicación* y *Resto de parcelas*. Para cada una de estas clases, se seleccionaron como muestras de entrenamiento del clasificador un 10% de la cantidad de parcelas de cada clase. Así el total de muestras de aprendizaje está formado por 407 parcelas de la clase *Resto de parcelas* y 44 parcelas de la clase *Vías de comunicación*.

Con el algoritmo C5.0, se generó un árbol de decisión capaz de separar ambas clases. En la figura 6-20 se representa el árbol de decisión obtenido, formado por una única condición basada en la característica FRACTALPAR.




Figura 6-20. Árbol de decisión para la extracción de vías de comunicación

Este árbol clasifica correctamente 42 de las 44 muestras de entrenamiento correspondientes a la clase *Vías de comunicación* y 406 de las 407 muestras de la clase *resto de parcelas*. Cometiendo un error sobre el conjunto de muestras de entrenamiento del 0.3%.

La evaluación del árbol de decisión sobre el conjunto de parcelas de evaluación, reflejó que el error cometido fue del 1.5%. En la tabla 6-23 se recoge la matriz de confusión obtenida, que muestra la alta adecuación de la variable FRACTALPAR para diferenciar entre las parcelas de vías de comunicación y el resto de parcelas.

| Clasificación | Verdad Terreno | | |
|-------------------------|-------------------|----------------------|-----------------------|
| | Resto de parcelas | Vías de comunicación | Fiabilidad de usuario |
| Resto de parcelas | 3640 | 35 | 0.99 |
| Vías de comunicación | 24 | 357 | 0.94 |
| Fiabilidad de productor | 0.99 | 0.91 | F. Global 0.98 |

Tabla 6-23. Matriz de confusión de la extracción de vías de comunicación

La fiabilidad global alcanzada es del 98% y las fiabilidades de productor y de usuario son en todos los casos superiores al 90%.

El grado de exactitud con la que el árbol de decisión hace la clasificación es tan alto que la aplicación del método *boosting* no permite mejorarla, ya que el algoritmo no es capaz de generar otros árboles que complementen al inicial para aumentar la fiabilidad de la clasificación.

6.8.2.1.- Análisis de los errores cometidos en la extracción de vías de comunicación

Los errores por exceso, es decir, parcelas clasificadas erróneamente en la clase *vías de comunicación* se pueden agrupar en tres categorías:

- a) Caminos desaparecidos que han sido englobados en parcelas mayores, pero que no han sido eliminados en la cartografía (figura 6-21).

Estos errores están motivados por la desactualización de la base cartográfica utilizada y son útiles para detectar elementos que han desaparecido y, por tanto, los límites de los objetos adyacentes deben ser modificados.




Figura 6-21. Caminos desaparecidos y no eliminados en la cartografía

El número de errores de este tipo es de 7 sobre 24 y representan un 29% de los errores por exceso.

- b) Cursos fluviales clasificados como vías de comunicación (figura 6-22).
La forma alargada de los objetos hidrográficos hace que surja confusión con las vías de comunicación. Este tipo de errores podría detectarse consultando la clase previa contenida en la base de datos, de forma que si en la base de datos a

actualizar tienen el atributo correspondiente a hidrografía no se les asignara el uso *Vías de comunicación*.



Figura 6-22. Cursos fluviales clasificados como vías de comunicación

Los errores de este tipo presentes en la zona de estudio son 3, representando un 12.5% de los errores por exceso.

c) Parcelas con formas irregulares (figura 6-23).

La existencia de varios usos en una misma parcela da lugar a que aparezcan polígonos con formas irregulares. Por este motivo, son asignados a la clase *Vías de comunicación*. Este tipo de errores es el más numeroso con 14 elementos, un 58.5% del total.




Figura 6-23. Parcelas irregulares clasificadas como vías de comunicación

Los errores por defecto, correspondientes a vías de comunicación no detectadas son, en todos los casos, pequeños caminos cuyo valor para la variable FRACTALPAR es ligeramente inferior al umbral fijado (figura 6-24). El índice Dimensión fractal está basado en un cociente entre perímetro y superficie. Por ello, cuanto más alargado es un objeto,

mayor es el valor de este índice. Los caminos y carreteras suelen tener una anchura constante, por tanto, aquellos que tienen una longitud reducida quedan sin ser detectados por tener valores inferiores al conjunto de las vías de comunicación.




Figura 6-24. Caminos no detectados

6.8.3.- Selección de características

Una vez obtenidos los valores de las 89 variables descritas para todas las parcelas, es conveniente realizar un proceso selectivo para determinar cuáles de estas variables son las más relevantes en el proceso de clasificación y, al mismo tiempo, eliminar de la clasificación aquellas que proporcionan información redundante o que menos aportan a la discriminación entre las clases.

Para realizar este proceso de selección de variables, se eligió un conjunto de parcelas representativas de las clases presentes en el estudio. El número de parcelas de cada clase utilizadas para hacer el análisis es el 10% de la cantidad total de parcelas de esa clase en el conjunto de la zona de estudio (tabla 6-24). Para cada una de estas parcelas se conoce tanto su valor en las 89 variables como la clase de uso del suelo asignada por el intérprete.

El método utilizado es el análisis discriminante paso a paso. El análisis discriminante es una técnica estadística capaz de determinar qué variables permiten diferenciar a las clases y cuántas de las variables son necesarias para alcanzar la mejor clasificación posible. La pertenencia a las clases, conocida de antemano, se utiliza como variable dependiente. Las variables en las que suponemos que se diferencian las clases se utilizan como variables independientes o variables de clasificación. Se trata de una técnica de análisis multivariante que es capaz de aprovechar las relaciones existentes entre una gran cantidad de variables independientes para maximizar la capacidad de discriminación.

En la estrategia de inclusión por pasos, las variables independientes van siendo incorporadas paso a paso a la función discriminante tras evaluar su grado de contribución individual a la diferenciación entre los grupos.

| Clase | Número de parcelas seleccionadas |
|---------------|----------------------------------|
| Agua | 5 |
| Algarrobos | 44 |
| Cítricos | 80 |
| Edificios | 22 |
| Jardín | 33 |
| Matorral | 13 |
| Olivos | 43 |
| Plantones | 16 |
| Regadío | 24 |
| Suelo desnudo | 125 |

Tabla 6-24. Número de muestras seleccionadas de cada clase

A fin de determinar las variables más significativas, el conjunto de variables descriptoras de las parcelas se dividió en los cuatro subgrupos siguientes:

- Variables espectrales de la parcela
- Variables de textura y variables relativas a los marcos de plantación extraídas mediante la transformada de Hough
- Variables extraídas del semivariograma y de la segmentación de los árboles contenidos en la parcela
- Variables topográficas y variables extraídas de la clasificación por píxel

a) Variables espectrales de la parcela

La utilización de estas variables permite clasificar las muestras de entrenamiento con un grado de acierto del 69.5%. En la figura 6-25, se muestra la variación del valor de la precisión alcanzada en la clasificación conforme se añaden más variables. Así por ejemplo, la precisión alcanzada utilizando únicamente la variable NDVI_STDPAR es del 43%, mientras que la que se obtiene añadiendo a la variable anterior la variable NDVIPAR es del 52.8%. En este caso, la precisión de la clasificación aumenta progresivamente hasta que se incluyen las dos últimas variables correspondientes a la desviación típica de las bandas espectrales roja e infrarroja, cuya influencia en el resultado de la clasificación es muy reducida.




Figura 6-25. Fiabilidad global estimada para las variables espectrales

b) Variables de textura y variables relativas a los marcos de plantación extraídas mediante la transformada de Hough

La fiabilidad global estimada con este grupo de variables alcanza su valor máximo al introducir la variable CONTRASTE, con un valor de 74.34% (figura 6-26). Estabilizándose a partir de este valor.




Figura 6-26. Fiabilidad global estimada para las variables de textura y de la transformada de Hough

Las características que no fueron utilizadas por el análisis discriminante son VARIANZA, RODIR2, RODIR2_STD, RODIR2MEDIAN y RODIR2MODA.

El análisis de los resultados obtenidos permite seleccionar, como más significativas para la clasificación, las doce primeras variables que utiliza el análisis discriminante.

c) Variables extraídas del semivariograma y de la segmentación de los árboles contenidos en la parcela

Con este grupo de variables se obtiene la mayor fiabilidad global, estimada en un 77.85%.

Las variables que no se utilizaron en el análisis discriminante son las siguientes: AREA_STDARB, DIAM_STDARB, LARGOANCHOARB, LARGOANCHO_STDARB, PERIAREAARB, PERIAREA_STDARB, ASIMETRIAARB, ASIMETRIA_STDARB, COMPACIDADARB, COMPACIDAD_STDARB, FRACTALARB, FRACTAL_STDARB.

De este grupo se seleccionaron, para la posterior clasificación, las quince primeras variables empleadas por el análisis discriminante, ya que a partir de la variable IRARB la fiabilidad estimada aumenta moderadamente con la inclusión de nuevas variables.




Figura 6-27. Fiabilidad global estimada para las variables del semivariograma y la segmentación de árboles

d) Variables topográficas y variables extraídas de la clasificación por píxel

Este grupo de variables clasifican las muestras de aprendizaje con una fiabilidad global del 38.79%, siendo el valor más bajo de los cuatro grupos analizados.




Figura 6-28. Fiabilidad global estimada para las variables topográficas y de la clasificación por píxel

Las variables que no se consideraron en el análisis discriminante son: SDCLARO, SDOSCURO, ASFALTO, EDIFAZUL, MATORRAL y SOMBRAS.

En la figura 6-30 se aprecia que la fiabilidad global estimada se mantiene estable con la incorporación de nuevas variables, siendo las variables topográficas las que más información aportan a la clasificación, mientras que las variables correspondientes a la clasificación por píxel son irrelevantes en el resultado final. Por este motivo, se seleccionaron únicamente las variables DIST y PTE.

El análisis discriminante paso a paso permitió reducir el conjunto de variables descriptoras de las 89 iniciales a las 37 que se utilizaron en la clasificación final. Este conjunto de variables quedó compuesto por las ocho características espectrales, doce texturales y extraídas de la transformada de Hough, quince calculadas a partir del semivariograma y de la segmentación de los árboles y dos variables topográficas.

Con las 37 variables se realizó un nuevo análisis discriminante, a fin de comprobar el comportamiento conjunto de las variables de los cuatro grupos. En la figura 6-29 se ve la gran utilidad que tiene la variable PORCPTODIR1NORM ya que sólo con ella se obtiene una fiabilidad del 49.4%. La incorporación de cuatro variables espectrales incrementa rápidamente la fiabilidad hasta un 70.96%. Al añadir dos características de textura (IB_STD y ENTROPIA) y una espectral (GPAR), la fiabilidad aumenta hasta el 80.22%. A partir de este punto, la incorporación de nuevas variables produce ligeros incrementos de la fiabilidad global, alcanzando un valor máximo del 87.48% con el conjunto de las variables seleccionadas.




Figura 6-29. Fiabilidad global estimada con las 37 variables seleccionadas

6.8.4.- Clasificación con 37 variables

Una vez extraídas las vías de comunicación y después de seleccionar el conjunto de variables descriptoras de las parcelas se procedió a la clasificación de las parcelas mediante el algoritmo C5.0. Para crear los árboles de decisión se empleó el mismo conjunto de muestras de entrenamiento utilizado en el análisis discriminante. La selección de muestras de aprendizaje se realizó de forma que el número de muestras de cada una de las clases fuera proporcional al número de parcelas de esa clase en el conjunto de la zona de estudio. Más concretamente, el número de parcelas de muestra de cada clase corresponde con el 10% de la cantidad total de parcelas de esa clase.

Se empleó el método multiplicador *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.

En la figura 6-30 se muestra el primer árbol de decisión creado de forma que todas las muestras de entrenamiento tienen el mismo peso. La primera división que se realiza es según la variable PORCPTODIR1NORM con la cual se separan aquellas parcelas con cultivos arbóreos en marcos de plantación bien definidos, como son los cítricos y los plantones, del resto de parcelas donde no existe marco de plantación, o bien no ha quedado bien detectado en el proceso de extracción de características. El grupo de parcelas con marco de plantación regular se separan posteriormente según las propiedades espectrales de las mismas en las clases *Cítricos* y *Plantones*.

El segundo grupo de parcelas se divide en dos subgrupos según un umbral del índice NDVI. Los objetos con un valor inferior a este umbral corresponden a parcelas donde no predomina la vegetación, como son las correspondientes a las clases *Agua*,

Edificios, Suelo desnudo y Jardín. Las parcelas cuyo valor de NDVIPAR es superior al umbral fijado se asignan a clases con vegetación como *Matorral, Regadío, Algarrobos, Olivos*, etc. El proceso de división continúa utilizando distintas variables hasta conseguir grupos homogéneos de muestras de una misma clase o hasta que no exista ninguna condición que mejore la clasificación.

En la construcción de los árboles de decisión se impuso la condición de que el tamaño mínimo de los grupos de parcelas resultantes de la clasificación fuera de 5 elementos. La inclusión de esta condición de poda del árbol, evita que los árboles se adapten en exceso a las muestras de entrenamiento produciéndose una pérdida de generalidad de las reglas que es especialmente notable en el caso de existir muestras erróneas.

En la tabla 6-25 se muestra el número de errores cometidos por cada uno de los árboles de decisión, así como el error cometido tras la aplicación del multclasificador *boosting*. La evaluación del rendimiento de cada uno de los árboles se ha realizado mediante el conteo de las muestras de entrenamiento que son incorrectamente clasificadas.

El primer árbol es siempre el más preciso con un grado de error del 11% mientras que en el resto de árboles, el porcentaje de las parcelas de muestra erróneamente clasificadas oscila entre el 16 y el 20%. La aplicación conjunta de los 10 árboles reduce el error hasta un 3%.

| Árbol | Errores | Porcentaje de error |
|-----------------|---------|---------------------|
| 1 | 44 | 11.0 |
| 2 | 85 | 21.2 |
| 3 | 66 | 16.4 |
| 4 | 77 | 19.1 |
| 5 | 71 | 17.8 |
| 6 | 66 | 16.4 |
| 7 | 72 | 18.1 |
| 8 | 81 | 20.4 |
| 9 | 66 | 16.5 |
| 10 | 70 | 17.5 |
| <i>Boosting</i> | 12 | 3.0 |

Tabla 6-25. Precisión de los árboles de decisión




Figura 6-30. Árbol de decisión creado con 37 variables

La matriz de confusión correspondiente a la clasificación de las parcelas utilizadas en la construcción de los árboles de decisión (tabla 6-26) muestra el alto grado de ajuste que se consigue con la aplicación de este método a las parcelas de entrenamiento.

| CLASIF. | VERDAD TERRENO | | | | | | | | | |
|---------------|----------------|------------|----------|-----------|--------|----------|--------|-----------|---------|---------------|
| | Agua | Algarrobos | Cítricos | Edificios | Jardín | Matorral | Olivos | Plantones | Regadío | Suelo desnudo |
| Agua | 5 | | | | | | | | | |
| Algarrobos | | 42 | | | | | | | | |
| Cítricos. | | | 79 | | | | 1 | | | |
| Edificios | | | | 20 | | | | | | |
| Jardín | | 2 | 1 | | 26 | | | | | |
| Matorral | | | | | | 15 | | | | |
| Olivos | | | | | | | 41 | | | |
| Plantones | | | | | | | | 12 | | |
| Regadío | | | | | | | | | 23 | |
| Suelo desnudo | | | | 2 | 2 | | 1 | 3 | | 125 |

Tabla 6-26. Matriz de confusión correspondiente a las muestras de entrenamiento

La evaluación del resultado de la clasificación por medio de las parcelas utilizadas para la construcción de los árboles de decisión no es adecuada ya que resulta excesivamente favorable al coincidir el conjunto de muestras de evaluación con las que se han utilizado en el entrenamiento del clasificador. En cambio, es necesario disponer de un conjunto de muestras de evaluación diferente al de entrenamiento. En este caso, la evaluación de la clasificación se ha realizado con todas las parcelas presentes en la zona de estudio a excepción de las utilizadas para la creación de los árboles de decisión. En la tabla 6-27 se recoge la matriz de confusión obtenida. La fiabilidad global obtenida es del 73% y el índice kappa es 0.67 que, según la escala propuesta por Landis y Koch (1977), corresponde a un grado de concordancia bueno entre los resultados de la clasificación y la asignación de clases de referencia.

| CLASIF. | VERDAD TERRENO | | | | | | | | | | |
|---------------|----------------|------------|----------|-----------|--------|----------|--------|-----------|---------|---------------|-------|
| | Agua | Algarrobos | Cítricos | Edificios | Jardín | Matorral | Olivos | Plantones | Regadío | Suelo desnudo | Total |
| Agua | 6 | | | | | | | | | | 6 |
| Algarrobos | | 246 | 7 | | 37 | 20 | 45 | 2 | 7 | 31 | 395 |
| Cítricos | | 2 | 631 | 3 | 22 | 6 | 20 | 24 | 18 | 8 | 734 |
| Edificios | 3 | | | 94 | | | | | | 15 | 112 |
| Jardín | | 12 | 28 | 15 | 195 | 6 | 17 | 1 | 10 | 33 | 317 |
| Matorral | | 36 | 5 | | 8 | 60 | 7 | | 1 | 10 | 127 |
| Olivos | | 72 | 14 | | 12 | 5 | 265 | | 1 | 12 | 381 |
| Plantones | | | 30 | 3 | | | 2 | 58 | | 19 | 112 |
| Regadío | | 11 | 1 | 1 | 4 | 2 | 3 | 7 | 138 | 54 | 221 |
| Suelo desnudo | 1 | 15 | 3 | 85 | 26 | 12 | 26 | 47 | 35 | 940 | 1190 |
| Total | 10 | 394 | 719 | 201 | 304 | 111 | 385 | 139 | 210 | 1122 | 3595 |

Tabla 6-27. Matriz de confusión de la clasificación con 37 variables

En la tabla 6-28 se muestran las fiabilidades de usuario y productor para cada una de las clases del estudio.

| | Fiab. Usuario | Fiab. Productor |
|---------------|---------------|-----------------|
| Agua | 1 | 0.6 |
| Algarrobos | 0.62 | 0.62 |
| Cítricos | 0.86 | 0.88 |
| Edificios | 0.84 | 0.47 |
| Jardín | 0.61 | 0.64 |
| Matorral | 0.47 | 0.54 |
| Olivos | 0.70 | 0.69 |
| Plantones | 0.52 | 0.42 |
| Regadío | 0.62 | 0.66 |
| Suelo desnudo | 0.79 | 0.84 |

Tabla 6-28. Fiabilidades de usuario y de productor de la clasificación con 37 variables

Las clases *cítricos* y *plantones* corresponden al mismo tipo de cultivo por lo que tras la clasificación deben fusionarse en una misma clase. La fiabilidad global de la clasificación tras la fusión de ambas clases se eleva al 74.7%, mientras que las fiabilidades de usuario y productor de la clase conjunta son respectivamente de 87.8% y 86.6%.

En el apartado 6.8.7 se analizan detalladamente la confusión existente entre algunas clases y los motivos de los errores de la clasificación.

6.8.5.- Incorporación de la clase contenida en la base de datos

Como se ha visto en el apartado 6.7, una de las ventajas principales del algoritmo C5.0, frente a otros tipos de clasificadores, es la posibilidad de incluir como variables descriptoras de los objetos variables de tipo discreto.

La información contenida en una base de datos sobre el uso de una parcela en un momento previo puede resultar útil en el proceso de asignar una clase a esa parcela. En un paisaje estable, la clase más probable para una parcela sería la que tenía en un momento anterior. Por otro lado, en un ámbito dinámico, los usos del suelo varían siguiendo unas tendencias cuyo conocimiento combinado con el de la clase previa del objeto puede facilitar la determinación del nuevo uso.

Partiendo del mismo conjunto de muestras de entrenamiento que en el ensayo anterior, se aplicó de nuevo el algoritmo C5.0 con el multclasificador *boosting*, con las mismas variables seleccionadas en el análisis discriminante a las que se añadió el uso contenido en la base de datos catastral. Este uso se almacenó en la variable CLASECAT.

En la figura 6-31 se muestra el primero de los 10 árboles de decisión creados. Comparando este árbol con el de la figura 6-30 se aprecia que la mayor parte de las condiciones de ambos árboles son las mismas, excepto en el caso de las parcelas sin un marco de plantación bien definido y con un valor bajo del índice NDVI que en este caso se clasifican considerando su uso catastral. Es remarcable el hecho de que el uso catastral no determina directamente la clase a la que se asignan las parcelas, ya que, por ejemplo, parcelas con distintos usos catastrales se clasifican en la clase *Suelo desnudo* y parcelas con el uso catastral *Algarrobos* son asignados en la clase *Plantones*. Resulta especialmente interesante cómo parcelas con el uso catastral *Improductivo* son clasificadas según otras características entre las clases *Agua*, *Edificios* y *Suelo desnudo*, poniendo de manifiesto que el uso catastral *Improductivo* es una clase heterogénea que engloba parcelas correspondientes a estas tres clases de la leyenda utilizada en este trabajo.

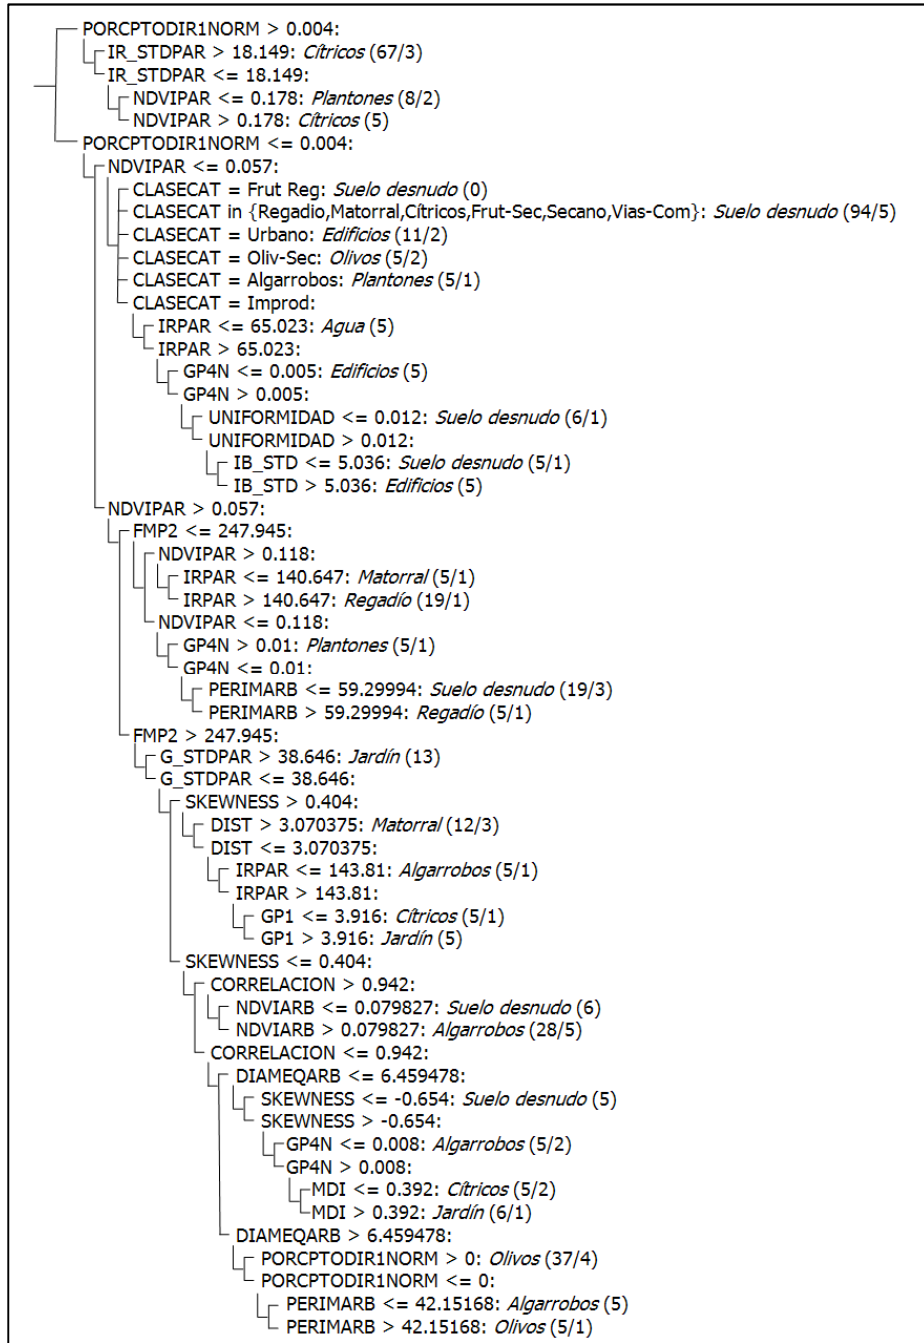


Figura 6-31 Árbol de decisión creado con 37 variables más el uso catastral

La fiabilidad global de esta clasificación es del 77%; superior en cuatro puntos a la obtenida en la clasificación anterior donde no se considera el uso catastral. El índice kappa también se ha incrementado hasta 0.72. En las tablas 6-29 y 6-30 se muestra la matriz de confusión obtenida y las fiabilidades de usuario y de productor para cada una de las clases.

| CLASIF. | VERDAD TERRENO | | | | | | | | | | |
|---------------|----------------|------------|----------|-----------|--------|----------|--------|-----------|---------|---------------|-------|
| | Agua | Algarrobos | Cítricos | Edificios | Jardín | Matorral | Olivos | Plantones | Regadío | Suelo desnudo | Total |
| Agua | 6 | | | | | | | | | | 6 |
| Algarrobos | | 301 | 7 | 3 | 39 | 17 | 35 | 3 | 6 | 31 | 442 |
| Cítricos | | | 635 | 4 | 24 | 2 | 19 | 21 | 12 | 6 | 723 |
| Edificios | 4 | | | 118 | 1 | | | 2 | | 5 | 130 |
| Jardín | | 16 | 33 | 19 | 203 | 13 | 17 | 1 | 13 | 41 | 356 |
| Matorral | | 27 | 2 | | 7 | 59 | 2 | | 1 | 10 | 108 |
| Olivos | | 35 | 13 | 2 | 6 | 9 | 290 | 2 | | 10 | 367 |
| Plantones | | | 19 | 2 | | | 1 | 67 | | 9 | 98 |
| Regadío | | 2 | 2 | 1 | 4 | 1 | | 9 | 136 | 46 | 201 |
| Suelo desnudo | | 13 | 8 | 52 | 20 | 10 | 21 | 34 | 42 | 964 | 1164 |
| Total | 10 | 394 | 719 | 201 | 304 | 111 | 385 | 139 | 210 | 1122 | 3595 |

Tabla 6-29. Matriz de confusión de la clasificación considerando el uso catastral

| | Fiab. Usuario | Fiab. Productor |
|---------------|---------------|-----------------|
| Agua | 1 | 0.6 |
| Algarrobos | 0.68 | 0.76 |
| Cítricos | 0.88 | 0.88 |
| Edificios | 0.91 | 0.59 |
| Jardín | 0.57 | 0.67 |
| Matorral | 0.55 | 0.53 |
| Olivos | 0.79 | 0.75 |
| Plantones | 0.68 | 0.48 |
| Regadío | 0.68 | 0.65 |
| Suelo desnudo | 0.83 | 0.86 |

Tabla 6-30. Fiabilidades de usuario y de productor de la clasificación considerando el uso catastral

La consideración del uso catastral ha resultado especialmente indicada para la mejora de la clasificación de determinadas clases. La fiabilidad de usuario ha aumentado un 6% para la clase *Algarrobos*, un 7% para la clase *Edificios*, un 9% para la clase *Olivos* y un 17% para los *Plantones*. La fiabilidad de productor ha aumentado un 6% para las clases *Plantones* y *Olivos*, un 12% para los *Edificios* y un 14% para los *Algarrobos*. El resto de clases han mantenido valores muy similares en las fiabilidades alcanzadas en ambas clasificaciones, como se muestra en la figura 6-32.

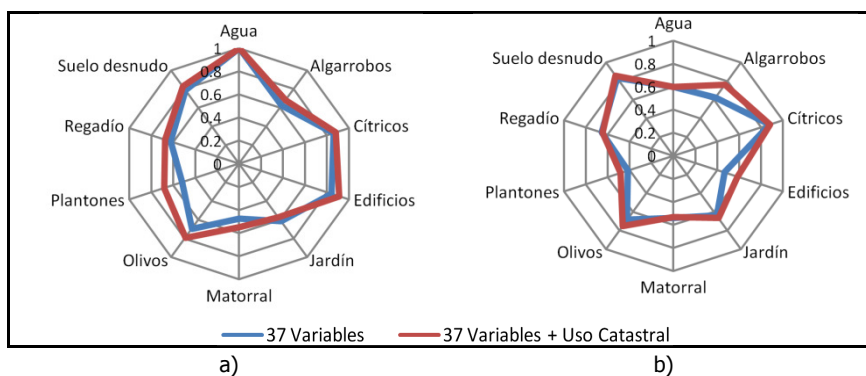


Figura 6-32. Comparación de las fiabilidades de usuario (a) y de productor (b)

Al igual que en el apartado anterior, la fiabilidad global aumenta tras la fusión de las clases *cítricos* y *plantones* en una misma clase, alcanzando un valor del 78.4%, mientras que las fiabilidades de usuario y productor de la clase conjunta son 90.3% y 86.5%.

En la tabla 6-31 se recoge la contribución del uso catastral en la clasificación. En los árboles de clasificación que emplean esta variable su utilización varía desde la tercera condición hasta la sexta. Además, el porcentaje medio de parcelas clasificadas según esta característica en los diez árboles es del 27.3%, valor que indica que la variable es relevante para la clasificación pero que no es determinante, ya que no se produce una asignación directa de la clase actual a partir de la información catastral por la desactualización de la base de datos y la falta de coincidencia entre ambas leyendas.

| Árbol | Posición de la condición que evalúa el uso catastral | Porcentaje de parcelas clasificadas considerando el uso catastral |
|-------|--|---|
| 1 | 3 | 35.2 |
| 2 | 5 | 31.5 |
| 3 | 4 | 28.5 |
| 4 | 0 | 0.0 |
| 5 | 0 | 0.0 |
| 6 | 3 y 5 | 54.7 |
| 7 | 6 | 23.5 |
| 8 | 4 | 16.7 |
| 9 | 3 | 29.7 |
| 10 | 4 y 4 | 53.2 |
| Media | | 27.3% |

Tabla 6-31. Intervención del uso catastral en la clasificación

El análisis de los resultados confirma que la inclusión del uso catastral como variable descriptora de las parcelas mejora sustancialmente la precisión de la clasificación sin condicionar en exceso la clase a la que se asigna cada parcela según su uso anterior.

6.8.6.- Contribución de las características en la clasificación

El análisis de los diez árboles empleados en la clasificación con 37 características permite conocer la contribución, entendida como su poder de discriminación entre las distintas clases de la leyenda, de cada característica en el proceso de clasificación. En la tabla 6-32 se muestra, para cada árbol de decisión, el porcentaje de parcelas en cuya clasificación se ha considerado el valor de cada característica. Así por ejemplo, en el primer árbol el valor de la variable NDVIPAR se ha utilizado en la clasificación del 48% de las parcelas, mientras que la variable PORCPTODIR1NORM se ha utilizado para la clasificación del 100% de las parcelas. Las características están ordenadas de mayor a menor contribución media en los diez árboles de clasificación.

Es destacable la alternancia de las características descriptoras de distintas tipologías de propiedades en la clasificación. La variable que más contribuye es una variable espectral de la parcela: NDVIPAR. Esta variable se ha evaluado en la clasificación del 91.1%; siendo la primera variable empleada en 8 de los 10 árboles. En segundo lugar se emplea un descriptor de los marcos de plantación extraído de la transformada de Hough: PORCPTODIR1NORM. La cual es la primera variable empleada en dos de los diez árboles. A continuación, dos variables extraídas del semivariograma, GP4N y GP4. En quinto y sexto lugar se encuentran SKEWNESS e IB_STD que describen la textura de la parcela.

Según estos resultados, se comprueba que las variables espectrales y relativas a la regularidad espacial de las parcelas, extraídas tanto con el semivariograma como con la transformada de Hough, son las que mejor describen las parcelas y permiten, en mayor medida, la discriminación entre clases. No obstante, estas variables están complementadas con variables de otros tipos, como son las texturales, las derivadas de la segmentación de árboles, o las variables topográficas.

Las variables COVARIANZA, FMP4 y PORCDIR1 no han sido empleadas en ninguno de los 10 árboles de clasificación.

| CARACTERÍSTICAS | Árbol 1 | Árbol 2 | Árbol 3 | Árbol 4 | Árbol 5 | Árbol 6 | Árbol 7 | Árbol 8 | Árbol 9 | Árbol 10 | Media |
|-----------------|---------|---------|---------|---------|---------|---------|---------|---------|---------|----------|-------|
| NDVIPAR | 48 | 100 | 63 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 91.1 |
| PORCPTODIR1NORM | 100 | 66 | 100 | 65 | | 4 | 67 | 23 | | 85 | 51.0 |
| GP4N | 13 | 33 | | 35 | 100 | 33 | 52 | 33 | 77 | 33 | 41.1 |
| GP4 | 2 | 45 | 54 | 19 | 27 | 71 | 67 | | 14 | 50 | 34.8 |
| SKEWNESS | 33 | 28 | | 21 | 29 | 32 | 41 | 39 | 49 | 35 | 30.7 |
| IB_STD | 30 | 21 | 23 | 39 | 10 | 9 | 12 | 53 | 46 | | 24.2 |
| GP5 | | | 49 | 45 | 71 | | 43 | 12 | 21 | | 24.0 |
| NDVI_STDPAR | | 26 | 27 | | | 36 | 28 | 30 | 51 | 28 | 22.5 |
| IRPAR | 8 | 11 | 15 | 14 | 36 | 33 | | 18 | 29 | 42 | 20.6 |
| NDVIARB | 19 | 7 | 12 | 54 | 18 | 20 | | 50 | | 25 | 20.5 |
| GP1 | 1 | 21 | | | | 67 | 8 | 67 | | 28 | 19.2 |
| G_STDPAR | 34 | 5 | | 40 | | 37 | | | 32 | 30 | 17.8 |
| DIST | 5 | | 11 | 7 | 17 | 34 | 17 | 8 | 23 | 47 | 17.0 |
| PORCPTODIR1 | | | | | 21 | 43 | 28 | | 33 | 22 | 14.7 |
| ENTROPIA | 10 | 33 | 4 | | 28 | | 38 | | 10 | | 12.2 |
| CORRELACION | 24 | | | 17 | 18 | 10 | | 15 | 14 | 8 | 10.6 |
| FMP2 | 45 | 30 | 8 | | | 20 | | | | | 10.4 |
| AREAARB | | 17 | 24 | 18 | 30 | | | 12 | | | 10.1 |
| DIAMEQARB | 14 | | | | | 17 | | 29 | 28 | | 8.7 |
| IRARB | | | | | | 29 | | 44 | 7 | | 8.1 |
| RPAR | 2 | 13 | 15 | | | | 37 | | | 10 | 7.7 |
| IR_STDPAR | 18 | | | | | | | | 8 | 49 | 7.4 |
| GARB | | 18 | | | 4 | | 21 | | 15 | | 5.8 |
| MDI | 2 | | 6 | | 4 | | | 19 | 7 | 15 | 5.4 |
| FMP7 | | | | | 10 | | 13 | | | 19 | 4.0 |
| UNIFORMIDAD | 5 | | 13 | 7 | 4 | 9 | | | | | 3.7 |
| PERIMARB | 5 | | | 5 | | | 19 | | | 4 | 3.3 |
| RARB | | 10 | | | | 10 | 13 | | | | 3.2 |
| CONTRASTE | | | 6 | | | | 19 | | | | 2.5 |
| GPAR | | | 5 | 4 | | | | 13 | | | 2.2 |
| IB | | | | | 7 | | | 14 | | | 2.1 |
| VPTE1 | | | | | | | 7 | 14 | | | 2.1 |
| R_STDPAR | | | | 19 | | | | | | | 1.9 |
| PTE | | | | | | 5 | | | | 8 | 1.4 |
| COVARIANZA | | | | | | | | | | | 0 |
| FMP4 | | | | | | | | | | | 0 |
| PORCDIR1 | | | | | | | | | | | 0 |

Tabla 6-32. Porcentajes de parcelas clasificadas empleando cada variable en los 10 árboles de decisión

6.8.7.- Análisis detallado de los errores cometidos en la clasificación con 37 variables

A continuación se analizan, para las clases temáticas presentes en la zona de estudio, las principales causas de error en su clasificación:

Agua

Los límites de las piscinas o balsas de riego no están bien delineados en la cartografía. Debido al reducido tamaño de estos objetos, la influencia de las áreas externas a los mismos es mayor que en el caso de polígonos con superficies mayores.




Figura 6-33. Parcelas de la clase *Agua* clasificadas como *Suelo desnudo* (a) y *Edificios* (b)

Esta clase es la menos frecuente en la zona de estudio. Por tanto, también es de la que menos muestras de entrenamiento se disponen quedando infrarrepresentada en el conjunto de muestras de entrenamiento. Por ello, se crean menos reglas para la clasificación de los objetos de esta clase.

La confusión de las parcelas de esta clase se produce con los objetos de la clase *Edificios* y de *Suelo desnudo*.

Algarrobos

De las 148 parcelas de algarrobos clasificadas erróneamente, el 48.6% (72) han sido asignadas a la clase *Olivos*. Esta confusión se debe a la alta similitud existente entre ambos tipos de cultivos, ya que ambos casos son cultivos arbóreos de secano con tamaños y marcos de plantación similares.

Por otra parte, el cultivo del algarrobo está en recesión en la zona de estudio y son numerosas las parcelas de este cultivo que se encuentran en estado de abandono; con

lo que en una misma parcela es común que coexistan algarrobos y matorral. Por este motivo, existe una confusión importante entre las parcelas ocupadas por algarrobos abandonados y las parcelas ocupadas por matorral (figura 6-34).



Figura 6-34. Parcelas de la clase *Algarrobos* clasificadas como *Matorral*

Los errores de clasificación más llamativos dentro de este grupo de parcelas corresponden a la confusión con las clases *Regadío* y *Suelo desnudo*, ya que en ninguna de estas dos clases existe vegetación arbórea ni marcos de plantación que puedan dar lugar a confusión, como ocurre en el resto de clases agrícolas. Estos errores se deben a que los algarrobos existentes en estas parcelas ocupan una proporción reducida de la superficie de la parcela y, por tanto, las características de las áreas sin árboles enmascaran a las de las zonas ocupadas por árboles (figura 6-35).

Es necesaria, la definición exacta de los criterios para asignar las parcelas entre cada una de las clases, de forma que se eviten las ambigüedades entre clases en la selección de muestras tanto de entrenamiento, como de evaluación.




Figura 6-35. Parcelas de la clase *Algarrobos* clasificadas como *Suelo desnudo*

Cítricos

Esta es la clase en la que mejores resultados se obtienen en la clasificación, con una fiabilidad de usuario de 0.86 y de productor de 0.88. El mayor número de errores en la asignación de parcelas de cítricos adultos se produce por su asignación a la clase *Plantones*. No se considera un error grave, ya que se identifica correctamente el cultivo. Este error se produce en ambos sentidos, es decir, parcelas que el intérprete asigna a la clase *Cítricos* son clasificadas por el sistema en la clase *Plantones* y a la inversa. El hecho de que no se haya fijado un umbral exacto que defina el límite entre la clase *Cítricos* y *Plantones* supone que aquellas parcelas cítrícolas cuyos árboles tienen tamaños intermedios entre los que el intérprete considera plantones o cítricos adultos, pueden ser clasificadas en cualquiera de las dos clases (figura 6-36).




Figura 6-36. Parcelas de la clase *Cítricos* clasificadas como *Plantones*

El segundo grupo de errores más numeroso corresponde a parcelas cítrícolas asignadas a la clase *Jardín*. Estos errores se deben en su mayoría a la coexistencia de varios usos en las parcelas.

La clase *Jardín* es heterogénea por definición, y puede incluir distintos tipos de cultivos, edificios, balsas de agua, etc. Por tanto, es normal que el sistema asigne a esta clase parcelas con distintos usos mientras que el intérprete las asignó a la clase *Cítricos* por ser la que tiene una mayor superficie en la parcela (figura 6-37).




Figura 6-37. Parcelas de la clase *Cítricos* clasificadas como *Jardín*

La confusión entre *Cítricos* y *Algarrobos* se debe principalmente al estado de abandono de algunas parcelas de cítricos cuya respuesta espectral es similar a la de los algarrobos de secano (figura 6-38a) y, por otro lado, a la existencia de parcelas donde coexisten ambos cultivos (figura 6-38b).



Figura 6-38. Parcelas de la clase *Cítricos* clasificadas como *Algarrobos*

El análisis de los errores cometidos en la asignación de parcelas cítricas a la clase *Olivos*, revela que las parcelas erróneamente clasificadas corresponden a plantaciones irregulares de cítricos (figura 6-39a), o bien, a parcelas mixtas donde existen varios usos (figura 6-39b).




Figura 6-39. Parcelas de la clase *Cítricos* clasificadas como *Olivos*

Edificios

Mientras la mayoría de las clases tienen valores de fiabilidad de productor y de usuario similares, esta clase presenta valores muy distintos en ambos índices. La fiabilidad de productor obtenida es del 47% y la fiabilidad de usuario es del 84%.

Aproximadamente, el 80% de los errores cometidos en la clasificación de edificios corresponden a su asignación a la clase *Suelo desnudo*. La mayor parte de los edificios existentes son viviendas o edificios industriales. Las viviendas se caracterizan por mostrarse en la composición falso color infrarrojo en tonos amarillos (figura 6-40a) y tienen cubiertas inclinadas de teja o cubiertas planas con baldosa. Por otro lado, los edificios industriales se caracterizan por tonos azules – grisáceos y corresponden a cubiertas metálicas (figura 6-40b).

La confusión que se produce entre la clase *Edificios* y la de *Suelo desnudo* está motivada porque las dos tipologías de tejados descritas presentan tonos similares al suelo sin vegetación en el caso de las viviendas y a las superficies asfaltadas en el caso de las construcciones industriales. Tanto el suelo sin vegetación como las superficies asfaltadas están incluidas en la clase *Suelo desnudo*.

Por otro lado, esta confusión entre clases no se da de igual forma en ambos sentidos. El número de edificios clasificados como suelo desnudo (85) es mucho mayor que el número de parcelas de suelo desnudo clasificadas como edificios (15). Este comportamiento del clasificador se debe fundamentalmente al hecho de que el número de parcelas de la clase *Suelo desnudo* es aproximadamente seis veces mayor que el número

de edificios por lo que, siendo dos clases con características similares, la mayor representación de una de las clases condiciona el rendimiento del clasificador.




Figura 6-40. Tipologías de edificios en la zona de estudio

La identificación de edificios en imágenes aéreas es un problema que está siendo ampliamente estudiado por su importancia para la actualización de bases de datos cartográficas. La complejidad y particularidad de este problema se aleja del carácter general que tiene la metodología propuesta centrada más en la interpretación de los usos del suelo especialmente agrícolas que en la identificación y localización de un determinado tipo de elementos.

El segundo grupo de errores más abundante en esta clase corresponde a la asignación de parcelas de edificios a la clase *Jardín*. Estos errores están motivados por la incorrecta delineación de los edificios que, en algunos casos, introduce parte de la vegetación adyacente en el perímetro de los edificios (figura 6-41).



Figura 6-41 Parcelas de la clase *Edificios* clasificadas como *Jardín*

Jardín

La clase *Jardín* es la más heterogénea de las presentes en el estudio. Se asignó esta clase a aquellas parcelas donde se combinan varios usos sin que exista un uso predominante sobre los demás. El ejemplo más claro de esta tipología son aquellas parcelas donde existe alguna edificación rodeada por jardines, pequeños huertos familiares, balsas de riego o piscinas, etc. Debido a la alta variabilidad interna de la clase su caracterización resulta más compleja que en el resto de clases.

La mayor parte de los errores cometidos en la clasificación de las parcelas de esta clase corresponden a parcelas que se han clasificado en las clases *Algarrobos* (figura 6-42), *Cítricos* (figura 6-43) y *Suelo desnudo* (figura 6-44).




Figura 6-42. Parcelas de la clase *Jardín* clasificadas como *Algarrobos*




Figura 6-43. Parcelas de la clase *Jardín* clasificadas como *Cítricos*



Figura 6-44. Parcelas de la clase *Jardín* clasificadas como *Suelo desnudo*

Matorral

En la tabla 6-27 se aprecia que la mayor parte de los errores en la clasificación de parcelas con matorral se producen al ser clasificadas en la clase *Algarrobos* o *Suelo desnudo*.

Como se comentó al hablar de la confusión entre los algarrobos y el matorral, el abandono de los campos de algarrobos por su escaso rendimiento económico, permite la aparición de vegetación espontánea, creándose una tipología mixta de uso del suelo donde se combinan algarrobos con matorral (figura 6-45). La asignación de estas parcelas a cualquiera de las dos clases consideradas se puede considerar como correcta al no existir en la leyenda una clase donde se combinen las clases *Algarrobo* y *Matorral*.



Figura 6-45. Parcelas de la clase *Matorral* clasificadas como *Algarrobos*

La confusión entre parcelas de matorral y suelo desnudo se da en aquellas parcelas donde se combinan ambos tipos de coberturas (figura 6-46).





Figura 6-46. Parcelas de la clase *Matorral* clasificadas como *Suelo desnudo*

Olivos

Las parcelas de olivos se han clasificado con una fiabilidad del 69%. El mayor número de errores se da en parcelas de olivos clasificadas como algarrobos. Esta confusión se debe a varios motivos como son la semejanza existente entre ambos cultivos, la mezcla de árboles de ambas especies en la misma parcela (figura 6-47a), etc.



a)

b)

Figura 6-47. Parcelas de la clase *Olivos* clasificadas como *Algarrobos*

Una de las diferencias más importantes entre ambos cultivos es el hecho de que los olivos normalmente están plantados en marcos de plantación rectangulares mientras que en los algarrobos su disposición espacial es menos regular. La inclusión de las

características descriptivas de los marcos de plantación conlleva la inclusión de parcelas de olivos con una distribución no regular en la clase *Algarrobos* (figura 6-47b).

El segundo grupo más numeroso de errores engloba a aquellas parcelas de olivos clasificadas en la clase *Suelo desnudo*. En la mayoría de los casos, estos errores se deben a que en la parcela coexisten ambos tipos de coberturas.




Figura 6-48. Parcelas de la clase *Olivos* clasificadas como *Suelo desnudo*

Plantones

Esta clase es la que presenta las fiabilidades más bajas en el estudio. La fiabilidad de productor es de 42% y la de usuario es de 52%.

En la clasificación de estas parcelas, los errores están agrupados en dos categorías: plantones clasificados como cítricos y plantones clasificados como suelo desnudo (figura 6-49). En el primer caso los errores son poco relevantes ya que, como se comentó anteriormente, la diferencia entre ambas clases está en los umbrales que han establecido el intérprete y el clasificador para separar los plantones del resto de cítricos.

El segundo grupo de errores relativos a la clasificación de parcelas en la clase *Suelo desnudo*, se debe al hecho de que la superficie ocupada por los árboles recién plantados en las parcelas es una proporción reducida del total de la parcela, quedando las características correspondientes a los árboles enmascaradas por las características de las áreas sin vegetación. En algunas de estas parcelas, los árboles tienen dimensiones tan pequeñas que su existencia se intuye con dificultad.

Las características que mejor describen los cultivos arbóreos en marcos de plantación regulares y que, por este motivo, son las más empleadas en los árboles de decisión, son las extraídas del análisis del semivariograma. En el caso de las parcelas de

plantones, estas características tienen una eficacia inferior que en el resto de clases ya que, por el reducido tamaño de los árboles, el semivariograma no presenta el comportamiento cíclico típico de una parcela con un cultivo en un marco regular. En la figura 6-50 se muestra una parcela con plantones con su semivariograma correspondiente el cual no refleja el comportamiento regular de la distribución espacial de los plantones.




Figura 6-49. Parcelas de la clase *Plantones* clasificadas como *Suelo desnudo*




Figura 6-50. Parcela de la clase *Plantones* (a) con su semivariograma correspondiente (b)

Regadío

El análisis de las parcelas de regadío erróneamente clasificadas muestra que las principales categorías de error que existen en esta clase tienen lugar por confusión con la clase *Suelo desnudo* o con la clase *Cítricos*.

En el caso de la confusión entre la clase *Regadío* y la clase *Suelo desnudo* el motivo principal es la existencia de parcelas con cultivos hortícolas recién plantados en el

momento de la toma de la imagen (figura 6-51a), por lo que el comportamiento de estas parcelas en las características analizadas son valores intermedios entre el de un cultivo hortícola y un suelo desnudo. Al igual que en otros casos analizados, como la confusión entre plantones y cítricos, se remarca la necesidad de fijar un umbral determinante que permita diferenciar sin ambigüedad el límite entre dos clases.

Por otra parte, la combinación de estos dos usos en el mismo polígono también puede inducir a su incorrecta clasificación (figura 6-51b).




Figura 6-51. Parcelas de la clase *Regadío* clasificadas como *Suelo desnudo*

La confusión entre las parcelas de regadío y las de cítricos se da en el caso de que las parcelas hortícolas no sean espacialmente homogéneas, sino que tengan una periodicidad espacial similar a la que puede existir en las parcelas cítricas. Este tipo de parcelas tienen un alto valor en la banda del infrarrojo y valores de regularidad espacial parecidos a los que pueden tener las parcelas cítricas.



Figura 6-52. Parcelas de la clase *Regadío* clasificadas como *Cítricos*

Suelo desnudo

Esta clase es la más abundante en la zona de estudio y la que ha obtenido unos valores de fiabilidad mayores tras los *Cítricos*. Su fiabilidad de productor es del 84% y su fiabilidad de usuario es del 79%.

La mayoría de los errores en esta categoría son debidos, al igual que ocurría en la clase anteriormente analizada, a la confusión entre el suelo desnudo y las parcelas de regadío por la existencia de parcelas con una ligera cobertura vegetal que podrían estar clasificadas en cualquiera de estas dos clases.

6.8.8.- Comparación de la clase asignada con la contenida en la base de datos catastral

Para poder actualizar la base de datos catastral empleada en este trabajo, se comparó con la base de datos creada mediante fotointerpretación combinada con trabajo de campo. En ella, se asignó el uso a todas las parcelas del estudio; habiendo sido utilizadas como verdad terreno para la evaluación de las distintas clasificaciones y ensayos realizados. La principal diferencia entre ambas bases de datos radica en la leyenda utilizada en cada una de ellas. El número de clases en la base de datos catastral es de 12, mientras que en la de verdad terreno es de 11 clases. En la tabla 6-33 se muestran las leyendas utilizadas en ambas bases de datos con las equivalencias entre ellas.

| B.D. Catastral | B.D. Verdad Terreno |
|-----------------------|----------------------------|
| | Agua |
| Algarrobos | Algarrobos |
| Cítricos | Cítricos y Plantones |
| Frutales de regadío | |
| Frutales de secano | |
| Hidrografía | |
| Improductivo | Suelo desnudo |
| | Jardín |
| Matorral | Matorral |
| Olivos de secano | Olivos |
| Regadío | Regadío |
| Secano | |
| Urbano | Edificios |
| Vías de comunicación | Vías de comunicación |

Tabla 6-33. Comparación de leyendas

La leyenda utilizada en la base catastral no es disjunta, ya que se solapan algunas de las categorías de usos del suelo. Por otra parte, no es coherente en cuanto a que las clases no tienen significados comparables semánticamente. Hay clases que corresponden a cultivos como algarrobos o cítricos, mientras que otras son más generales y hacen referencia a grupos de cultivos, como frutales de secano o de regadío. Por estos motivos, existen parcelas cuya asignación a una clase es ambigua ya que estarían correctamente asignadas en dos clases distintas. Por ejemplo, en las clases *Frutales de secano* y *Secano* aparecen parcelas que contienen algarrobos y/u olivos cuando estas parcelas deberían estar incluidas en las clases *Algarrobos* u *Olivos*. La clase *Frutales de regadío* contiene parcelas que corresponden a cítricos. La clase *Regadío* engloba tanto a parcelas de cultivos hortícolas como a parcelas con cultivos arbóreos de regadío que deberían estar incluidos en las clases *Cítricos* o *Frutales de regadío*. Esta diversidad de criterios en la definición de las clases que forman la leyenda catastral dificulta en gran medida la comparación directa con las clases definidas en la base de verdad terreno.

Por otra parte, las clases *Hidrografía* e *Improductivo* no están definidas según un criterio visual, sino según un criterio semántico. En ambas clases, hay parcelas que corresponden a distintas coberturas del suelo pero están englobadas en un uso común. Así por ejemplo, la clase *Improductivo* engloba edificios, masas de agua, superficies yermas, etc. Dentro de *Hidrografía* aparecen tanto superficies ocupadas por matorral como superficies sin vegetación.

Por lo que respecta a la definición de clases hecha en la base de datos de verdad terreno, se ha basado en criterios visuales considerando la metodología de clasificación semiautomática que se pretende utilizar. Se ha pretendido que la leyenda cumpla con las condiciones establecidas en el apartado 2.2.2. Es decir, que sea completa, de forma que todas las parcelas en el área de estudio se puedan asignar a una clase. Que sea disjunta, con el fin de que no haya solapes entre clases. Que sea reconocible, ya que está basada en propiedades visuales cuantificadas numéricamente. Y por último, que sea coherente, ya que todas las clases son comparables semánticamente en el mismo nivel de abstracción.

En esta leyenda se han incorporado clases no existentes en la leyenda catastral como son la clase *Agua*, por tener unas características espectrales distintas al resto de elementos; la clase *Jardín*, que corresponde a polígonos caracterizados por su heterogeneidad y donde no existe un uso predominante; la clase *Suelo desnudo*, en la que se asignan las parcelas sin vegetación de ningún tipo, por lo que en esta clase se combinan parcelas yermas sin uso definido, con parcelas agrícolas sin cultivo en el momento de la toma y, por último, la clase *Plantones de cítricos*, que se crea por la necesidad de establecer una tipología de cítricos distinta de los cítricos adultos ya que sus características son notablemente diferentes. La clase *Plantones de cítricos*, tras la clasificación, se combina con la clase *Cítricos* por corresponder a un mismo uso.

La clase *Regadío* se asigna a parcelas dedicadas a cultivos hortícolas en el momento de la toma de la imagen. Las parcelas dedicadas a cultivos hortícolas de temporada, que en la fecha de adquisición de la imagen no presentan ningún tipo de cultivo, son clasificadas por medio de sus características visuales en la clase *Suelo desnudo*, que correspondería a parcelas sin aprovechamiento económico. Debido a la reducida duración en el tiempo de los cultivos hortícolas, la apariencia de estas parcelas varía rápidamente en el tiempo, produciéndose la asignación de parcelas de regadío que en la fecha de la imagen no tienen cultivo a la clase *Suelo desnudo*. Para evitar este tipo de errores, pueden utilizarse dos imágenes de la misma zona en estaciones distintas del año, pudiendo establecerse una condición según la cual, aquellas parcelas clasificadas como *Regadío* en una de las dos fechas del mismo año y clasificadas como *Suelo desnudo* en la otra fecha, podrían seguir considerándose como *Regadío*. En caso de que las dos clasificaciones asignasen la clase *Suelo desnudo*, es de suponer que la parcela ha dejado de cultivarse de forma permanente y, por lo tanto, su uso deberá actualizarse.

La comparación de los usos asignados en la base catastral con los empleados como verdad terreno refleja que un 10% de las parcelas tiene asignado un uso catastral que no tiene equivalencia en la leyenda de la base de verdad terreno. Es decir, tienen asignadas clases como *Frutales de regadío*, *Hidrografía*, *Secano*, etc. que no son directamente comparables con las categorías de verdad terreno. El 90% restante se divide entre aquellas parcelas cuya clase coincide en ambas bases de datos, que suponen un 39% del total y las que no coincide su clase que representan el 51% restante. Por tanto, desde el punto de vista de la leyenda establecida en este trabajo, el 61% de las parcelas tendría asignada una clase errónea en la base de datos catastral. Este alto porcentaje de discrepancias entre ambas bases de datos no significa que la base de datos catastral sea de baja calidad, sino que se han utilizado criterios distintos en la definición de ciertas clases, aún teniendo el mismo nombre, en ambas leyendas. Por otra parte, la fecha de creación de ambas informaciones es diferente y en numerosos casos no coincide la clase asignada, debido a los cambios en el uso del suelo ocurrido entre las fechas de realización de ambas.

La implantación de la metodología propuesta para hacer la actualización de la base de datos catastral de forma semiautomática mediante la incorporación de la información resultante de la clasificación, requiere recodificar la información contenida en la base catastral, conforme a una leyenda que coincida con la establecida en la clasificación y que esté basada en características apreciables por parte del sistema.

En el caso de definir clases heterogéneas según sus propiedades visuales, es conveniente definir subclases homogéneas para, posteriormente a la clasificación, fusionarlas en la clase superior.

En la primera actualización de la base de datos catastral según esta metodología se asignaría, mediante la clasificación de la imagen, una clase a cada parcela. Todas aquellas parcelas cuya clase asignada no coincida con la clase catastral, deberían ser revisadas por un fotointérprete y, en el caso de incertidumbre en la asignación de la clase, habría que determinar el uso con visitas de campo. Con este proceso de revisión en la primera actualización se cumplen dos objetivos distintos: por un lado, se realiza la conversión de la leyenda catastral a la nueva leyenda, ya que todas las parcelas cuya clase catastral no coincida directamente con una clase en la nueva leyenda serán revisadas. Por otro lado, se comprueban las discrepancias entre la clase catastral y la obtenida en la clasificación, debidas bien a errores en alguna de las dos asignaciones, o bien a cambios de uso que se han detectado correctamente y que deben ser confirmados por el operador.

En actualizaciones sucesivas, el número de parcelas a revisar sería más reducido ya que la leyenda previa y la posterior a la actualización estarían unificadas y la base de datos más depurada frente a la base inicial.

En la tabla 6-34 se muestran las posibles combinaciones entre los tres conjuntos de datos a comparar.

| | Verdad terreno | Base de datos | Clasificación |
|----------|----------------|---------------|---------------|
| Aciertos | A | A | A |
| Cambios | A | B | A |
| Error 1 | A | A | B |
| Error 2 | A | C | B |
| Error 3 | A | B | B |
| Error 4 | A | 1 | A o B |

Tabla 6-34. Tipos de combinaciones posibles de datos

Sea el uso de una parcela el valor A en el instante de la toma de la imagen. Las posibles combinaciones de los datos dan lugar a las categorías siguientes:

- *Aciertos:* Coincide la clasificación con la base de datos y la verdad terreno.
- *Cambios:* La clasificación asigna correctamente el uso que es incorrecto en la base de datos.
- *Error tipo 1:* La clasificación asigna incorrectamente el uso que es correcto en la base de datos.
- *Error tipo 2:* La clasificación asigna incorrectamente el uso que también es incorrecto en la base de datos y ambos no coinciden.
- *Error tipo 3:* La clasificación asigna incorrectamente el uso que también es incorrecto en la base de datos y ambos coinciden.
- *Error tipo 4:* El uso asignado en la base de datos no coincide con ninguna de las clases en la leyenda de la clasificación. Por lo tanto, debe revisarse independientemente del resultado de la clasificación.

Como se muestra en la tabla 6-35, de las 3.999 parcelas procesadas y clasificadas, 1.219 parcelas (30.5%) no han tenido cambio de uso y su uso ha sido correctamente detectado, por lo que no es necesaria revisión alguna. Los cambios de uso correctamente detectados son 1.634 parcelas (40.8%) que deben ser revisadas para verificar el cambio de uso. En cambio, 348 parcelas (8.7%) son detectadas como cambios cuando en realidad no ha existido ningún cambio, por lo que serán revisadas para corregir los errores de asignación cometidos en la clasificación. Las parcelas cuyo uso en la base de datos no coincide con el asignado en la clasificación, siendo ambos erróneos, son 291 (7.3%) y también deben ser revisadas. En cambio, las parcelas cuyo uso catastral coincide con el asignado por la clasificación siendo ambos erróneos son 106 parcelas (2.7%). Este último grupo de parcelas no puede ser detectado con la condición establecida y, por tanto, su uso no se modificará, siendo el único conjunto de parcelas cuyo cambio de uso no será detectado. Las parcelas cuyo uso catastral corresponde a clases que no existen en la leyenda utilizada son 401 (10%) y deben ser revisadas.

| | Número de parcelas | Porcentaje (%) | Revisión |
|----------|--------------------|----------------|----------|
| Aciertos | 1219 | 30.5 | No |
| Cambios | 1634 | 40.8 | Sí |
| Error 1 | 348 | 8.7 | Sí |
| Error 2 | 291 | 7.3 | Sí |
| Error 3 | 106 | 2.7 | No |
| Error 4 | 401 | 10.0 | Sí |
| TOTAL | 3999 | 100 | |

Tabla 6-35. Identificación de las parcelas a revisar

En resumen, del conjunto de parcelas un 33.2% no se revisarían, de las cuales un 2.7% del total, sí deberían ser revisadas por tener asignada una clase errónea. Este 2.7% es el grado de error que tendría la base de datos tras la actualización, suponiendo que en el proceso de revisión no se cometieran más errores.

Las parcelas a revisar suponen un 66.8%, de las cuales 58.1% son debidas a cambios o a discrepancias entre las leyendas. Mientras que un 8.7% corresponden a cambios erróneamente detectados.

En esta primera actualización, la proporción de parcelas a revisar es muy elevada debido a las discrepancias en la definición de las leyendas y a la alta desactualización de la base catastral. En sucesivas actualizaciones periódicas, el número de parcelas a revisar se reduciría drásticamente en caso de emplear leyendas comunes. El grado de acierto de la clasificación realizada es del 74.7%, por lo tanto en el caso de que las leyendas fueran comparables directamente, el número de parcelas a revisar sería del orden del 25% del total más el porcentaje correspondiente a los cambios ocurridos.

Por otra parte, una actualización periódica con esta metodología permitiría almacenar un historial con las características calculadas para cada parcela en cada una de las actualizaciones, de modo que la información previa de la parcela no se limitaría a la clase anterior sino que estaría complementada con la descripción de la parcela en todas las variables extraídas de la misma en fechas anteriores. La comparación de las descripciones cuantitativas de cada parcela en dos instantes, separados un intervalo de tiempo determinado, permitirá detectar cambios siempre que la variación de estas características fuera superior a un umbral que debe ser establecido de forma que se asegure la detección de todos los cambios y, al mismo tiempo, se limite al máximo el número de parcelas a revisar.

6.8.9.- Revisión mediante fotointerpretación y visitas de campo

La modificación del uso de una parcela es una tarea que debe ser contrastada por un operador mediante fotointerpretación asistida por ordenador, en la mayoría de casos, o bien mediante la realización de visitas de campo en aquellos casos más problemáticos.

El operador debe tener la opción de consultar toda la información disponible sobre el uso de la parcela en cualquier tipo de formato digital. El uso de los SIG actuales, permite combinar imágenes con características diversas en cuanto a sensores, resoluciones, fechas de adquisición, etc. con la información gráfica y alfanumérica de bases de datos de distinta procedencia y con la información resultante de la clasificación. De esta forma dispondrá de forma inmediata de toda la información disponible a la hora de realizar la asignación del uso con la mayor precisión posible. El desarrollo de una herramienta SIG que facilite la consulta de la información asociada a una parcela en distintas bases de datos, así como la visualización de la representación de la parcela en las imágenes disponibles, acelera enormemente el proceso de revisión al mismo tiempo que facilita el trabajo del operador. En la figura 6-53 se muestra, a modo de ejemplo, la aplicación creada en el grupo de Cartografía Geoambiental y Teledetección de la U.P.V. para la actualización del inventario citrícola de la provincia de Castellón.

El empleo de estas técnicas permite generar de forma automática fichas para revisión en campo con toda la información relevante para el operador de campo, así como mapas de localización y listados que faciliten la planificación de las salidas de campo.

La utilización de ordenadores portátiles o *tablet PC*, con toda la información disponible, posicionamiento GPS, y la aplicación informática adecuada permite agilizar los procesos de localización e identificación de las parcelas, así como la introducción en la base de datos de las clases observadas por el operador.



Figura 6-53. Aplicación SIG para la fotointerpretación de parcelas con clases no coincidentes

Capítulo VII

CONCLUSIONES Y LÍNEAS DE INVESTIGACIÓN FUTURAS

7.1.- Conclusiones

En esta tesis se ha desarrollado una metodología para la actualización de bases de datos cartográficas de usos del suelo, basada en la integración y el análisis de información cartográfica vectorial, ortoimágenes e información temática. Esta metodología se ha aplicado para su evaluación y discusión en un caso real.

El primer punto a destacar de este trabajo consiste en la profundización en una nueva tendencia en el análisis de imágenes de la superficie terrestre para la actualización de bases de datos espaciales de usos del suelo mediante la integración de la información disponible de distintas fuentes y en distintos formatos, en lugar del empleo único o fundamental de imágenes. La combinación de distintos tipos de información lleva asociada la combinación de las técnicas y herramientas propias del tratamiento de esa información. De forma más concreta, se combinan metodologías propias de la teledetección y el procesado digital de imágenes con procesos y técnicas propias de los sistemas de información geográfica, produciéndose la fusión de las dos tipologías de información cartográfica digital: ráster y vectorial. Este enfoque supone un cambio sustancial en la adquisición de información sobre el territorio ya que se introduce en una misma metodología información de distintas fuentes que tradicionalmente se han tratado separadamente. Los resultados obtenidos permiten afirmar que la combinación de estas fuentes de datos es fundamental para la creación de un sistema que interprete el territorio de forma semiautomática con una fiabilidad alta y un grado de detalle elevado y a continuación, detecte los cambios ocurridos desde la generación de la base de datos hasta

la toma de la imagen. De esta forma, se consigue una reducción significativa de tiempo y costes por medio de un intenso procesado de las fuentes de datos.

El primero de los objetivos parciales definidos en la introducción consiste en el desarrollo de una sistemática para integrar información geográfica de distintos tipos en un mismo nivel de abstracción. Este primer objetivo se ha abordado a partir de la definición del objeto de estudio que en este trabajo ha sido la sub-parcela catastral ya que es el elemento poligonal con mayor grado de detalle en la cartografía catastral y con un uso homogéneo. En la base de datos catastral, cada sub-parcela está identificada por la referencia catastral y está compuesta por una geometría y una serie de atributos alfanuméricos asociados. En el sistema propuesto se ha empleado el mismo modelo de datos y cada objeto está representado por un vector de características descriptivas que pueden ser tanto continuas como discretas. La utilización de la sub-parcela catastral como unidad mínima de estudio permite integrar la información alfanumérica asociada a la sub-parcela y a la parcela de la que forma parte, junto con la información del resto de bases de datos geográficas que emplean la referencia catastral como identificador. Por otra parte, su definición geométrica permite describir su morfología y, al mismo tiempo, extraer a partir de imágenes, modelos digitales, cartografía ráster, etc., la región correspondiente para su posterior procesado y análisis.

En el capítulo V se recoge el conjunto de características definidas orientadas a la descripción de parcelas en ámbitos agrícolas y forestales. Esta metodología de extracción de características está condicionada por los datos de partida disponibles y por las propiedades del paisaje de la zona de estudio. La aplicación de esta metodología en áreas con diferentes propiedades o sobre datos distintos, requeriría un ajuste de determinados umbrales establecidos en el procesado de imágenes así como una selección de variables de acuerdo a las características del paisaje a describir. El conjunto de variables definido extrae rasgos descriptivos de las parcelas similares a los percibidos por un fotointérprete y permite identificar correctamente el uso de aquellas parcelas que tienen un único uso y una forma regular respecto al conjunto de las parcelas representativas de su clase.

La descripción completa de los objetos se logra analizando cada objeto desde distintos puntos de vista; se han definido características espectrales, texturales, estructurales, de forma, topográficas, relativas a los árboles contenidos en la parcela obtenidos mediante la segmentación automática de imágenes, relativas a la proporción de superficie ocupada por una determinada cobertura y relativas a la información alfanumérica contenida en la base de datos asociada. La mayor parte de estas características descriptivas se han obtenido mediante técnicas de procesado digital de imágenes. De este apartado, cabe destacar la definición de un conjunto de nuevas características estructurales que permiten cuantificar numéricamente distintos aspectos de los elementos contenidos en la parcela. La extracción de características estructurales sigue

un proceso gradual pasando de la descripción global del objeto a la descripción de los sub-objetos contenidos en la misma. Las variables extraídas del semivariograma experimental permiten describir la regularidad espacial de la parcela e informan sobre la existencia o ausencia de patrones regulares espacialmente. Una vez obtenida la información sobre el comportamiento global de la parcela, se utiliza esta información como punto de partida para otros análisis más detallados. Más concretamente, la información deducida del semivariograma se emplea como información de partida para la aplicación del método de detección de árboles basado en la identificación de máximos locales. En el ensayo de la sección 6.2 se comprobó que la posición del primer máximo del semivariograma es un indicador muy preciso para determinar el tamaño de los árboles situados en parcelas a las que corresponde un semivariograma cíclico. Las dos condiciones necesarias para que una parcela tenga un semivariograma omnidireccional cíclico son que ésta tenga un marco de plantación bien definido y que los árboles tengan un tamaño de copa lo suficientemente grande para ser detectados por medio del semivariograma. La precisión del método disminuye conforme no se cumplen alguna de estas dos condiciones. En dicho ensayo, el tamaño medio de los árboles en las parcelas con semivariogramas cíclicos se estimó con un error medio inferior a un metro.

Los cultivos arbóreos son relativamente sencillos de identificar por un fotointérprete mediante el estudio de las características de las copas y su distribución espacial. En cambio, su identificación automática resulta compleja por su heterogeneidad y por la combinación de varios tipos de cubiertas en una misma parcela. La novedosa metodología propuesta de localización de alineaciones de árboles con la transformada de Hough permite detectar la existencia o ausencia de marco de plantación en una parcela y, al mismo tiempo, ha demostrado su utilidad para obtener las dimensiones del marco de plantación. La cuantificación de estas propiedades contribuye significativamente a la definición exhaustiva de la parcela facilitando la identificación de su uso. En el ensayo de la sección 6.3 se muestra cómo con las variables extraídas de la aplicación de la transformada de Hough sobre el conjunto de puntos representativos de árboles, se ha determinado la existencia o ausencia de marco de plantación con una fiabilidad superior al 90%. Al mismo tiempo, las dimensiones de los marcos de plantación se han obtenido, mediante esta técnica, para el 85% de las parcelas con un error medio igual o inferior a un metro.

El desarrollo de una metodología propia de segmentación automática de árboles junto a la definición de características descriptoras de dichos polígonos representativos de árboles, facilita la identificación de la tipología de cultivo presente en una parcela. Esta segmentación se inicia con la aplicación de un nuevo método, diseñado en esta tesis, de pre-procesado de la imagen, basado en un filtrado de medio ponderada, donde el peso de cada píxel es inversamente proporcional a su distancia espectral al píxel central en la

ventana de aplicación. La aplicación de este filtrado facilita enormemente la clasificación posterior al homogeneizar internamente los objetos y eliminar los píxeles de borde.

Una vez segmentados y caracterizados los árboles interiores a la sub-parcela, la descripción de la misma se ve ampliada por características que no son propias sino que describen los sub-objetos contenidos en ella. El hecho de no seleccionar muestras de los objetos a extraer en la imagen redundante en una aplicación más rápida del proceso, ganando en objetividad y repetitividad pero perdiendo en precisión, ya que en determinados casos pueden ser seleccionados como árboles objetos que no lo sean. En el ensayo de la sección 6.4 se ha comprobado que la metodología de segmentación desarrollada permite extraer la superficie cubierta por vegetación arbórea con un alto grado de ajuste, especialmente en el caso de los árboles adultos. Esta información resulta útil tanto para la descripción exhaustiva de la parcela con el objeto de su posterior clasificación, como en aplicaciones en las que resulte necesario conocer la superficie cubierta por los árboles, como por ejemplo: estudios de irrigación, inventarios forestales en los que se calcula la fracción de cabida cubierta, cálculo de biomasa, estimación de producciones frutales o madereras, etc.

En los ensayos de clasificación de cultivos arbóreos contenidos en la sección 6.5, se identifican con una fiabilidad alta, comprendida entre el 83 y el 88% en función del número de características utilizadas y del método de clasificación empleado, el cultivo existente en las parcelas por medio de las características espectrales, de forma y de tamaño de los distintos sub-objetos, confirmándose que el cultivo arbóreo de una parcela puede determinarse únicamente mediante el análisis de la descripción completa de los árboles que contiene.

La realización de una clasificación por píxel previa y la incorporación a la descripción de los objetos del porcentaje de los píxeles clasificados en cada clase de la clasificación por píxel han sido frecuentemente utilizadas en la bibliografía de clasificación por objetos y, a priori, podían parecer interesantes para explicar el contenido de la parcela. Sin embargo, no han resultado efectivas en los ensayos realizados al tener un menor poder de separación entre clases que otras de las características propuestas.

En la descripción de los objetos se han incorporado características topográficas que, en determinados casos, pueden ser condicionantes del uso del suelo que se da en el mismo. Aunque en los ensayos realizados, la participación de estas variables ha sido reducida, en el caso de clases de usos del suelo con propiedades geográficas determinantes las variables topográficas resultan fundamentales para su descripción.

El hecho de considerar agrupaciones de píxeles u objetos, en lugar de píxeles aislados como unidades a clasificar, comporta que se pueden considerar características descriptivas, como son las relativas a la forma o al tamaño del objeto, que en el caso de

los píxeles aislados no aportan nada a la descripción del píxel. En cambio, en el enfoque por objeto, las características de forma y tamaño de los objetos han demostrado su utilidad en dos vertientes distintas:

- En la clasificación de objetos resultan básicas para separar ciertos tipos de objetos gráficos como son las vías de comunicación del resto.
- En la clasificación de sub-objetos han resultado fundamentales para discriminar tipologías de cultivos arbóreos.

En el objetivo parcial cuarto se plantea el estudio de las alternativas para incorporar la información auxiliar en la generación de los objetos y en su posterior clasificación. En la sección 3.5 se describen las distintas posibilidades de incorporación de la información externa a la imagen en el proceso de clasificación. Las distintas alternativas tienen en común el intentar dirigir la clasificación de forma que la asignación de una clase a un objeto no se limite a un cálculo estadístico o de distancias sino que intervenga la lógica establecida por el usuario o la que se pueda extraer del análisis combinado de las características descriptivas y la información de la base de datos. En la metodología desarrollada en esta tesis, la información externa a la imagen se utiliza en tres instantes distintos. En primer lugar, la información gráfica contenida en una cartografía digital se emplea para la generación de los objetos de estudio, conservándose así la división del espacio ya establecida en la base de datos a actualizar. Respecto a la información alfanumérica, en la sección 6.7 se ha comprobado el efecto de la incorporación en la clasificación, como una variable descriptora más de cada parcela, del uso previo a la actualización contenido en la base de datos. El algoritmo C5.0 ha mostrado ser eficiente en la gestión de este tipo de variables discretas de forma que las fiabilidades globales de las clasificaciones aumentan al emplear estas variables. Estos incrementos de fiabilidad global están relacionados con el grado de actualización de la base de datos. Es decir, los incrementos de fiabilidad mayores corresponden a aquellos casos en los que la base de datos estaba más actualizada. Del mismo modo, el algoritmo C5.0 emplea esta variable de forma gradual, la utiliza para clasificar un número reducido de parcelas cuando la base de datos está considerablemente desactualizada y por lo tanto la variable tiene una validez reducida, mientras que en el caso de bases de datos actualizadas su empleo es más frecuente. Según los resultados obtenidos, el empleo de esta variable resulta adecuada en el proceso de creación de una base de datos, no así en el proceso de actualización de una base de datos ya que aunque se reduce el número de parcelas a revisar, parte de los errores contenidos en la base de datos se trasladan a la clasificación resultando imposibles de detectar mediante la comparación de la base de datos con el resultado de la clasificación, produciéndose por tanto una reducción en la precisión de la asignación de clases a los objetos de la base de datos. En el ensayo sobre la actualización de toda la base de datos correspondiente a la zona de estudio mostrado en la sección 6.8.5, la

incorporación del uso catastral ha supuesto un incremento del 4% en la fiabilidad global, mientras que las fiabilidades de usuario y productor de las distintas clases han permanecido estables o bien han aumentado en distinto grado. En ninguno de los casos, la incorporación de esta información ha supuesto un decremento de la fiabilidad de la predicción realizada por el clasificador. Las conclusiones obtenidas respecto a la inclusión del uso previo como característica descriptora resultan novedosas ya que habitualmente es una información de la que se dispone en un proceso de actualización cartográfica, que suele ser consultada por los fotointérpretes en los procesos manuales, pero no en la generación automática de cartografía temática al no poder ser procesada por los clasificadores estadísticos o basados en distancias.

Como paso final, la información respecto al uso previo de la parcela se tiene en consideración en la fase de detección de cambios. La actualización de una base de datos no debe suponer una pérdida de calidad y por eso cualquier modificación de la información contenida en la misma debe estar confirmada por un intérprete. Esta detección de cambios se obtiene mediante la comparación de la información contenida en la base de datos con la obtenida del proceso global de clasificación desarrollado. La confirmación del cambio por un fotointérprete garantiza que la base de datos no pierda calidad con una metodología más rápida, económica y efectiva que la revisión manual de todas las parcelas.

Dado el volumen de características definidas, es conveniente realizar un proceso selectivo de las mismas con el fin de que sólo participen en la clasificación aquellas que no sean redundantes y aporten información significativa para la discriminación de clases. En el ensayo realizado en la sección 6.8 sobre el conjunto de parcelas de la zona de estudio, se comprobó que las características más empleadas en la clasificación correspondían a características estructurales, texturales, espectrales y extraídas de la segmentación de árboles. Las características topográficas tuvieron una importancia reducida mientras que las características extraídas de la clasificación por píxel no fueron empleadas.

Respecto al objetivo parcial sobre la adecuación de los algoritmos de creación de árboles de decisión para la clasificación de imágenes, se ha demostrado la efectividad del conjunto de reglas de clasificación deducidas por el algoritmo C5.0 para relacionar las clases a asignar a los objetos con las características descriptivas de los mismos. Estas condiciones son inteligibles para el usuario lo que permite la interpretación del proceso de clasificación seguido por cada objeto. De forma implícita a la aplicación de este algoritmo se realiza una selección de variables según su adecuación para la generación de subconjuntos más homogéneos. Por otra parte, este algoritmo tiene la ventaja de aceptar distintas tipologías de características, ya que acepta tanto datos continuos, que no necesariamente deben seguir una distribución normal, como datos discretos. Esta flexibilidad respecto a los datos que puede gestionar permite describir los objetos con atributos difíciles de tratar por otros clasificadores.

La aplicación del algoritmo C5.0 por medio del método multclasificador *boosting* da lugar a clasificaciones en las que aumenta de forma significativa la precisión respecto a la clasificación mediante un único árbol de decisión. Este multclasificador genera conjuntos de árboles de decisión tan ajustados a las muestras de entrenamiento suministradas que es necesaria la aplicación de algún tipo de poda de los árboles de decisión para que las predicciones de los árboles ganen en generalidad y no estén condicionadas en exceso por las particularidades de las muestras de entrenamiento. La inteligibilidad que proporciona la clasificación mediante árboles de decisión, que se ve reducida parcialmente por la aplicación del multclasificador *boosting*, facilita la comprensión de la lógica empleada por el clasificador y, por lo tanto, permite tomar medidas para corregir los errores de clasificación.

El objetivo principal de la Tesis sobre el establecimiento de una metodología para la actualización de una base de datos cartográfica de usos del suelo en un paisaje agrícola mediante la detección automática de los cambios se ha desarrollado de forma desglosada a lo largo de toda esta memoria, y su aplicación práctica sobre una zona de estudio real y con los datos disponibles se ha desarrollado en la sección 6.8. La aplicación de la metodología ha mostrado que los beneficios respecto a la detección de cambios manual son significativos. En primer lugar, el número de parcelas a revisar en la actualización tradicional de una base de datos es ingente, del orden de varios miles por municipio, por lo que la reducción del trabajo manual será altamente positiva siempre que se garantice el mantenimiento de la precisión de la base de datos. En la metodología propuesta, el tiempo necesario para la selección de muestras, el establecimiento de parámetros para el procesado de las imágenes y la revisión de los cambios detectados es significativamente menor que la revisión de la totalidad de las parcelas. Esta reducción de tiempo será tanto mayor cuanto mayor sea el número de parcelas a revisar ya que el tiempo necesario para el establecimiento de los parámetros y la selección de muestras es independiente del número de parcelas a procesar. Además, la precisión de la base de datos no se ve alterada, ya que todos los cambios que se realizan en la información de la base de datos son supervisados por un fotointérprete.

En el ensayo sobre la zona de estudio se han obtenido fiabilidades globales en la clasificación de las parcelas del 78.4% cuando se consideró el uso previo y del 74.7% cuando no se tuvo en cuenta esta información. Del total de parcelas, el porcentaje a revisar supone un 66.8% que corresponde en un 49.5% a parcelas cuyo uso ha cambiado y ha sido correctamente detectado, un 10% son parcelas donde la clase en la leyenda de la base de datos no tiene correspondencia con ninguna de las clases de la leyenda y un 8.7% corresponde a errores cometidos por el sistema en la clasificación del uso. Por otra parte, un 2.7% del total de las parcelas han tenido un cambio de uso y no ha sido detectado por lo que no serán revisadas y su información permanecerá errónea tras la

actualización de la base de datos. Este 2.7% es el grado de error que tendrá la nueva base de datos una vez finalizada la actualización.

Los ensayos han demostrado que las parcelas con usos bien definidos y, por así decirlo, sencillas de interpretar para un fotointérprete se clasifican de forma automática con un grado elevado de precisión. En cambio, la aplicación efectiva de esta metodología se ve dificultada cuando se dan algunos de los factores siguientes:

- Polígonos de dimensiones muy reducidas donde la asignación de la clase sólo se puede deducir considerando el entorno en el que está situado el polígono.
- Parcelas agrícolas en estado de abandono en las que la pertenencia a una clase no es evidente.
- Polígonos donde se dan varios usos: Requiere una delineación manual de los distintos usos o un análisis más exhaustivo que discrimine dos o más usos en el interior de cada objeto.
- No coincidencia entre la cartografía y la imagen: Los defectos de georreferenciación, bien de la cartografía o bien de la imagen, implican que la extracción de la imagen de la región correspondiente al objeto no se realice de forma exacta. Este error tiene más importancia cuanto menor es el tamaño de los objetos.
- Cartografía geoméricamente desactualizada. El hecho de que los contornos de los objetos representados en la cartografía no coincidan con los existentes en la imagen a causa de la desactualización de la cartografía dificulta la aplicación de esta metodología. La mayor parte de estos desajustes son detectados en la fase de comparación de la clase asignada con la contenida en la base de datos.
- Existencia de clases en la leyenda poco representadas en la zona de trabajo. Debido a la metodología empleada por el algoritmo C5.0 en la creación de los árboles de clasificación, diferencias notables en el número de muestras de entrenamiento de clases similares pueden derivar en que las parcelas pertenecientes a las clases infra-representadas se asignen de forma incorrecta en las clases similares más representadas.
- Leyenda de la base de datos no acorde con la metodología utilizada para la creación o actualización de la base de datos. La leyenda a utilizar debe establecerse de modo que las clases sean separables según las características extraídas de la imagen o de las fuentes de información auxiliares.

La descripción numérica de los objetos desde distintos puntos de vista hace que esa descripción sea objetiva e independiente del criterio de distintos fotointérpretes. Por otra parte, las descripciones de un mismo objeto en instantes distintos pueden compararse

a fin de detectar cambios en su ocupación, siendo ésta una de las líneas de investigación que se proponen para el futuro como se comenta en la sección siguiente.

El análisis combinado de las diversas fuentes de información disponible sobre el territorio, ya sean imágenes de alta resolución, cartografía, información temática, geográfica, conocimiento experto, etc. dentro de un proceso que debe ser lo más inteligible, objetivo y automatizado posible tiene un gran potencial en la automatización de diversas fases de la actualización de bases de datos de usos y ocupación del suelo. La consecuencia más evidente de su aplicación es la reducción del tiempo necesario para la detección de los cambios ocurridos en el territorio de forma que posibilita el aumento en la frecuencia de actualización de las bases de datos que en la actualidad se crean y mantienen con metodologías que requieren un grado de intervención humana muy alto. Al mismo tiempo, estas técnicas pretenden responder a la necesidad creciente de nuevas herramientas para el tratamiento de los datos obtenidos por sensores de alta resolución, que son cada vez más abundantes.

Como resultado del desarrollo de esta Tesis y de otros trabajos del Grupo de Investigación en Cartografía GeoAmbiental y Teledetección de la Universidad Politécnica de Valencia se ha implementado el software propio de extracción de características llamado FETEX (figura 7.1) en el que se realiza la integración de la cartografía con las imágenes de alta resolución y con el que se obtiene la extracción de la mayor parte de las características presentadas en esta Tesis.

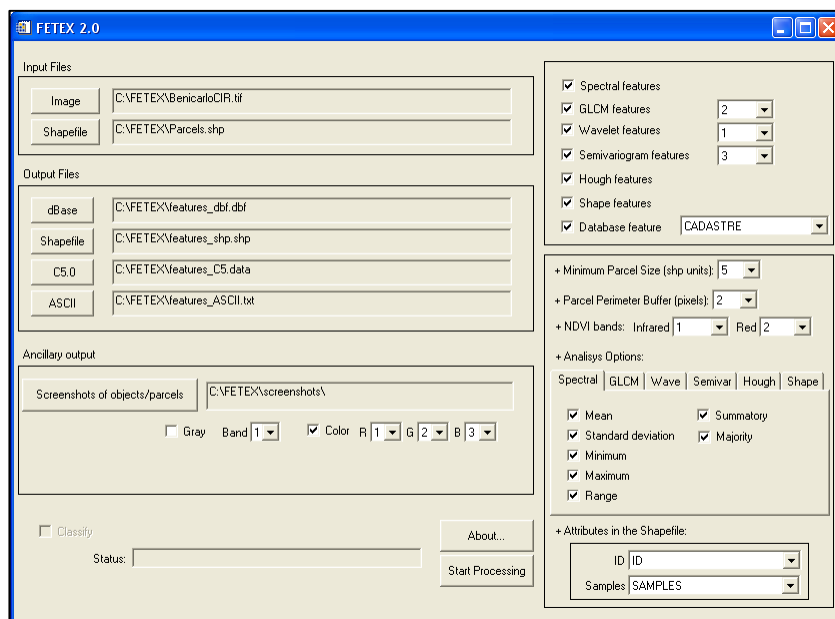


Figura 7-1. Interfaz gráfico de FETEX 2.0

La metodología presentada en esta Tesis se ha utilizado con éxito en varios trabajos de producción como la actualización del SIG Citrícola de la Comunidad Valenciana en la provincia de Castellón, en la actualización del Inventario de Cultivos de la Región de Murcia y en la elaboración de cartografía de usos del suelo para el Banco de Terras de Galicia. Las fiabilidades obtenidas en las clasificaciones de estos trabajos oscilan entre el 78% y el 93%, siendo paisajes, leyendas y datos de partida muy distintos entre sí. En todos los casos, la aplicación de esta metodología supone una reducción significativa en los tiempos de actualización de la base de datos al reducirse en gran medida el número de parcelas a revisar por los fotointérpretes.

7.2 Líneas futuras de investigación

La realización de esta tesis ha abierto varias líneas de investigación cuyo desarrollo puede mejorar la clasificación de los objetos contenidos en la base de datos. Estas posibles líneas harían referencia a las distintas fases del proceso de clasificación.

En primer lugar, por lo que respecta a las unidades de estudio, en esta tesis se ha considerado que los polígonos contenidos en la base de datos tienen un uso homogéneo. Esta suposición, aún siendo cierta en la mayor parte de los casos, no lo es en otros. Sería conveniente el estudio de métodos que permitieran determinar el número de usos que se dan en el interior del objeto así como sus límites para su posterior clasificación. La **segmentación intraobjeto** sin conocer a priori el número de regiones interiores al objeto que existen, ni la tipología de las mismas, se plantea como una tarea compleja pero de gran interés para la clasificación por parcelas de espacios agrarios. En este sentido, el algoritmo desarrollado por Turker y Kok (2006) para la segmentación de usos en el interior de parcelas ofrece resultados prometedores siempre que los distintos usos sean regiones espectralmente homogéneas.

Respecto a la extracción de características descriptivas de los objetos pueden proponerse varias líneas de mejora:

- Del mismo modo que se ha utilizado el tratamiento masivo de datos (*data mining*) para extraer relaciones entre las clases y las características descriptivas de los objetos, se plantea la posibilidad de aplicar **tratamiento masivo de datos espaciales** para extraer conocimiento sobre las propiedades espaciales y las relaciones entre los objetos. La descripción de un objeto será perfeccionada si al conjunto de características propuestas se añaden sus características espaciales relativas a conceptos como vecindad, proximidad, inclusión, etc.
- El empleo de **datos multitemporales** de una misma campaña dota al análisis de información respecto al estado fenológico de la vegetación, tanto de los cultivos como espontánea, en distintos momentos de su ciclo vegetativo. La adecuada selección de las fechas de adquisición de las imágenes facilita la discriminación entre cultivos que pueden tener apariencia semejante en determinados estadios de su ciclo. Especies arbóreas caducifolias, cultivos hortícolas, herbáceos, etc. pueden ser descritos con mayor rigurosidad incorporando la información temporal. La inclusión de imágenes de distintas fechas requiere la definición de características que relacionen el comportamiento de los objetos en ambas representaciones.

- Las imágenes **hiperespectrales** aportan una mayor cantidad de información sobre el comportamiento espectral de las cubiertas, facilitando la diferenciación entre cultivos con propiedades espectrales similares gracias a su mayor resolución espectral que permiten identificar rasgos imperceptibles con sensores multiespectrales.
- La adquisición de las **imágenes radar** de alta resolución espacial, como las recientemente disponibles del sensor Terrasar-X, no está limitada por la iluminación solar o los factores meteorológicos, por lo que puede ser una fuente adicional de información, especialmente en las áreas con nubosidad elevada.
- El empleo de **datos LIDAR** facilita la obtención de modelos digitales del terreno y modelos digitales de superficie a partir de los cuales se pueden generar modelos digitales de superficie normalizados que informan sobre la estructura tridimensional de la vegetación. Esta información resulta especialmente interesante para la localización, extracción y descripción de la vegetación al incorporar una nueva variable como es la altura de los árboles y/o el matorral.

En relación a la fase de clasificación, el algoritmo utilizado para crear los árboles de decisión establece una serie de condiciones basadas en las características suministradas para clasificar los objetos. En ocasiones, el **conocimiento** de un **experto** sobre el territorio a caracterizar puede ser expresado también mediante reglas de clasificación. La integración de las reglas deducidas por un algoritmo con las generadas por un experto podría incrementar la precisión de las clasificaciones. Esta integración de reglas provenientes de distintas fuentes no es inmediata y requiere el establecimiento de una metodología que permita la combinación de ambos tipos de conocimiento, de modo que las condiciones establecidas por el algoritmo de creación de árboles estén supeditadas a las condiciones fijadas por el experto.


Resulta necesaria la estimación de un parámetro que indique el grado de confianza o de incertidumbre con el que un objeto se asigna a una clase. Este parámetro permitiría determinar aquellos objetos que, por estar clasificados con una fiabilidad baja, requieren un post-procesado más profundo en aras de asignarlo a su clase correspondiente así como para evaluar el rendimiento de distintos clasificadores sobre un mismo conjunto de datos. El indicador de la confianza con la que se hace la clasificación que provee el algoritmo C5.0 no resulta completamente fiable ya que es dependiente de las muestras de entrenamiento seleccionadas y no considera las características de las distintas fuentes de datos que intervienen.

Las actualizaciones sucesivas de una misma base de datos con la metodología propuesta permitirían perfeccionar la detección de cambios mediante la comparación de los valores de las características extraídas de la imagen más reciente con las características extraídas de las imágenes correspondientes a momentos anteriores. El estudio de las variaciones en los valores de las mismas variables en fechas distintas permitiría determinar umbrales por encima de los cuales se estaría produciendo un cambio en el uso de la parcela, mientras que variaciones inferiores a ese umbral corresponderían a diferencias entre las imágenes por otros motivos. Es de esperar, que la aplicación de la extracción de características en dos instantes distintos tenga un gran potencial para la detección de cambios ya que permitiría comparar con detalle la descripción de cada parcela en dos momentos distintos.


Anejo I

FICHAS DE REVISIÓN EN CAMPO

FICHA DE REVISIÓN EN CAMPO

| | | | |
|---|---|--------------------|-----------|
| Municipio | Benicarló | Fecha: | 24-1-2006 |
| Identificador | 2811 | Coordenadas U.T.M. | |
| Polígono | 3 | Datum | ED50 |
| Parcela | 260 | Huso | 30 |
| Cultivo | Regadío no cultivado | X = | 787776 |
| Estado | Terreno preparado para plantación | Y = | 4484911 |
| Observaciones | Aproximadamente el 15% de la superficie está cultivada con productos hortícolas. El resto no tiene cultivo. | | |
| Fotografía | | | |
|  | | | |

FICHA DE REVISIÓN EN CAMPO

| | | | |
|---|--|--------------------|-----------|
| Municipio | Benicarló | Fecha: | 24-1-2006 |
| Identificador | 2479 | Coordenadas U.T.M. | |
| Polígono | 2 | Datum | ED50 |
| Parcela | 181 | Huso | 30 |
| Cultivo | Algarrobos | X = | 788301 |
| Estado | En producción | Y = | 4486723 |
| Observaciones | Se alternan los algarrobos adultos con olivos de porte inferior. | | |
| Fotografía | | | |
|  | | | |

Anejo II

CLASIFICACIÓN POR PÍXEL

Con el objeto de preservar la información respecto a la heterogeneidad interna de los objetos y mejorar su descripción, se realizó una clasificación a nivel de píxel, de forma que para cada objeto se conociera el porcentaje de sus píxeles clasificados en las clases de la leyenda de la clasificación por píxel.

Las clases establecidas son: *Agua, Asfalto, Edificios amarillos, Edificios azules, Frutales de regadío, Frutales de secano, Matorral, Regadío, Sombras, Suelo desnudo claro y Suelo desnudo oscuro.*

Esta clasificación se realizó por el método de Máxima Probabilidad seleccionando dos conjuntos de muestras independientes para entrenamiento y evaluación del clasificador. Tras la evaluación de la clasificación mediante las muestras de evaluación, que no fueron utilizadas en el entrenamiento del clasificador, se obtuvo una fiabilidad global del 77.4%. Las fiabilidades de productor y de usuario se muestran en la tabla A2-1.

| CLASE | F. Productor | F. Usuario |
|---------------|--------------|------------|
| Agua | 70.45 | 89.38 |
| Asfalto | 64.19 | 75.16 |
| Edif. amar. | 91.97 | 77.91 |
| Edif. azules | 97.67 | 99.7 |
| Frut. regadío | 44.95 | 74.72 |
| Frut. secano | 54.85 | 38.11 |
| Matorral | 85.49 | 85.68 |
| Regadío | 84.44 | 82.17 |
| Sombras | 97.48 | 86.93 |
| S.D. Claro | 69.83 | 60.19 |
| S.D. Oscuro | 71.76 | 94.61 |

Tabla A2-1. Fiabilidades de productor y de usuario

Como se puede observar, los mejores resultados se obtienen en las clases *Sombras*, *Edificios azules* y *Edificios amarillos* obteniéndose fiabilidades de productor superiores al 90%. En cambio, son las clases correspondientes a *Frutales de regadío* y *Frutales de secano* las que obtienen unas fiabilidades menores; 45% y 55% respectivamente.

En la matriz de confusión (tabla A2-2), expresada en porcentajes, se observa que en las clases correspondientes a cultivos (*Frutal de regadío*, *Frutal de secano* y *Regadío*) existe un alto grado de confusión entre ellas ya que tienen respuestas espectrales similares. Esta confusión espectral entre los cultivos afianza la necesidad de un tratamiento adicional de la información disponible para aumentar la precisión en la realización de la cartografía de zonas agrícolas. Otras confusiones destacables en la clasificación son entre la clase *Agua* y *Sombras*, entre *Suelo desnudo claro* y *Edificios amarillos* o entre *Suelo desnudo claro* y *Suelo desnudo oscuro*.

| CLASIF. | VERDAD TERRENO | | | | | | | | | | |
|---------------|----------------|---------|---------------------|------------------|----------------|---------------|----------|---------|---------|---------------------|----------------------|
| | Agua | Asfalto | Edificios amarillos | Edificios azules | Frutal regadío | Frutal secano | Matorral | Regadío | Sombras | Suelo desnudo claro | Suelo desnudo oscuro |
| Agua | 70.45 | 15.95 | 0 | 0 | 0 | 3.07 | 0 | 0 | 2.04 | 0 | 0 |
| Asfalto | 10.27 | 64.19 | 0.81 | 2.33 | 0 | 0 | 0 | 0 | 0.29 | 5.1 | 2.95 |
| Edif. amar. | 0 | 0 | 91.97 | 0 | 0 | 0 | 0 | 0 | 0 | 24.54 | 0 |
| Edif. azules | 0.44 | 0 | 0 | 97.67 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| Frut. regadío | 0 | 0 | 0 | 0 | 44.95 | 11.57 | 0 | 4.46 | 0 | 0 | 0 |
| Frut. secano | 0 | 0 | 0.1 | 0 | 41 | 54.85 | 14.13 | 11.01 | 0.19 | 0 | 2.9 |
| Matorral | 0.93 | 0 | 0 | 0 | 0 | 22.44 | 85.49 | 0.09 | 0 | 0 | 0.79 |
| Regadío | 0.98 | 0 | 0 | 0 | 14.05 | 6.47 | 0.1 | 84.44 | 0 | 0 | 0 |
| Sombras | 16.22 | 0.23 | 0 | 0 | 0 | 0 | 0 | 0 | 97.48 | 0 | 0 |
| S.D. Claro | 0.33 | 17.95 | 7.13 | 0 | 0 | 0 | 0 | 0 | 0 | 69.83 | 21.6 |
| S.D. Oscuro | 0.38 | 1.67 | 0 | 0 | 0 | 1.59 | 0.29 | 0 | 0 | 0.54 | 71.76 |
| Total | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 |

Tabla A2-2. Matriz de confusión de la clasificación por píxel

La leyenda utilizada en esta clasificación no permite una actualización directa de una base de datos de usos del suelo, ya que las clases utilizadas no se corresponden en todos los casos con la codificación empleada en las mismas. Sin embargo, sí permite el objetivo de determinar para cada parcela el porcentaje de píxeles en su interior que pertenecen a cada clase. De forma que se conserva la información respecto a las tipologías de píxeles que hay en la parcela y se reduce el efecto homogeneizador que produce el cálculo de la media sobre los niveles digitales de los píxeles.

BIBLIOGRAFÍA

Lista de abreviaturas

- CG: Computers & Geosciences
- IAPRS : International Archives of Photogrammetry and Remote Sensing (renombrada a International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences desde el volumen 33, año 2000)
- IJRS: International Journal of Remote Sensing
- OBIA: First International Conference on Object-Based Image Analysis
- PERS: Photogrammetric Engineering and Remote Sensing
- PRS: ISPRS Journal of Photogrammetry and Remote Sensing
- RSE: Remote Sensing of Environment
- RSIA: *Remote Sensing Image Analysis: Including the Spatial Domain*. S.M. De Jong y F. D. Van der Meer (eds.), Dordrecht: Kluwer Academic Publishers.

Adams, J. B., Sabol, D. E., Kapos, V., Filho, R. A., Roberts, D. A., Smith, M. O. y Gillespie, A. R. (1995). Classification of multispectral images based on fractions of endmembers: application to land cover change in the Brazilian Amazon. *RSE*, Vol. 52(2), pp. 137-154.

AGRIFISH Unit. (2007). *Common technical specifications for the 2007 campaign of remote-sensing control of area-based subsidies*. <http://mars.jrc.it/Bulletins-Publications/Common-Technical-Specifications-for-the-2007-Campaign-of-Remote-Sensing-Control-of-Arable-and-Forage-Land-Area-based-Subsidies>. (último acceso 10/11/2009)

Antunes, A., Lingnau, C. y Silva Centeno, J. (2003). Object oriented analysis and semantic network for high resolution image classification. *Boletim de Ciências Geodésicas*, Vol. 9(2), pp. 233-242.

Aplin, P., Atkinson, P. M. y Curran, P. J. (1999). Fine Spatial Resolution Satellite Sensor Imagery for Land Cover Mapping in the United Kingdom. *RSE*, Vol. 68(3), pp. 206-216.

Aplin, P. y Atkinson, P. M. (2004). Predicting missing field boundaries to increase per-field classification accuracy. *PERS*, Vol. 70(1), pp. 141-149.

Arozarena A., García, L., Villa, G. (2008). *Plan Nacional de Observación del Territorio en España*. Actas del Congreso Internacional de Ingeniería Geomática y Topográfica, TOP-CART, 18-21 Febrero, Valencia, España, on CD.

Baatz, M., Benz, U., Dehghani, S., Heynen, M., Höltje, A., Hofmann, P., Lingenfelder, I., Mimler, M., Sohlbach, M., Weber, M. y Willhauck, G. (2004). *eCognition USER GUIDE 4* on CD.

Balaguer, A., Ruiz, L.A., Hermosilla, T., Recio, J.A. Definition of a comprehensive set of texture semivariogram features and their evaluation for object-oriented image classification. *CG* (en prensa)

Baltsavias, E. P. (2004). Object extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems. *PRS*, Vol. 58(3-4), pp. 129-151.

Bauer, E. y Kohavi, R. (1999). An empirical comparison of voting classification algorithms: Bagging, boosting and variants. *Journal of Machine Learning*, Vol. 36 (1-2), pp. 105-139.

Bauer, T. y Kaiser, G. (2006). *Knowledge transfer - formalizing an interpretation key*. En S. Lang, T. Blaschke y E. Schöpfer (Ed.), OBIA. 4-5 Julio, Salzburg, Austria.
<http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).

Benz, U., Hofmann, P., Willhauck, G., Lingenfelder, I. y Heynen, M. (2004). Multi-resolution, object oriented fuzzy analysis of remote sensing data for GIS-ready information. *PRS*, Vol. 58(3-4), pp. 239-258.

Berberoglu, S., Lloyd, C. D., Atkinson, P. M. y Curran, P. J. (2000). The integration of spectral and textural information using neural networks for land cover mapping in the Mediterranean. *CG*, Vol. 26(4), pp. 386-396.

Berberoglu, S. y Curran, P. J. (2004). *Merging spectral and textural information for classifying remotely sensed images*. En RSIA, pp. 113-136.

Blaes, X., Vanhalle, L. y Defourny, P. (2005). Efficiency of crop identification based on optical and SAR image time series. *RSE*, Vol. 96(3-4), pp. 352-365.

Blaschke, T. y Strobl, J. (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *GIS - Zeitschrift für Geoinformationssysteme*, Vol. 6, pp. 12-17.

Blaschke, T., Burnett, C. y Pekkarinen, A. (2004). *Image segmentation methods for object-based analysis and classification*. En RSIA, pp. 211-236.

- Bogaert, J., Rousseau, R., Hecke, P. V. y Impens, I. (2000). Alternative area-perimeter ratios for measurement of 2D shape compactness of habitats. *Applied Mathematics and Computation*, Vol. 111(1), pp. 71-85.
- Bontemps, S. y Defourny, P. (2008). *Change detection feasibility in Corine LC map using MERIS data set. Case study in Spain and Portugal*. http://dup.esrin.esa.it/files/project/131-176-149-30_2008912104351.pdf (último acceso 10/11/2009).
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, Vol. 24(2), pp. 123-140.
- Büttner, G., Feranec, J. y Jaffrain, G. (2002). *Corine land cover update 2000. Technical guidelines*. European Environment Agency Technical report 89.
- Caetano, M. y Santos T. (2001). *Updating land cover maps with satellite images*. Proceedings of IEEE Geoscience and Remote Sensing Symposium, Vol.1, pp. 979-981.
- Catlow, D. R., Parsell, R. J. y Wyatt, B. K. (1984). The integrated use of digital cartographic data and remotely sensed imagery. *Earth Oriented Application of Space Technology*, Vol. 4(4), pp. 255-260.
- Chica-Olmo, M. y Abarca-Hernández, F. (2000). Computing geostatistical image texture for remotely sensed data classification. *CG*, Vol. 26(4), pp. 373-383.
- Chica-Olmo, M. y Abarca-Hernández, F. (2004). *Variogram derived image texture for classifying remotely sensed images*. En RSIA, pp. 93-111.
- Chuvieco, E. (1996). *Fundamentos de teledetección espacial (3ª ed.)*. Madrid: Ediciones Rialp S.A.
- Chuvieco, E. (1998). El factor temporal en teledetección: evolución fenomenológica y análisis de cambios. *Revista de Teledetección*, Vol. 10. http://www.aet.org.es/revistas/revista10/AET10_4.pdf (último acceso 10/11/2009).
- Cohen, Y. y Shoshany, M. (2000). Integration of remote sensing, GIS and expert knowledge in national knowledge-based crop recognition in Mediterranean environment. *IAPRS*, Vol. XXXIII, Part B7, pp. 280-286.
- Comber, A., Fisher, P. y Wadsworth, R. (2005). You know what land cover is but does anyone else? ... an investigation into semantic and ontological confusion. *IJRS*, Vol.26:1, pp.223-228.
- Corchado, E. y Fyfe, E. (2004). *Redes neuronales artificiales*. En J. Hernández Orallo, M. J. Ramírez Quintana y C. Ferri Ramírez, (Eds.), *Introducción a la minería de datos*. Madrid: Pearson Educación, S.A., pp. 327-352.
- De Jong, S. M., Pebesma, E. J. y Van der Meer, F. D. (2004). *Spatial variability, mapping methods, image analysis and pixels*. En RSIA, pp. 17-35.

Del Bosque, I., Arozarena, A., Villa, G., Valcárcel, N. y Porcuna, A. (2005) *Creación de un sistema de información geográfico de ocupación del suelo en España. "Proyecto SIOSE"*. Actas del XI Congreso Nacional de Teledetección, 21-23 Septiembre, Puerto de la Cruz, España, pp. 255-262.

De Wit, A. J. W. y Clevers, J. G. P. W. (2004). Efficiency and accuracy of per-field classification for operational crop mapping. *IJRS*, Vol. 68(11), pp. 1155-1161.

Dietterich, T. G. (2000). *Ensemble methods in machine learning*. En Multiple Classifier Systems. Springer, pp.1-15.

Directiva 2007/2/CE del Parlamento Europeo y del Consejo por la que se establece una infraestructura de información espacial en la Comunidad Europea (INSPIRE). 2007. *Diario Oficial de la Unión Europea*, Vol. L108, pp. 1-14.

Durrieu, M., Ruiz, L.A., Balaguer, A. (2005). *Analysis of geostatistical parameters for texture classification of satellite images*. Proceedings of the 25th EARSEL Symposium: Global Developments in Environmental Earth Observation from Space, 6-11 Junio, Porto Portugal, pp. 11-18.

Escudero, M. R. y Galiano, M. A. (2007). *Control asistido por Teledetección en España de las Ayudas de la PAC a la superficie de cultivos*. En Rivas, R., A. Grisotto y M. Sacido (Eds.), Actas del XII Congreso de la Asociación Española de Teledetección, 19-21 Septiembre, Mar del Plata, Argentina. pp. 38-45.

Fanning, D. (2002). *Programa para la obtención de los píxeles frontera de un objeto en una imagen*. En www.dfanning.com/programs/find_boundary.pro (último acceso 10/11/2009).

Fernández Sarría, A. (2007). *Estudio de técnicas basadas en la transformada wavelet y optimización de sus parámetros para la clasificación por texturas de imágenes digitales*. Tesis doctoral, Dpto. Ingeniería Cartográfica, Geodesia y Fotogrametría, Universidad Politécnica de Valencia.

Ferro, C. J. y Warner, T. A. (2002). Scale and texture in digital image classification. *PERS*, Vol. 68(1), pp. 51-63.

Fisette, T., Chenier, R., Maloley, M., Gasser, PY., Huffman, T., White, L., Ogston, R. y Elgarawany, A. (2006). *Methodology for a canadian agricultural land cover classification*. En S. Lang, T. Blaschke y E. Schöpfer (Eds.), OBIA. 4-5 Julio, Salzburg, Austria. <http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).

Förster, M. y Kleinschmit, B. (2006). *Integration of ancillary information into object-based classification for detection of forest structures and habitats*. En S. Lang, T. Blaschke y E. Schöpfer (Eds.), OBIA. 4-5 Julio, Salzburg, Austria. <http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).

Freeman, H. (1961). On the encoding of arbitrary geometric configurations. *IEEE Transactions on electronic computers*, Vol. 10(2), pp. 260-268.

- Freund, Y. (1995). Boosting a weak learning algorithm for majority. *Information and Computation*, Vol. 121(2), pp. 256-285.
- Freund, Y. y Shapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, Vol. 55(1), pp. 119-139.
- Friedl, M. A., McIver, D. K., Hodges, J. C. F., Zhang, X. Y., Muchoney, D., Strahler, A. H., Woodcock, C. E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F. y Schaaf, C. (2002). Global land cover mapping from Modis: algorithms and early results. *RSE*, Vol. 83(1-2), pp. 287-302.
- Friedman, J., Hastie, T. y Tibshirani, R. (2000) . Additive logistic regression: a statistical view of boosting. *The Annals of Statistics*, Vol. 28(2), pp. 337-407.
- Fuller, R. M., Smith, G. M. y Thomson, A. G. (2004). *Contextual analyses of remotely sensed images for the operational classification of land cover in United Kingdom*. En RSIA, pp. 271-290.
- Galli, A. y Malinverni, E. S. (2005). *Hyperspectral data classification by object-oriented approach for the management of urban landscape*. Proceedings of International Cartographic Conference 9-16 Julio, La Coruña, España.
http://cartography.tuwien.ac.at/ica/documents/ICC_proceedings/ICC2005/htm/pdf/oral/TE_MA10/Session%202/ANDREA%20GALLI.pdf (último acceso 10/11/2009).
- Gong, P. y Howarth, P. J. (1990) . The use of structural information for improving land-cover classification accuracies at the rural-urban fringe. *PERS*, Vol. 56(1), pp. 67-73.
- Gong, P. y Xu, B. (2004). Contextual image analysis methods for urban applications. En RSIA, pp. 137-152.
- González R.C. y Woods, R. E. (1996). *Tratamiento digital de imágenes*. Wilmington (E.U.A.): Addison-Wesley Iberoamericana,S.A.
- Guijun, Y. (2004). Land cover change automatic detection based on parcel-knowledge integrate RS with GIS. *IAPRS*, Vol. 35, Part 7, pp. 1160-1162.
- Haj-Yehia, B. y Peled, A. (2004). Rule-base system for updating spatial data-base. *IAPRS*, Vol 35, Part 2, pp. 498-502.
- Hájek, F. (2006). *Object analysis of Ikonos XS and Pan-Sharpned imagery in comparison for purpose of tree species estimation*. En S. Lang, T. Blaschke y E. Schöpfer (Ed.), OBIA.4-5 Julio, Salzburg, Austria. <http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).
- Haralick, R. M., Shanmugan, K. y Dinstein, I. (1973). Texture features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, Vol.3(1), pp. 610-621.

- Hay, G. J. y Marceau, D. J. (2004). Multiscale object-specific analysis (MOSA): an integrative approach for multiscale landscape analysis. En RSIA, pp. 71-92.
- Hay, G. J. y Castilla, G. (2006). *Object-based Image Analysis: Strengths, weakness, opportunities and threats (SWOT)*. En S. Lang, T. Blaschke y E. Schöpfer (Eds.), OBIA. 4-5 Julio, Salzburg, Austria. <http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).
- Heipke, C. y Straub, B. M. (1999) *Towards the automatic GIS update of vegetation areas from satellite imagery using digital landscape model as prior information*. IAPRS, Vol. 32, Part 3-2W5, pp.167-174.
- Heipke, C., Pakzad, K. y Straub, B. M. (2000). Image analysis for GIS data acquisition. *Photogrammetric Record*, Vol.16(96), pp.963-985.
- Hernández Orallo, J., Ramírez Quintana, M. J. y Ferri Ramírez, C. (2004). *Introducción a la minería de datos*. Madrid: Pearson Educación S.A..
- Hodgson, M. E., Jensen, J. R., Tullis, J. A., Riordan, K. D. y Archer, C. M. (2003). Synergistic use of Lidar and color aerial photography for mapping urban parcel imperviousness. *PERS*, Vol. 69(9), pp. 973-980.
- Hoffer, R. M. et al. (1975). *Natural resource mapping in mountainous terrain by computer analysis of ERTS-1 Satellite Data*. LARS Technical Note 061575, Purdue University, Indiana.
- Hommer, C., Huang, C., Yang, L., Wylie, B. y Coan, M. (2004). Development of a 2001 national land-cover database for the united states. *PERS*, Vol. 70(7), pp. 829-840.
- Hu, M. (1962). Visual pattern recognition by moment invariants. *IRE Transactions on Information Theory*, Vol. 8(2), pp. 179-187
- Huang, X. y Jensen, J. R. (1997). A machine-learning approach to automated knowledge-base building for remote-sensing image analysis with GIS data. *PERS*, Vol. 63(10), pp. 1185-1194.
- Instituto Geográfico Nacional. (2001a). *Guía técnica de actualización del Corine Land Cover*.
http://www.fomento.es/MFOM/LANG_CASTELLANO/DIRECCIONES_GENERALES/INSTITUTO_GEOGRAFICO/Teledeteccion/corine/clc2000/documentos/doc_tecnica/010419GuiatecnicaadeactualizaciondelCORINELandCover-doc.htm (último acceso 10/11/2009).
- Instituto Geográfico Nacional. (2001b). *Nomenclatura del Corine Land Cover al nivel 5º*.
http://www.fomento.es/NR/rdonlyres/86D25BA3-E051-4239-B4B9-D149BBEB2501/3164/021213Nomenclatura5_descrip.doc (último acceso 10/11/2009).
- Instituto Geográfico Nacional - Equipo Técnico Nacional SIOSE. (2007). *Modelo Conceptual del Proyecto SIOSE v1.12*.
http://www.ign.es/siose/Documentacion/Modelo_de_datos_SIOSE/070213_Modelo_Conceptual_SIOSE_v1_12.pdf (último acceso 10/11/2009).

- Instituto Geográfico Nacional. (2009). *Plan Nacional de Teledetección versión 2.0*. http://www.juntadeandalucia.es/medioambiente/web/Red_informacion_ambiental/productos/teledeteccion/plan_nacional_teledeteccion/plan_espanha/090417%20Documento%20PNT%20version%202.0.pdf (último acceso 10/11/2009).
- Jain, A. K. y Farrokhnia, F. (1991). Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, Vol. 24(12), pp. 1167-1186.
- Jakomulska, A. y Clarke, K. C. (2000). *Variogram-derived measures of textural image classification*. En P. Monestiez, D. Allard y R. M. Fuller (Eds.), *Proceedings of geoENV III - Geostatistics for Environmental Applications*. 22-24 Noviembre, Avignon, Francia, pp. 345-355.
- Janssen, L. L. F., Jaarsma, M. N. y Van der Linden, T. M. (1990). Integrating topographic data with remote sensing for land-cover classification. *PERS*, Vol. 56(11), pp. 1503-1506.
- Janssen, L. L. F. y Middelkoop, H. (1992). Knowledge-based crop classification of a Landsat Thematic Mapper image. *IJRS*, Vol. 13(15), pp. 2827-2837.
- Janssen, L. L. F. y Molenaar, M. (1995). Terrain objects, their dynamics and their monitoring by the integration of GIS and Remote Sensing. *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 33(3), pp. 749-758.
- Jensen, J. R. (2005). *Introductory digital image processing* (3ª ed.). Upper Saddle River (E.U.A.): Pearson Education, Inc.
- Johnsson, K. (1994). Segment-based land-use classification from SPOT satellite data. *PERS*, Vol. 60(1), pp. 47-53.
- Journel, A. G. y Huijbregts, C. J. (1978). *Mining Geostatistics*. New York: Academic Press.
- Konecny, G. (1996). Hochauflösende Fernerkundungssensoren für kartographische Anwendungen in Entwicklungsländer. *Zeitschrift für Photogrammetrie und Fernerkundung*, Vol. 64, pp. 39-51.
- Kort y Matrikelstyrelsen. (2001). *TOP10DK geometrisk registrering specifikation udgave 3.2.0*, National Survey and Cadastre, Copenhagen.
- Krummel, J. R., Gardner, R. H., Sugihara, G., O'Neill, V. y Coleman, P. R. (1987). Landscape patterns in a disturbed environment. *OIKOS*, Vol. 48(3), pp. 321-324.
- Landis, J. R. y Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, Vol. 33(1), pp. 159-174.
- Lang, S. y Blaschke, T. (2006). *Bridging remote sensing and GIS - which are the main supportive pillars?*. En S. Lang, T. Blaschke y E. Schöpfer (Eds.), *OBIA*. 4-5 Julio, Salzburg, Austria. <http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).

Lawrence, R. L. y Wright, A. (2001). Rule-based classification systems using classification and regression tree (CART) analysis. *PERS*, Vol. 67(10), pp. 1137-1142.

Laws, K. I. (1985). Goal-directed texture image segmentation. *Applications of Artificial Intelligence II*, SPIE Vol. 548, pp. 19-26.

Leránz, A., Albizua, L. y Zalba, M. (2007). *Nueva metodología de estimación de superficies de cultivos*. En Rivas, R., A. Grisotto y M. Sacido (Eds.), Actas del XII Congreso de la Asociación Española de Teledetección, 19-21 Septiembre, Mar del Plata, Argentina. pp. 46-51

Levien, L. M., Roffers, P., Maurizi, B., Suero, J., Fischer, C. y Huang, X. (1999). *A machine-learning approach to change detection using multi-scale imagery*. Proceedings of American Society of Photogrammetry and Remote Sensing Annual Conference, 17-21 Mayo, Portland, Oregon. http://frap.cdf.ca.gov/projects/change_detection/pdfs/asprs99b.pdf (último acceso 10/11/2009).

Li, D., Di, K. y Li, D. (2000). Land use classification of remote sensing image with gis data based on spatial data mining techniques. *IAPRS*. Vol 33, Part B3, pp. 238-245.

Li, D., Sui, H. y Xiao, P. (2002). Automatic change detection of geo-spatial data from imagery. *IAPRS*, Vol. XXXIV, Part 2, pp. 245-251.

Lizarazo, I. y Elsner, P. (2008). *From pixels to grixels: A unified functional model for geographic object-based image analysis*. Proceedings of GEOBIA, 2008 - Pixels, Objects, Intelligence: Geographic Object Based Image Analysis for the 21st century. 5-8 Agosto, Calgary, Canada. http://homepages.ucalgary.ca/~gjhay/geobia/Proceedings/Sessions/Session10/6664_Lizarazo_Proc.pdf (último acceso 10/11/2009).

Lobo, A., Chic, O. y Casterad, A. (1996). Classification of Mediterranean crops with multisensor data: per pixel versus per-object statistics and image segmentation. *IJRS*, Vol. 17(12), pp. 2385-2400.

López González, F.J., Crecente Maseda, R. y Álvarez López, C.J. (2002). *Los usos del suelo analizados mediante S.I.G.* XIV Congreso de Ingeniería Gráfica. 5-7 Junio, Santander, España. <http://departamentos.unican.es/digteg/ingegraf/cd/ponencias/196.pdf> (último acceso 10/11/2009).

Lu, D. y Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *IJRS*, Vol. 28(5), pp. 823-870.

Maillard, P. (2003). Comparing texture analysis methods through classification. *PERS*, Vol. 69(4), pp. 357-367.

Malila, W. A. (1980) *Change vector analysis: An approach for detecting forest changes with Landsat*. Proceedings of LARS Machine Processing of Remotely Sensed Data Symposium, 3-6 Junio, West Lafayette, Indiana, E.U.A., pp. 326-336.

- Mallat, S. G. (1989). A theory of multiresolution signal decomposition: The wavelet representation. *IEEE Transactions on Pattern Analysis Machine Intelligence*, Vol. 11(7), pp. 674-693.
- Manzano Agugliario, F., Tapias Esteban, M. J. y Manzano Agugliario, G. (2003). El proceso de actualización catastral de rústica: aplicación a los TT.MM. de La Mojonera y Nacimiento (Almería). *Catastro*, Vol. 47, pp. 75-90.
- Marchant, J. A. (1996). Tracking of row structure in three crops using image analysis. *Computers and Electronics in Agriculture*, Vol. 15(2), pp. 161-179.
- Maselli, F., Conese, C., De Filippis, T. y Romani, R. (1995). Integration of ancillary data into a maximum-likelihood classifier with nonparametric priors. *Journal of Photogrammetry and Remote Sensing*, Vol. 50(2), pp. 2-11.
- Megier, J., Mehl, W. y Rupelt, R. (1984). *Per-field classification and application to SPOT simulated, SAR and combined SAR-MSS data*. Proceedings of the 18th International Symposium on Remote Sensing of Environment, 1-5 Octubre, París, Francia, pp. 1011-1018.
- Ministerio de Medio Ambiente y Medio Rural y Marino. (2001). *Actualización del Mapa de Cultivos y Aprovechamientos de España. Hojas Escala 1:50.000*. Documento interno.
- Mirón Pérez, J. (2005). El catastro y la reforma de la política agrícola común de la Unión Europea. La implantación del SIGPAC. *Catastro*, Vol. 54, pp. 7-40.
- Nelson, T., Boots, B. y Wulder, A. (2005). Techniques for accuracy assessment of tree locations extracted from remotely sensed imagery. *Journal of Environmental Management*, Vol. 74(3), pp. 265-271.
- Niederöst, M. (2000). Reliable reconstruction of buildings for digital map revision. *IAPRS*, Vol. XXXIII, Part B3, pp. 635-642.
- Olsen, B. P., Knudsen, T. y Frederiksen, P. (2002). Digital change detection for map database update. *IAPRS*, Vol. XXXIV, Part 2, pp. 357-364.
- Ozdarici, A. y Turker, M. (2006). *Field-based classification of agricultural crops using multi-scale images*. En S. Lang, T. Blaschke y E. Schöpfer (Eds.), OBIA. 4-5 Julio, Salzburg, Austria. <http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).
- Pajares, G. y De la Cruz, J. M. (2001). *Visión por computador: Imágenes digitales y aplicaciones*. Madrid: RA-MA Editorial.
- Pakzad, K. (2002). Knowledge based multitemporal interpretation. *IAPRS*, Vol.34, Part 3A, pp. 234-239.
- Pedley, M. I. y Curran, P. J. (1991). Per-field classification: an example using SPOT-HRV imagery. *IJRS*, Vol. 12(11), pp. 2181-2192.

Pedroni, L. (2001). Discriminación de diferentes tipos de bosque tropical mediante imágenes de satélite y datos auxiliares. *Revista Forestal Centroamericana*, Vol. 34, pp. 12-18.

Peled, A. y Haj-Yehia, B. (1998). Toward automatic updating of the Israeli National GIS - Phase II, *IAPRS*, Vol. 32, Part 4, pp. 467-472.

Perdigao, V. y Annoni, A. (1997). *Technical and methodological guide for updating Corine Land Cover database*. European Environment Agency Technical report 17288 EN. http://www.fomento.es/NR/rdonlyres/9F7D4816-169E-4F5C-B538-AFC752DFF75A/3118/update_guide.pdf (último acceso 10/11/2009).

Pouliot, D. A., King, D. J., Bell, F. W. y Pitt, D. G. (2002). Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *RSE*, Vol. 82(2-3), pp. 322-334.

Pozzobon Martins, M., Frutuoso Guimaraes, L. N. y Garcia Fonseca, L. M. (2002). *Classificador de texturas por redes neurais*. Proceedings of II Congresso Brasileiro de Computação - CBComp 2002. 20-30 Agosto, Itajaí, Brasil, Vol.1, pp.1-12.

Pratt, W.K. (1991), *Digital image processing (2ª ed.)*. New York: Wiley Interscience.

Pyrz, M. J. y Deutsch, C. V. (2003). *The whole story on the hole effect*. En S. Searston (Ed.), Geostatistical Association of Australasia Newsletter.

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, 4-8 Agosto, Portland, Oregon, E.U.A., pp. 725-730.

Quinlan, J. R. (1996b). Improved use of continuous attributes in C4.5. *Journal of Artificial Intelligence Research*, Vol. 4, pp. 77-90.

Quinlan, J. R. (1996c). Learning decision tree classifiers. *ACM Computing Surveys*, Vol. 28(1), pp. 71-72.

Quinlan, J. R. (1999). Simplifying decision trees. *International Journal of Human-Computer Studies*, Vol. 51(2), pp. 497-510.

Raclot, D., Colin, F. y Puech, C. (2005). Updating land cover classification using a rule-based decision system. *IJRS*, Vol. 26(7), pp. 1309-1321.

Ramirez, J. R. (2005). Updating of geospatial data: a theoretical framework. *Surveying and land internation systems*, Vol. 65(4), pp. 245-254.

Real Decreto Legislativo 1/2004 por el que se aprueba el texto refundido de la Ley del Catastro Inmobiliario. 2004. *Boletín Oficial del Estado*, Vol. 58, pp. 10137-10154.

- Real Decreto 2128/2004 por el que se regula el sistema de información geográfica de parcelas agrícolas. 2004. *Boletín Oficial del Estado*, Vol. 274, pp. 37481-37485.
- Recio, J. A., Acosta, P. y Durrieu, M. (2001). *Identificación de la variación de la superficie agroforestal detectada mediante imágenes Landsat TM*. Actas del 1^{er} Congreso nacional de ingeniería para la agricultura y el medio rural, 19-21 Septiembre, Valencia, España, pp. 515-520.
- Recio, J.A., Ruiz, L.A., Fdez.Sarría, A. y Hermosilla, T. (2006) *Integration of multiple feature extraction and object oriented classification of aerial images for map updating*. Proceedings of Second Recent Advances in Qualitative Remote Sensing, 25-29 Septiembre, Torrent, España, pp.391-396.
- Reglamento (CE) 1593/2000 del Consejo de la UE que modifica el Reglamento (CEE) nº 3508/92 por el que se establece un sistema integrado de gestión y control de determinados regímenes de ayuda comunitarios. 2000. *Diario Oficial de las Comunidades Europeas*, Vol. L182, pp. 4-7.
- Robbez-Masson, J. M. y Foltete, J. C. (2005). Localizing missing plants in squared-grid patterns of discontinuous crops from remotely sensed imagery. *CG*, Vol. 31(7), pp. 900-912.
- Ruiz, L. A., Fernández Sarría, A. y 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 Fernández, L.A., Fernández Sarría, A. y Recio, J.A. (2004). Texture feature extraction for classification of remote sensing data using wavelet decomposition: A comparative study. *IAPRS*, Vol. XXXV, Part B7, pp. 1109-1115.
- Ruiz, L.A., Recio, J.A., Hermosilla, T. (2007). *Methods for automatic extraction of regularity patterns and its application to object-oriented image classification*. Proceedings of Photogrammetric Image Analysis 07. 19-21 Septiembre, Munich, Alemania, pp. 117-121
- RuleQuest Research. *See 5: An Informal Tutorial*. <http://www.rulequest.com/see5-win.html> (último acceso 10/11/2009).
- Russ, J. C. (1995). *The image processing hand book (2ª ed.)*. Boca Ratón: CRC Press.
- Schmidt, K. S., Skidmore, A. K., Kloosterman, E. H., van Oosten, H., Kumar, L. y Janssen, J. A. M. (2004). Mapping coastal vegetation using an expert system and hyperspectral imagery. *PERS*, Vol. 70(6), pp. 703-715.
- Shapiro, L. G. y Stockman, G. C. (2001). *Computer Vision*. London: Prentice Hall.
- Singh, A. (1989). Digital change detection techniques using remotely-sensed data. *IJRS*, Vol. 10(6), pp. 989-1003.
- Skidmore, A. K. (1989). An expert system classifies eucalypt forest types using Thematic Mapper data and a Digital Terrain. *PERS*, Vol. 55(10), pp. 1449-1464.

Sluiter, R., De Jong, S. M., Van der Wast, H. y Walstra, J. (2004). *A contextual approach to classify Mediterranean heterogeneous vegetation using the spatial reclassification kernel (SPARK) and DAIS7915 imagery*. En RSIA, pp. 291-310.

Smith, G. M. y Fuller, R. M. (2001). An integrated approach to land cover classification: an example in the Island of Jersey. *IJRS*, Vol. 22(16), pp. 3123-3142.

Strahler, A. H., Logan, T. L. y Bryant, A. (1978). *Improving forest cover classification accuracy from Landsat by incorporating topographic information*. Proceedings of the 12th International Symposium on RSE 20-26 Abril, Manila, Filipinas, pp. 927-942.

Sutton, R. N. y Hall, E. L. (1972). Texture measures for automatic classification of pulmonary disease. *IEEE Transactions on Computers*, Vol. C-21(7), pp. 667-676.

Tullis, J. A. y Jensen, J. R. (2003). Expert system house detection in high spatial resolution imagery using size, shape and context. *Geocarto International*, Vol. 18(1), pp. 5-15.

Turker, M. y Kok, E. H. (2006). *Developing an integrated system for extracting the sub-fields within agricultural parcels from remote sensing images*. En S. Lang, T. Blaschke y E. Schöpfer (Eds.), OBIA. 4-5 Julio, Salzburg, Austria.
<http://www.commission4.isprs.org/obia06/papers.htm> (último acceso 10/11/2009).

Velasco Martín-Varés, A. (2007). La parcela catastral en las Infraestructuras Nacionales de Datos Espaciales (NDSI) y en INSPIRE. Resultados del grupo de trabajo sobre el papel de la parcela catastral en Europa. *Catastro*, Vol. 60, pp. 7-73.

Veronez, M. R., Reinhardt, A. O., Thum, A. B., Wittmann, G., da Silva, L. F. y Pertovt, L. E. (2007). *Artificial neural network: another option to determine soil surface temperature*. En Rivas, R., A. Grisotto y M. Sacido (Eds.), Actas del XII Congreso de la Asociación Española de Teledetección, 19-21 Septiembre, Mar del Plata, Argentina, pp. 327-332.

Villa, G., Peces, J.J., Domenech, E., Tejeiro, J.A. y Plaza, N. (2008). *El Plan Nacional de Teledetección*. Actas del Congreso Internacional de Ingeniería Geomática y Topográfica, TOP-CART, 18-21 Febrero, Valencia, España, on CD.

Volante, J. N., Campos, C. J., Noé, Y. E. y Elena, H. J. (2007). *Método de clasificación "por parcela" para la detección de cultivos: Aplicación al área agrícola de Las Lajitas (Salta, Argentina)*. En Rivas, R., A. Grisotto y M. Sacido (Eds.), Actas del XII Congreso de la Asociación Española de Teledetección, 19-21 Septiembre, Mar del Plata, Argentina. pp. 79-86.

Walter, V. (2000) Automatic change detection in GIS databases based on classification of multispectral data. *IAPRS*, Vol. XXXIII (B4), pp.1138-1145.

Walter, V. (2004). Object-based classification of remote sensing data for change detection. *PRS*, Vol. 58(3-4), pp. 225-238.

Wardlow, B. D. y Egbert, S. L. (2005). *State-level crop mapping in the U.S. central Great Plains agroecosystem using Modis 250-meter NDVI data*. Proceedings of Pecora 16 - Global

Priorities in Land Remote Sensing, 22-27 Septiembre, Sioux Falls, South Dakota, E.U.A., on CD

Weldon, T. P. y Higgins, W. E. (1998). An algorithm for designing multiple Gabor filters for segmenting multi-textured images. *IEEE International Conference on Image Processing*, 4-7 Julio, Chicago, Illinois, E.U.A., pp. 333-337.

Woodcock, C. E., Strahler, A. H. y Jupp, D. L. B. (1988a). The use of variograms in remote sensing I: Scene models and simulated images. *RSE*, Vol. 25(3), pp. 323-348.

Woodcock, C. E., Strahler, A. H. y Jupp, D. L. B. (1988b). The use of variograms in remote sensing II: real digital images. *RSE*, Vol. 25(3), pp. 349-379.

Wulder, M., Niemann, K. y Goodenough, G. D. (2000). Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *RSE*, Vol. 73(1), pp. 103-114.

Zhang, J., Guo, D. y Wan, Q. (1999). *Geospatial data mining and knowledge discovery using decision tree algorithm - a case study of soil data set of Yellow river delta*. En B. Li (Ed.), *Proceedings of Geoinformatics' 99 Conference*, 19-21 Junio, Ann Arbor, Michigan, E.U.A., pp. 1-8.

Zhang, S. y Liu, X. (2005). Realization of data mining model for expert classification using multi-scale spatial data. *IAPRS*, Vol. 36, Part 4/W6 on CD.